

GPによる学習を行うエージェントとその局所的交互作用を仮定したセル平面の挙動解析と応用

呂, 建軍

<https://doi.org/10.15017/3000377>

出版情報 : 経済論究. 122, pp.87-98, 2005-07-25. 九州大学大学院経済学会
バージョン :
権利関係 :

GPによる学習を行うエージェントとその局所的交互作用を仮定したセル平面の挙動解析と応用

呂 建 軍

概要

エージェント理論の分野として2次元平面上に配置されたセル上のエージェントのモデル分析が行われている。本論文では、局所的な交互作用と遺伝的プログラミング (GP: Genetic Programming) による学習を行うエージェントからなるセル平面の挙動解析と、その応用について述べる。これまでのモデル分析を参考にして、セル上のエージェントが2種類で相互に効用関数をもつモデルと、エージェントが1種類で囚人のジレンマに従い行動する2つのモデルを考察する。シミュレーションをもとにして、これらのモデルにおいて、ある条件のもとでは、均衡には達しないで2次元平面上のカオス状況が発生することを示す。更に、エージェントが確定的予測式に基づいて行動していることに注目してカオス制御の方法を用いて2次元平面上でのカオス振動を抑制し、クラスタを形成する方法を提案する。考察として、これまでのising modelなどとの関連性を述べる。

This paper deals with the analysis of multi agent systems on planer cells consisting of local interaction and GP learning and its applications. As the first type of agents model, we assume two kinds of agents having own utility functions predict their optimal behavior, and the market assess is used for the GP learning of agents. As the second

model, the single-type agents are assumed to behave on the Prisoner's dilemma game based on the GP learning using prescribed payoff. By simulation studies we show various chaotic phenomena are observed besides the equilibrium. Then, a control method based on GP procedure is proposed which leads the system to the formation of clusters of agents' states.

1 まえがき

エージェント理論の1つの分野として、最近、2次元平面上に配置されたセル上のエージェントの間での局所的な交互作用 (local interaction, あるいはlocal tradeとよばれる)を仮定するモデル分析が行われている[1]-[3]。特に、エージェントが2つの状態だけをとり得る場合の議論は、従来のイシングモデル、スピングラスあるいは囚人のジレンマなどの理論と密接に関連しており、注目されている。

本論文では、このようなエージェントからなるセル平面のモデルをとりあげ、これまでのモデルで提案されたエージェントの行動について、やや一般化した場合の議論を行う[8][9]。具体的には、局所的な交互作用と遺伝的プログラミング (GP: Genetic Programming) による学習を行うエージェントからなるセル平面の挙動解析と、その応用について述べる。

セル上に配置されたエージェントが交互作用

を行うモデルにはさまざまなものが存在するが、大きく分類すると、エージェントが2種類で相互に効用関数をもつモデルと（以下では2種エージェントモデルとよぶ）、エージェントが1種類で囚人のジレンマに従い行動するモデル（以下では1種エージェントモデルとよぶ）に分けられる [1]-[3]。本論文でも、これら2つのモデルを考察する。

これまでの研究では、主として均衡条件が検討され、近隣のセルとの交互差用だけを行うエージェントシステムを仮定し、エージェントが2つの状態のみをとる場合には、均衡点に達しクラスタ（同じ状態のエージェントの固まり）を構成する条件が知られている [1]。しかし、エージェントがGPにより学習的に最適化行動をとる場合へと一般化した場合には、均衡には達しないで2次元平面上のカオス的な状況が発生する。これは、エージェントの行動が決定論的に行われているもとで発生する興味ある現象である。本論文では、シミュレーションをもとにして、カオス性発生におけるパラメータの特定と、分岐の条件などを求める。

これまで、GP手法を用いてカオス時系列から力学系を推定する問題や、そのカオス制御への応用、エージェントにより構成される人工市場の分析と制御について示してきた。以下では、このGP手法を、セル平面上のエージェントの行動モデル化に応用する。本論文の手法においては、それぞれのエージェントがシステムの変化モデルをGPにより推定しており、決定論的な記述が可能となっている [4]-[9]。従って、この関数形が分かっているという特性を用いて、カオス的な振動を制御する方法を提案する。応用例として、このような人工的なエージェントが配置されたセル平面上の挙動解析と制御を行うとともに、関連するモデルとの比較と考察を

行う。

以下、2.では基本モデルについて述べ、3.ではGP手法の概要を述べる。4.ではカオス制御と均衡条件について述べる。5.および6.においては、2つの種類のエージェントモデルのシミュレーション結果について整理する。更に、7.ではこれまでのising modelなどとの関連性を考察する。

2 基本モデル

2.1 2種エージェントモデルと生産・消費の相互作用

以下では、本論文で考察する最初のモデルである2種エージェントモデルを説明する [1]。このモデルは、労働市場における雇用の地理的分布をはじめ、ising modelなど数理モデル解析にも利用されている。本論文では、エージェントの相互に利害関係が存在する場合を考察するので、分かりやすくするために、2種のエージェントが、それぞれ企業と労働者であるという表現を用いる。

2次元平面としてネットワークが広がっており、格子点（セルと呼ぶ）には企業と労働者（同時に商品を購入する消費者である）が1人ずつ配置されている。セルの場所を x , y で表す。

企業と労働者はエージェントとしてみなされGPを基礎として、次のような学習を実施しながら行動すると仮定する。なお、GPは関数近似のほかに、株式市場やサービス施設のシミュレーションに有効であり、ここではエージェントの行動をモデル化するのに用いている [3]-[5]。

なお、以下では変数には、本来なら時間を意味する添字である t が含まれるが、繁雑であるので省略している。

(1) 生産と消費

セル x に配置された企業は、製造する製品が販売でき収益がある限りは生産を継続する。製品は、ある範囲の市場で販売される。セル x の労働は賃金 $w(x)$ と企業からの移転所得 $\pi(x)$ により商品を購入する。労働者は、雇用されるか ($\eta(x)=1$)、失業か ($\eta(x)=0$) の2つの状態をとり、この状態が決まったもとの、予算制約、すなわち利用可能な金のもとで最適な消費配分 $c(x)$ を行う。

(2) 局所的な交易 (local trade)

エージェントは、周辺範囲 R 内の相手とだけ交易を行う。 R が小さい場合には限定された市場が前提とされ、 R が大きくなるに従って、交易がグローバル化する [1] [2]。具体的には、セル x の企業エージェントは、次の条件 $|x-y| \leq R$ (この範囲を、以下では N_x と表す) を満足する労働エージェント y に対する商品販売だけが可能であると仮定する。すなわち、販売収益は

$$pr(x) = \sum_{y \in N_x} p(x, y)c(y) \quad (1)$$

となる。ただし、 $p(x, y)$ は企業と労働者との交易確率である。同様に、情報の利用に関しても、企業と労働エージェントは周辺範囲 R だけのエージェントの情報だけが利用可能であると仮定しておく。

(3) 予測式による行動決定

エージェントである企業と労働者は、自己を含めて周辺 R 以内のエージェントの現在までの状態を入力として、次の時刻における自己の最適な行動パターンを予測式により同時に決定していく。具体的には、セル x における企業エージェントは周辺における雇用状況と消費状況を入力とする利益の予測式をもとに計算を実施し、予測する利益 ($\hat{r}(x)$ により表す) が正か負

かにより、生産の継続か中止を決める。セル x の労働者は、同様に周辺の労働者の雇用状況および消費状況を参考に、雇用されるかどうかの予測 ($\hat{\eta}(x)$ とする) を実施する。雇用されると予測する場合には消費 $w(x) + \pi(x)$ を実施し、雇用されないと予測する場合には $\pi(x)$ を消費する。なお、それぞれのエージェントはGPにおける個体のプールをそれぞれもっており、その適合度の最高の個体の予測値をもとに行動を決定すると仮定する。

(4) 市場における決定とGP学習

2種のエージェントは予測により、次の時刻における行動を決定するが、これは実際に、次の時刻となった場合に、市場において調整される。セル x の企業の利益は、次で計算される。

$$r(x) = \sum_{y \in N_x} p(x, y)c(y) - w(x)\eta(x) \quad (2)$$

この数値が正である場合には、企業はセルにおける雇用を実施する ($\eta(x)=1$ となる)、負の場合には雇用しない ($\eta(x)=0$ となる)。労働のエージェントはこれらの雇用の実現値と自身の行った予測値との差をもとにして個体の適合度を計算しておく。一定の時間 T の経過ののちにGPにより最適な学習が実施される。同様に、企業エージェントは、実現された利益 $r(x)$ と自身が行った利益予測 $\hat{r}(x)$ との差をもとにして、個体の適合度を計算し、一定の時間経過 T ののちにGP学習により最適化を実施する。

2.2 1種エージェントモデルと囚人のジレンマゲーム

次に、エージェントの種類が1つで、相互に囚人のジレンマゲームに従って行動が決定されるモデルを考察する [2]。この分野の研究として、エージェントが周辺のエージェントの利益を参考にして、自身の状態を切替えるモデルが

提案されている。本論文では、これを拡張し、周辺の状態を入力としてエージェントが次の状態を決定すると同時に、この予測誤差にもとづいてGP学習を行うモデルを考察する。

(1) 予測式による行動決定

セル x におけるエージェントは協力 (corporation) と非協力 (non-corporation, defection) 2つの状態をとり得ると仮定する。これを $\eta(x)=1$, $\eta(x)=0$ として表現する。セル x のエージェントは、自己を含めて周辺 R 以内のエージェントの現在の状態 $\eta(x)$, $y \in N_x$ を入力として、次の時刻における自己の最適な行動パターン $\eta(x)$ を予測式により決定していく。

(2) 市場における決定とGP学習

それぞれのエージェントは予測により、次の時刻における状態(態度) $\eta(x)$ を決定するが、これは実際に、次の時刻となった場合に、市場において表 1 に示すような利益関係 (payoff) により調整される。この利益の大きさが、エージェントの選択した個体の適合度を表すと考えられる。従って、エージェントは、これらの利益の実現値の累積をもとにして個体の適合度を計算しておく。一定の時間 T の経過ののちにGPにより最適な学習が実施される。

表 1 : エージェントの間の利益関係 (payoff)

	1(corporation)	0(defection)
1(corporation)	C,C	L,H
0(defection)	H,L	D,D

3 GP手法の基本と特徴記述

3.1 GPによる関数近似

本論文で用いるGP手法については、すでに多くの記述があるので、以下では要点のみを簡単にまとめておく [4]-[13]。

GPのシステムは基本的に、3つの部分からなりたっており、その第1番目は個体の表現である。方程式は木構造で表現できるが、これを前置表現 (prefix representation) により置き換えておく。例えば、方程式 $x(t)=(3 \times x(t-1) - x(t-2)) \times (x(t-3) - 4)$ は、次のように表現する。

$$\times - \times 3x(t-1)x(t-2) - x(t-3)4 \quad (3)$$

このような前置表現のそれぞれを、個体とよぶ。

次に必要なのが、GPにより表現された個体の解釈である。これには式(3)に示すような式により表現された方程式の右辺の形をもとにして、関数の値を求めることである。個体により計算された関数の値 $\hat{x}(t)$ と観測された時系列データ $x(t)$ との2乗誤差は近似度を与えるので、この逆数により個体の適合度を定義する。

第3番目に必要なのが、GPにより個体を性能の良いもの(今の場合には関数近似の能力のたかいもの)に変換していく方法である。個体の集合(プール)の能力をたかめることは、個体に対して交差処理、突然変異処理を行うことにより可能である。このため、StackCountというカウンタを用いる。

StackCountの値は、前置表現で表現された個体のストリングを左側からサーチしていき演算記号に出会うとその数値を1つ増やし、被演算子に出会うとその数値を1つ減らす操作を実施した結果である。個体のストリングの全体をサーチし終えたあとに、StackCountの数値は必ず1になる。従って、GPにおける初期個体を生成するときに、この条件を満足しないものは個体として採用しない。適合度に応じて2つの個体A、Bを選択したあと個体Aの交差位置を乱数により選択し、この位置におけるStackCountを計算しておく。次に、個体Bについて同じ

*StackCount*をもつ位置を検出し、等確率で、ある1つの交差点を確定する。これらの位置を境界として、それぞれの個体の前半と後半を、相互に交換した個体がoffspringとして生成される。

以上のような方法をアルゴリズムとしてまとめると、次のようになる [1]-[10]。

(ステップ1)

乱数を用いて被演算子、演算記号の並びからなる初期個体のプールを構成する。すでに述べた*StackCount*を用いて妥当性を検査する。

(ステップ2)

個体に表現された関数をもとに、それぞれの個体により得られる予測値を求める。これをもとにして、個体における適合度を求める。

(ステップ3)

遺伝的操作により新しい個体を生成する。次に示す適合度から変換された確率に応じて個体*i*が選択される。

$$p_i = (S_i - S_{min}) / \sum_{i=1}^N (S_i - S_{min}) \quad (4)$$

ここで、 S_{min} は適合度の最低値、 N はプールの大きさである。生成された新しい個体により、プールに存在する適合度の低い個体を置き換える。

(ステップ4)

ステップ2からステップ4までの交差処理をすべての個体に適用し、新しい個体のプールを作成したあとに、次に示す突然変異を実施する。突然変異にはG-突然変異とL-突然変異の2つの種類があり、適用する確率は同じとする。

G-突然変異：グローバルな突然変異を意味し、2つの個体に対する交差処理である。個体Aは選択され突然変異を適用する個体であるが、個体Bは、初期個体の発生と同じ手順を用いて一

時的に発生させた作業用の個体である。交差点を適切に決めたのちに、個体Aの後半を個体Bの後半と交換する（個体Bに対しては、特に何も操作や保存はしない）。

L-突然変異：任意に個体を選択して、この個体の被演算子、演算記号の部分を、任意に選択した被演算子、演算記号により置き換える。

(ステップ5)

ステップ2からステップ4までの操作を規定回数繰り返す。

3.2 共進化GPの適用

これまでの仮定では、それぞれのエージェントは固有の個体のプールを所有し、他のエージェントとの直接的な相互関連なくGPによる学習を進めている。これに対して、それぞれのエージェントの知識を共有する方法にも注目すべき点があることが知られている。このようなGPにおける知識の共有方法として、共進化(co-evolutionary) GPがある [7]-[9]。本論文でも、この共進化GPの実現の最も簡単な方法と取りあげる。具体的には、それぞれのエージェントが共通の個体のプールを用いて予測を行うとともに、GPによる個体の改善も全体を通じて共通に実施されるものである。

人工株式市場の分析においては、このような共進化GP手法により興味深い現象が観測されるが、本論文でとりあげるモデルでは、単調な現象だけが観測される。従って、以下の議論では詳細は省略する。

4 カオス制御と均衡条件

4.1 モデルの均衡条件

これまででは、カオス力学系をGPにより近似する方法を用いて、予測や近似を行う方法を提案

し、その有効性を確認している。同時に、カオス力学系が関数の形で近似表現できるので、均衡点へと移行する入力を加える方法で、カオス制御を行う方法を提案した。

本論文でモデル化を行っているような 2 次元平面上におけるカオス現象をモデル化し、カオス的な振動を抑制する方法についての検討は、ほとんど行われていない。従って、以下では、従来行ってきたカオス時系列の制御へ用いている方法を拡張することにする。

まず、2 種エージェントモデルに関しては、システムの均衡点の存在条件についていくつかのケースの結果が知られているので、これを参考にする。なお、エージェントの状態が 1 かゼロかの離散的な場合だけの結果を参照するが、連続値をとる場合の結果も示されている。

2 つの状態だけが可能な場合に、市場の均衡状態にいたる状況を示す。この場合、資本と労働の双方の利益最大化を同時に達成する場合 (planner モデルとよばれる) だけが均衡するので、次のような制約で資本と労働は行動する [1]。この最適な解は

$$\eta_t(x) = \begin{cases} 1, & \text{for } \sum p(x, y) E_{t-1} c_t(y) < \sigma; \\ [0, 1] & \text{for } \sum p(x, y) E_{t-1} c_t(y) = \sigma; \\ 0, & \text{for } \sum p(x, y) E_{t-1} c_t(y) > \sigma; \end{cases} \quad (5)$$

となる。ここで、 $E_{t-1}(\cdot)$ は時刻における期待値を意味する。通常の解析では $\sigma=0.5$ としておく。 $\eta_t(x)$ 、 $c_t(y)$ は、それぞれ、時刻 t における雇用 $\eta(x)$ と消費 $c(y)$ を意味する。

同様に、1 種エージェントモデルに関しても、エージェントが周辺のエージェントの中で利益を増加させているエージェントにならって行動を選択することにより、クラスタが形成され安定的な状態へと移行できることが示されている。

4.2 カオス制御の方法

カオス的な振動から制御を加えて安定化させる方法として、上の条件を参考にすると、次のような方法が考えられる。いま、エージェントが予測式 $f(x)$ をもとにして次の時刻の状態を決定する場合に、予測式の値がゼロ以上かゼロ未満であるかより、 $\eta(x)=1$ あるいは $\eta(x)=0$ の状態をとると仮定しておく。更に、次に示す周辺からの状態の平均値から期待値引いたものを求める。

$$g(x) = \sum_{y \in N_x} \eta(y) / N_x - 0.5 \quad (6)$$

予測値の値に、更に、この $g(x)$ を加えて、 $f(x) + g(x)$ がゼロ以上であるか、未満であるかにより状態決定を実施する。もし、 $g(x)$ がセルのエージェントの均衡点であるならば、常にこの方向に状態が修正されることになる。

この場合のシミュレーション結果は、次の章で示すが、結論的に言えば、式(6)の値はエージェントの状態の均衡点を与えており、クラスタが形成される。

5 2 種エージェントモデルのシミュレーション

5.1 カオス振動の発生

以下では、最初に 2 種エージェントモデルについてシミュレーションをもとにして、セル平面における状態の変化とその特徴を求め、考察を行う。シミュレーションの条件を次に示す。

(セル平面に関して)

セル平面の大きさ：50×50の平面

取引と情報収集の範囲： $R=1\sim 2$ を考察する

$w(t)$ 、 $\pi(x)$ ： $w(x)=0.5$ 、 $\pi=0, 0.01, 0.1$

セルの境界処理：セルにおける演算で境界を越える場所が発生したら反対の境界から始める

(トラス状)。(エージェントのGPに関して)

エージェントの所有する個体の数：100
 個体のストリング文字列の最大長さ：30
 個体予測式に含まれる演算子：+，×，-，abs
 個体予測式に含まれる変数：現在の時刻の $c(y)$ ， $\eta(y)$ ， $y \in N_x$
 GP実施間隔： $T=10$ ，10期間にわたり同じ個体を使用して予測その後GPで改善

最初に、それぞれのセルに配置された2種類のエージェントがランダムな状態から出発して、時間的に状態がどのように変化するかを示す。状態としては、セルにおける労働エージェントの雇用 $\eta(x)=1$ を黒の点で示すが、これは同時にこのセルにおける企業エージェントの操業になっている。この例の1つを図1に示す ($R=1$ ， $\pi=0.01$ としている)。

図1の例では、 $t=1$ ， $t=30$ の2つの時刻におけるパターンを示しているが、セル平面における状態のパターンは特定のクラスタなどへと収束してはいない。また周期的なパターンへも収束していないためカオス的な振動を繰り返して




図1：カオス振動を示すセル平面上の $\eta(x)=1$ の例




図2：カオス振動を示す $\eta(x)=1$ の比率

いると思われる。

なお、カオス的な振動を繰り返していることを示すために、セル平面における雇用の状態数、すなわち、 $\eta(x)=1$ となる数の割合を示した例が図2である。これから分かるように、時間ごとに割合の時系列は変動を繰り返している。

5.2 2種エージェントモデルシステムのカオス制御

次に、2種エージェントモデルで形成されたシステムのエージェントのカオス的な挙動を制御する事例を示す。前に述べたように、1つの均衡解として、周辺のセルの状態に近付ける方向で予測式を修正することが可能性として存在する。

図3には、ある時刻から式(6)に示す周辺のセルの状態の平均値からのずれを、予測式に加えながら、エージェントが個体の適合度を修正していく場合の状態の変化を示している。2番目(図3における右の図)は、労働エージェントのグループが形成され、いわゆるクラスタ(固まり)となっている。しかも、時間の経過とともに、このパターンは少なくとも短時間の間では、これ以上変化しない。従って、1つの均衡状態に移行したと考えられる。

5.3 初期クラスタの移動

これまでのシミュレーションで、エージェン




図3：カオス振動の制御(左：形成されたクラスタ，右： $\eta(x)=1$ の比率の時間変化)

トがランダムな初期状態をとるセル平面においては、ランダムな状態が継続されるが、制御を加えることにより安定したクラスタが形成されることが示された。以下では、逆に、初期状態としてまとまったクラスタを与えた場合のこの形状が、維持されるか消滅する、あるいはセル平面上を伝搬するなどの現象が見られるかを検討する。

いま、例として x 座標、 y 座標が $10 \leq x \leq 10$, $10 \leq y \leq 30$, とする領域には初期値 1 を与え、これ以外はゼロとしておく。最初に、特別な制御を加えないケースでは、このような帯状のクラスタ初期値を与えるにもかかわらず、クラスタは消滅し全部のセルがランダムな状態になる。

次に、帯状のクラスタを初期値として与えると同時に、本論文で用いているカオス制御の方法を適用した場合には、ある条件のもとではクラスタの形状が維持される。ただし、長い時間の経過を見ると、クラスタは拡大したり縮小したりする現象が見られる。具体的には、パラメータである $\pi(x)$ の値が $\pi > 0.4$ である場合にはクラスタは拡大するが、これ以外の場合には、クラスタは徐々にではあるが縮小する。

6 1種エージェントモデルのシミュレーション

6.1 カオス的な振動の発生

次に、1種エージェントモデルで構成されるシステムのシミュレーション結果についてまと




図4：クラスタの移動の例

める。シミュレーションの条件は2種エージェントモデルの場合と同じである。表1に示すパラメータは、単純化して次のようにする。

$$C=1, D=1.0e-03, L=0$$

$$H \quad H=1 \sim H=3 \text{ の範囲で変化させる。}$$

図5には $H=1.6$ の場合において、ランダムな状態から開始して、エージェントの状態が時間的にどのように変化するかを示す1つの事例をあげている。図では、黒の点はエージェントが協力状態 $\eta(x)=1$ にあることを示す。この図でも分かるように、エージェントの状態は時間の経過とともに、一定のパターンに収束することではなく、ランダムな変動を繰り返す。2種エージェントモデルの場合と同様に、セル平面に占める状態の割合の変化を時系列として示したものが図6である。これより分かるように、状態の変化は持続されていることが分かる。




図5：カオス振動を示すセル平面上 $\eta(x)=1$ の例




図6：カオス振動を示す $\eta(x)=1$ の比率

6.2 1種エージェントモデルのカオス制御

1種エージェントモデルにおけるエージェントの実施するGP学習を仮定した場合には、得られるセル平面上のパターンに、カオス的な変動が見られることが分かった。次に、この変動パターンに対して制御を加えて、均衡状態へと移行させることができるかどうかを検討する。

すでに述べたように、均衡状態への制御において有効な方法と思われるものは、周辺のエージェントの状態の期待値への接近の状況を参考にすることであり、この方法を用いる。

具体的には、セル x のエージェントが、次の時刻にとるべき状態を予測に用いる関数 $f(x)$ の値がゼロ以上であるか以下であるかの判断をする場合に、この関数の値に式に示される周辺のエージェントの状態の期待値からのずれ $g(x)$ を加えておく。すなわち、関数値 $f(x) + g(x)$ がゼロ以上であるか未満であるかに応じて、次の時刻におけるエージェントが $\eta(x) = 1$ とするか $\eta(x) = 0$ とするかを決める。

このような制御方法を用いた場合のエージェントの状態の変化を示したものが図7である。この図より分かるように、時間の経過とともに2種エージェントモデルの場合と同様にクラスタらしきものが形成されていることが分かる。しかし完全なクラスタのパターンではなく部分的に他の状態が混在している状況であることが分かる。

これを確認するため、セル平面上のすべてのエージェントに占める $\eta(x) = 1$ の割合の時間的な変化を求め、これを描いてみる。これを示したものが図8である。この図より分かるように、制御の結果として、 $\eta(x) = 1$ となるエージェントの比率は急速に一定の値に近づいているが、しかし、最後の段階でも小さな変動を繰り返している。これは、制御が完全に実施されたもの




図7：カオス制御の例（左：形成されたクラスタ，右： $\eta(x) = 1$ の比率の時間変化）

ではなく、小さな範囲での状態の入れ替わりがおきていることを示している。すなわち、完全にクラスタが形成され、時間的に変化することはない理想的な状態ではなく、そのクラスタの周辺で状態が変化し、続けるエージェントが存在することが示されている。

6.3 初期クラスタの移動

2種エージェントシステムの場合と同様に、 x 座標、 y 座標が $10 \leq x \leq 10$, $10 \leq y \leq 30$, となる領域には初期値1を与え、これ以外はゼロとしておく。最初に、特別な制御を加えないケースでは、このような帯状のクラスタ初期値を与えるにもかかわらず、クラスタは消滅し全部のセルがランダムな状態になる。

7 考察

7.1 イシングモデルとの関連性

セル平面上での局所的な交易をもつエージェントモデルとイシングモデルとの関連性について、文献[1]で簡単にふれられている。これらの研究の中では、定量的な分析として式に含まれている σ の値にランダム性が含まれる場合においてもクラスタが形成されること、および交易の確率 $p(x, y)$ が一様でなく、自身への依存が相対的に大きな場合などに、同様な興味ある結果が得られることがのべられている。

このように、パラメータにノイズが含まれて

いる場合の議論も重要ではあるが、以下では、特にイジングモデル臨界温度（あるいは臨界指数）との関係だけを議論する。鉄の磁化に見られるように、臨界温度を境界として磁化の方向が一定になるか、磁化が失われるかの2つの相が出現し、ちょうど臨界温度になってところで部分的な磁化が発生し、本論文で述べるようなクラスタが出現する。

ここで取り扱うようなエージェントからなるセル平面の2つのモデルにおいては、臨界温度に相当するものとして共通するものは、式(6)に示される周辺のエージェントの状態の平均値（これを臨界状態 S_a とよぶことにする）があげられる。また、2種エージェントシモデルにおいてはパラメータである $\pi(x)$ があり、1種エージェントモデルにおいては表1におけるパラメータ H, L, C, D がある。以下ではこれらのパラメータとイジングモデルにおける臨界温度との関連性をシミュレーションにより検討する。

(1) 周辺のエージェントの平均状態 S_a

周辺のエージェントの状態 S_a を1つの均衡状態と考えた場合には、これまでの議論では、この値を0.5に設定している。しかし、これを0.5より小さくすると、エージェントの全体を状態ゼロの状況に移行させることを意味している。従って、セル平面に配置されたエージェントの初期状態をランダムに1か0をとった場合には、最終的には全部のエージェントの状態は0に収束する。同様に S_a を0.5より大きくとった場合には、同様の初期状態からスタートすると、エージェントの状態はすべて1になる。

しかし、細かく調べると、この境界となる S_a の値は0.5から多少はずれていることがシミュレーションの結果として得られる。このように、クラスタ形成が促されるための S_a の値の臨界

点が存在することが分かる。

(2) 他のパラメータの影響

臨界状態である S_a の他のパラメータが、クラスタ形成に与える影響についても、シミュレーション結果をまとめておく。当然予想されることであるが、これらのパラメータの値を、ある境界より大きくあるいは小さくすることにより、クラスタ形成に影響が見られるであろう。また、複数のパラメータを含む場合には、これら相互の組み合わせによりいくつもの条件が出現する。従って、以下では次のような制限を設ける。

2種エージェントモデルに関しては、パラメータ $\pi(x)$ は資本から労働への厚生に相当するものであり、賃金である $\sigma(x)$ より十分に小さいことが必要である。従って、 $\pi(x) \leq 0.1$ の場合を考察する。1種エージェントモデルについては、パラメータ D はゼロに極めて近い値である必要があること、および制約式 $HLCD > 0.2$ を満足する必要があることを考慮する。

これらのパラメータの影響について、まとめている。この結果から、パラメータの許容範囲の一部ではクラスタ形成に直接影響を与えていることが観測されるが、ほとんどの領域で臨界状態である S_a によりクラスタ形成が制御されていることが分かる。

7.2 囚人のジレンマゲームと均衡

囚人のジレンマゲームにもとづき行動する1種エージェントモデルにおいては、状態1あるいは0を相互に選択することが均衡状態であるが、これを見出すまでの間の試行錯誤が存在する。本論文のモデルにおいても、エージェントが自己最適な行動を探索している限りは、ランダムなセル平面の状態は持続する。しかし、すでに述べたように、臨界状態を目標値とする制

御により、クラスタが形成される。

以下では、同様のことが再現できるかをシミュレーションで検討する。すなわち、均衡状態から制御を中止すれば、再びランダムな状態へと移行するのか、更に、再度制御を加えた場合に、同様なクラスタ形状は当然異なるが形成されるかどうかを見る。

結果的には、このような過程になることは肯定される。すなわち、クラスタ形成のためのカオス制御には再現性がある。このような方法を社会モデルとの関係で考察すれば、いったん社会的なクラスタ形成が完成されたのちに、何らかの不都合が発生した場合に、再度ランダムな状態へと移行させておいて、再度、臨界状態 S_a への状態遷移を進める制御を加えることに相当している。

8 むすび

本論文では、局所的な交互作用とGPによる学習を行うエージェントからなるセル平面の挙動解析について、セル上のエージェントが2種類で相互に効用関数をもつモデルと、エージェントが1種類で囚人のジレンマに従い行動する2つのモデルを考察した。シミュレーションをもとにして、モデルにおいて、2次元平面上のカオス的狀況が発生する条件、カオス制御の方法を用いて2次元平面上でのカオス振動を抑制する方法を提案した。

今後、実際に観測されるクラスタ形成の近似や、これを用いた制御について検討を進めていきたい。

参 考 文 献

[1] N. Oomes, “Local trade networks and spatially

persistent unemployment”, *Journal of Economic Dynamics and Control*, vol.27, pp.2115-2149, 2003.

[2] L. Tesfatsion, “Structure, behavior and market power in an evolutionary labor market with adaptive search”, *Journal of Economic Dynamics and Control*, vol.25, pp.419-457, 2001.

[3] A. V. Outkin, “Cooperation and local interactions in the prisoners’ dilemma game”, *Journal of Economic Behavior & Organization*, vol.52, pp.481-503, 2003.

[4] O. Kirchkamp, “Spatial evolution of automata in the prisoners’ dilemma”, *Journal of Economic Behavior & Organization*, vol.DD4352, pp.239-262, 2000.

[5] J. H. Holland and J. H. Miller, “Artificial adaptive agents in economic theory”, *Learning and Adaptive Economic Behavior*, vol.81, no.2, pp.365-370, 1992.

[6] 時永祥三, 呂 建軍, “局所的な交互作用とGPによる学習を行うエージェントからなるセル平面の挙動解析とその応用”, *信学技報*, CAS2004-30, pp.13-18, 2004.

[7] X Chen and S. Tokinaga, “Approximation of chaotic dynamics for input pricing at service facilities based on the GP and the control of chaos”, *Trans. IEICE*, vol.E85-A, no.9, pp.2107-2117, 2002.

[8] Y. Ikeda and S. Tokinaga, “Approximation of chaotic dynamics by using smaller number of data based upon the genetic programming”, *Trans. IEICE*, vol.E83-A, no.8, pp.1599-1607, 2000.

[9] Y. Ikeda and S. Tokinaga, “Controlling the chaotic dynamics by using approximated system equations obtained by the genetic programming”, *Trans. IEICE*, vol.E84-A, no.9, pp.2118-2127, 2001.

[10] 矢加部正幸, 時永祥三, “遺伝的プログラミングを用いたCNNによる拡散モデルの近似とその同期化への応用”, *電子情報通信学会論文誌*, vol.J85-A, no.5, pp.548-559, 2002.

[11] 池田欽一, “共進化によるカオス常微分システムの推定”, *電子情報通信学会論文誌*, vol.E85-A, no.4, pp.424-433, 2002.

[12] 陳 曉榮, 時永祥三, “共進化GPを用いたマルチ

エージェントシステムの構成とその人工市場分析への応用”, 電子情報通信学会論文誌, vol.E86-A, no.10, 2003.

- [13] Y. Ikedand S, Tokinaga, “Chaoticity and fractality analysis of an artificial stock market by the multi-agent systems based on the co-evolutionary Genetic Programming”, Trans. IEICE, vol.E87-A, no.9, pp.2387-2394, 2004.
- [14] J. Koza, “Genetic programming : A paradigm for genetically breeding populations of computer programs to solve problems”, Report No. STANCS-90-1314, Dept.of.Computer Science Stanford University, 1990.
- [15] J. Koza, “Evaluation and subsumption using genetic programming”, Proc of the First European Conference on Artificial Life, MIT Press, 1991.
- [16] J. R. Koza, Genetic Programming, MIT Press, 1992.
- [17] M. J. Keith and M. C. Martin, “Genetic programming in C++ : Implementation issues”, in (ed) K. E. Kinnerar, Jr., Advance in Genetic Programming MIT Press, 1994.