マルチエージェントシステムの共生学習進化 (Masbiole) の基礎検討

正 員 平 澤 宏太郎 (九州大学)

非会員 吉 田 英 正 (九州大学)

非会員 中 西 賢 精 (九州大学)

正 員 胡 敬 炉 (九州大学)

Basic Study of Multi Agent Systems with Symbiotic Learning and Evolution - Masbiole -

Hirasawa Kotaro, Member, Yoshida Hidemasa, Non-member, Nakanishi Katsushige, Non-member, Hu Jinglu, Member (Kyushu University)

Recently, systems are becoming more complex and larger than ever, so numerous attempts have been made by researchers to introduce biological features into artificial systems, because many biological systems in the nature exist as one of the most complex systems. In this paper, we paid attention to symbiotic learning and evolution among creatures. The purpose of this paper is to introduce a new modeling technology using the concept of symbiosis, and propose a new learning and evolutionary method named Masbiole for the multi agents systems, which uses symbiotic strategies such as mutualism, competition, predation and altruism to realize the symbiotic relations among agents consisted of neural networks. Further more, it is stated that Masbiole has pareto optimal solutions instead of common optimal solutions. From the simulations of Masbiole, it has been clarified that Masbiole can be a basic algorithm to realize the multi agent systems with symbiotic relations.

キーワード : multi agent system, symbiosis, learning, evolution, pareto optimal solutions

1. はじめに

近年、システムの複雑化かつ巨大化が進むにつれ、これらを解析・検討するための道具として、生命現象の挙動を工学的に反映させる研究が進められている^{(1)~(3)}。なぜなら、自然界の生態系などに見られる生命現象には工学のヒントとなるものが多く存在するからである。本論文では、生態系にみられる共生現象に注目し、マルチエージェントシステム(MAS)の学習進化プロセスに共利、搾取、競争、利他等の共生現象を考慮する新しい方式(Multi Agent Systems with Symbiotic Learning and Evolution: Masbiole)を提案する^{(4)~(6)}。

例えば、共利の学習進化とは、相手エージェントの評価指標の向上をも目指して自エージェントの評価指標を高めるように自エージェントの戦略を変更していくこと、搾取とは、相手エージェントの評価指標が減少し、かつ、自エージェントの評価指標が増大するように自エージェントの戦略を変更していく事と考える。従って、Masbioleでは、複数のエージェントから構成されるシステムにおいて、上

記のような共生による学習進化が自分と相手の2エージェント間で実行されるが、この結果、エージェント全体としては相互の共生関係に依存した複雑な学習進化が実現されることになる。Masbioleでは、このような共生関係に基づく学習進化型のモデルを構築することを目的としている。

例えば、企業をエージェントとして考えると、相手企業に協調の戦略(共利に対応する)あるいは、相手企業を淘汰する戦略(搾取に対応する)を採用した場合に、複数の企業間にどのような盛衰が展開するのか等を検討するモデルの構築に資することが可能となる。

また、Masbioleでは、自エージェントの評価指標のみならず、相手エージェントの評価指標をも考慮して自エージェントの戦略を学習進化させていくため、自エージェントの戦略はパレート最適解となる。この点が通常の学習進化とは基本的に異なる点である。なお、各エージェントが1個の個体で構成され、個体の戦略を共生戦略により変更していく事を本論文では共生学習、また、各エージェントが複数の個体により構成され、これらの個体群(集団)の戦略を共生戦略により変更していく事を共生進化ということに

表 1 エージェント i のエージェント j に対する
共生学習進化

Table 1. Symbiotic learning and evolution of
Agent i to Agent j

Symbiotic Learning	Agent i	Agent j
Mutualism	Improvement	Improvement
Competition	Deterioration	Deterioration
Predation	Improvement	Deterioration
Altruism	Deterioration	Improvement
Self Improvement	Improvement	-
Self Deterioration	Deterioration	-

する。従って共生学習では、パレート解の一点が、共生進化では複数個のパレート最適解を求めることが可能となる。

本論文では、第 2 章において共生学習進化の枠組みとパレート最適解の説明、第 3、4 章において共生学習アルゴリズムと共生進化アルゴリズムの提案、第 5 章では、進化よりむしろ学習に着目し、ニューラルネットワークで構成されたマルチエージェントシステムの共生学習のシミュレーションの結果を示す。共生進化のシミュレーションについては別途報告する。第 6 章は結論である。

2. 共生学習進化とパレート 最適解

Masbiole ではマルチエージェントシステムの各エージェントが行動評価 (Evaluation) と行動戦略 (Strategy) を持っており、各エージェントの行動戦略がエージェント間の共生関係により学習進化していく方式である (Fig.1)。

共生関係として、共利 (Mutualism)、競争 (Competition)、搾取 (Predation) および利他 (Altruism) を考える。共生学習進化は任意の 2 個のエージェント間で行う。例えば、エージェント i のエージェント j に対する共利学習進化とは、エージェント i の行動戦略を変更 (学習進化) した事により、エージェント i の行動評価が改善し、かつ、エージェント j の行動評価が善することを言う。又、エージェント i のエージェント j に対する搾取学習進化とは、エージェント i の行動戦略を変更 (学習進化) した事により、エージェント i の行動評価が改善し、かつ、エージェント j の行動評価が改悪することを言う。他の競争、利他の共生学習進化についても同様であり、その概要を Table 1 に示す。

なお、共生関係は Fig.1 のように複数のエージェント間に複雑に設定されるが、共生学習進化そのものは 2 個のエージェント間の組合せで実現するものとする。これは、複数のエージェント間の共生学習進化を 2 個のエージェント間の共生学習進化の組み合わせにて実現する方が、学習進化に関する創発現象の創出、学習進化アルゴリズムの実装の容易さの点で好ましいと考えたからである。

Table 1 中の Self Improvement と Self Deterioration は相手エージェントのことを考慮せず自エージェントの行動評価を改善あるいは改悪することに対応する。

1. はじめに において、Masbiole では自エージェントの行動評価のみならず、相手エージェントの行動評価をも考

図 1 Masbiole の基本構成
Fig.1. Basic structure of Masbiole

慮して、自エージェントの行動戦略を学習進化させるため、自エージェントの行動戦略はパレート最適解となると述べた。本章では、Table 1 の共生関係におけるパレート最適解についてより詳しく述べる。

Masbiole のパレート最適解を共生パレート解という。共生パレート解は次のように定義することができる。

エージェント j の行動戦略の集合 Λ_j に対して、下記の条件を満足する $(\lambda_i, \lambda_j) \in \Lambda_i \times \Lambda_j$ が存在しない時、
 $(\lambda_i^*, \lambda_j^*) \in \Lambda_i \times \Lambda_j$ は、エージェント j の集合 Λ_j に対するエージェント i の共生パレート解である。

< 条件 >
$$E_i(\lambda_i, \lambda_j) \sim E_i(\lambda_i^*, \lambda_j^*) \wedge E_j(\lambda_i, \lambda_j) \approx E_j(\lambda_i^*, \lambda_j^*) \quad (1)$$

- ただし、
- λ_i : エージェント i の行動戦略
 - Λ_i : エージェント i の行動戦略の集合
 - E_i : エージェント i の行動評価
 - $E_i(\lambda_i, \lambda_j)$: エージェント i が行動戦略 λ_i を、エージェント j が行動戦略 λ_j を採用する場合のエージェント i の行動評価
 - $\wedge$: 論理積記号

である。(1) 式の記号 $\sim$ および $\approx$ はエージェント i がエージェント j に対してどのような共生戦略をとるかにより次のようになる。

- < 共利戦略 > を取る時 $\sim : >, \approx : >$
- < 競争戦略 > を取る時 $\sim : <, \approx : <$
- < 搾取戦略 > を取る時 $\sim : >, \approx : <$
- < 利他戦略 > を取る時 $\sim : <, \approx : >$

なお、行動評価の増加を改善と考える。

前述のエージェント*i*のエージェント*j*に対する共生パレート解のイメージ例を共生戦略ごとに行動評価平面(E_i, E_j)上に描くと Fig.2 のようになる。

図2 エージェント*i*のエージェント*j*に対する共生パレート解
Fig. 2. Pareto optimal solutions of Agent *i* to Agent *j*

前述のごとく共生学習ではパレート最適解の一点が、一方、共生進化では複数個のパレート最適解が求まることになる。

3. 共生学習のアルゴリズム

〈3・1〉 行動戦略の変更を受け入れる確率の計算 本章では、前述の共生学習を具体化するアルゴリズムについて提案する。具体的には、エージェント*i*のエージェント*j*に対する共生学習を考える。学習にはグラジエント法を活用することも可能であるが⁽⁷⁾、より複雑な構成のエージェントにも対応できるようにランダム探索法の一つである適応的ランダム探索最適化手法(Random Search with Intensification and Diversification: RasID)⁽⁸⁾⁽⁹⁾を採用した。また、局所共生学習ではなく、大域的共生学習を実現するため、アニーリング法を活用している。

エージェント*i*の行動戦略の変更(RasIDによるランダム探索により行う)によるエージェント*i*とエージェント*j*の行動評価の増分 ΔE_i と ΔE_j を計算し、これによりエージェント*i*の行動戦略の変更を受け入れる確率 P_i を

$$P_i = \pi_i \wedge \pi_j \dots\dots\dots (2)$$

のように計算する。ここで、 π_i および π_j はエージェント*i*およびエージェント*j*がエージェント*i*の行動戦略の変更を受け入れる確率であり、Table 1の共生学習を考慮して、Fig.3のようにボルツマン方式あるいはメトロポリス方式により計算するものとする。

例えば、ボルツマン方式によってエージェント*i*がエー

Method	Improvement (Increase of Evaluation)	Deterioration (Decrease of Evaluation)
(Boltzmann)	$\pi = \frac{1}{1 + \exp(-\frac{\Delta E}{T})}$ 	$\pi = \frac{1}{1 + \exp(\frac{\Delta E}{T})}$
(Metropolis)	$\pi = \min\{1, \exp(\frac{\Delta E}{T})\}$ 	$\pi = \min\{1, \exp(-\frac{\Delta E}{T})\}$

図3 受け入れ確率計算のためのボルツマン方式とメトロポリス方式

Fig. 3. Boltzmann and Metropolis Method for calculating accepting probability π

ジェント*j*に対して搾取学習を行う場合には、

$$\pi_i = \frac{1}{1 + \exp(-\frac{\Delta E_i}{T})} \dots\dots\dots (3)$$

$$\pi_j = \frac{1}{1 + \exp(\frac{\Delta E_j}{T})} \dots\dots\dots (4)$$

となる。なお、(3) および (4) 式の T はアニーリングの温度パラメータである。また、自改善 (Self Improvement) および自改悪 (Self Deterioration) 共生学習の場合はエージェント*j*の行動評価を考慮しないので

$$P_i = \pi_i \dots\dots\dots (5)$$

となる。

〈3・2〉 RasID による行動戦略の学習 前述のように、行動戦略の変更(学習)は、RasID⁽⁸⁾⁽⁹⁾により行う。RasIDはランダム探索の一種であり、パラメータ探索の成功・不成功情報を活用し、探索の集中化と多様化を統一した枠組で実現する手法である。つまり、解近傍に改善解が存在する可能性が高いときには、解近傍を適切な探索幅で重点的に集中化探索し、解がローカルミニマムに陥り、解近傍に改善解が存在しない場合には大きい探索幅で広い領域を多様に探索し、大域的な最適解を求める手法である。

RasIDでは探索の成功・不成功の情報により上述のようにランダム探索の確率密度関数を修正していく。なお、確率 P_i を使用して、エージェント*i*の行動戦略の変更を受け入れるかどうかを具体的に計算するが、もしも行動戦略を変更することになった場合にはRasIDの確率密度関数の更新に必要な情報"探索成功"、"探索失敗"のうち"探索成功"を選び、行動戦略を変更しなくなった場合には、"探索失敗"を選ぶものとする。

4. 共生進化のアルゴリズム

〈4・1〉 共生戦略を考慮したランキングの計算 前述の共生学習アルゴリズムでは、各エージェントの行動評価の値に応じて Masbiole のパレート最適解の 1 点が求まることになる。本章では、エージェント i のエージェント j に対する共生進化を考え、エージェント i の複数個の共生パレート最適解を求める共生進化アルゴリズムについて提案する。共生進化アルゴリズムの基本的な考え方は、共生戦略を考慮した多目的遺伝的アルゴリズム⁽³⁾のランキングを活用し複数個のパレート最適解を求める点にある。

今、

$\lambda_{il} \in \Lambda_i$: エージェント i の行動戦略の集団 Λ_i の l 番目の個体

$\lambda_{jm} \in \Lambda_j$: エージェント j の行動戦略の集団 Λ_j の m 番目の個体

とすると、集団間の個体の組み合わせ $(\lambda_{il}, \lambda_{jm})$ に対応して、Fig.4のように行動評価平面上に行動評価点 $\{E_i(\lambda_{il}, \lambda_{jm}), E_j(\lambda_{il}, \lambda_{jm})\}$ を描くことができる。

図4 個体の組 $(\lambda_{il}, \lambda_{jm})$ の行動評価点

Fig. 4. Evaluation of $(\lambda_{il}, \lambda_{jm})$

従って、 $\{E_i(\lambda_{il}, \lambda_{jm}), E_j(\lambda_{il}, \lambda_{jm})\}$ が R 個の他の評価点に、エージェント i のエージェント j に対する共生戦略という意味で支配されている時、 $(\lambda_{il}, \lambda_{jm})$ の共生戦略のランクを $R+1$ とすることができる。Fig.5に $(\lambda_{il}, \lambda_{jm})$ のランクの計算の例を共生戦略ごとに示す。

〈4・2〉 突然変異、交叉、淘汰による進化 エージェント i の集団の個体の突然変異および交叉については、個体の遺伝子の形態に依存した適切な方式を採用するものとする。Masbiole に特異な方式を特に採用する必要はない。

淘汰に関しては (4.1) で述べたエージェント i の個体 λ_{il} とエージェント j の個体 λ_{jm} の組み合わせ $(\lambda_{il}, \lambda_{jm})$ に対して、エージェント i のエージェント j に対する共生戦略を考慮したランキングを計算し、ランキングの小さい組み合わせに対応するエージェント i の個体を優先して次世代に残すものとする。

Fig.6にエージェント i のエージェント j に対する共生進化のフロー図を示す。

図5 エージェント i のエージェント j に対する共生戦略に対応した $(\lambda_{il}, \lambda_{jm})$ のランクの計算例

Fig. 5. Examples of rank calculation of $(\lambda_{il}, \lambda_{jm})$ under the symbiotic strategy from Agent i to Agent j

5. 共生学習のシミュレーション

〈5・1〉 シミュレーション例 シミュレーションでは、各エージェントを階層型のニューラルネットワークで構成した。中間層および出力層のノード関数は $[0, 1]$ の値をとるシグモイド関数 $f(x) = \frac{1}{1 + \exp(-\phi x)}$ を使い、出力ノードの値を各エージェントの個体数の最大個体数に対する割合とした。従って、シミュレーションでは各エージェントの個体数が他エージェントとの共生学習によりどのように推移していくかを調べることができる。

シミュレーション例では、エージェントの行動評価の改善はエージェントの個体数が増加することに、また、行動評価の改悪はエージェントの個体数が減少することに対応する。エージェントの行動戦略はニューラルネットワークの重みベクトルであり、従って、エージェントの共生学習とは、他のエージェントとの共生関係を考慮して、ニューラルネットワークの重みを変更していくことである。

〈5・2〉 2 個のエージェントの共生学習のシミュレーション 本節では、2 個のエージェント、エージェント i とエージェント j の共生学習の基本特性を調べるため、エージェント i のエージェント j に対する共生学習とエージェント j のエージェント i に対する共生学習の基本的組合せにより各エージェントの個体数がどのように推移するかについて検討した。

〈5・2・1〉 シミュレーションの条件 エージェント i とエージェント j は Fig.7 のように他エージェントの出力が自エージェントの入力となるように接続されている。

また、エージェント i の行動戦略の変更がエージェント

図 6 エージェント i のエージェント j に対する共生進化の計算フロー
Fig. 6. Flow of symbiotic evolution of Agent i to Agent j

j の行動評価に直接影響を及ぼすように、エージェント間を相互に結合させている (Fig.7 参照)。つまり、エージェント i の出力に重み付けをし、エージェント j の出力層の

図 7 2 個のエージェント間の接続
Fig. 7. Connection between two agents

図 8 エージェントの内部構造
(2 個のエージェントの接続)

Fig. 8. Structure of agent constructed by layered neural networks (Two agents are connected)

表 2 2 個のエージェント間の共生学習のシミュレーション例

Table 2. Simulations of symbiotic learning between two agents

シミュレーション	i から j への共生学習	j から i への共生学習
1	共利	共利
2	競争	競争
3	搾取	搾取
4	利他	利他

シグモイド関数の入力に加え、同様にエージェント j の出力に重み付けをし、エージェント i の出力層のシグモイド関数の入力に加えている。

また、エージェントの内部の構造は、入力層 1、中間層 8、出力層 1 個の各ノードからなる階層型ニューラルネットワークで構成した (Fig.8 参照)。また、ニューラルネットワークの初期重みはすべて、 $-1.0 \sim 1.0$ の間でランダムに与えた。

シミュレーションは Table 2 に示す 4 ケースについて行った。例えば、シミュレーション 1 においては、エージェント i はエージェント j に対して共利の共生関係を考慮して行動戦略を変更し、また、エージェント j はエージェント i に対して同様 (共利) の共生関係を考慮して行動戦略を変更している。また、初期時刻 ($t=0$) の各エージェントの出力は各々 0.3, 0.7 とし、20000 ステップの共生学習を行った。

Fig.3 の受け入れ確率の計算にはボルツマン方式 (但し、 $T = 100/\log t$) を採用した。各エージェント毎に RasID ルーチンを、従って、エージェント i には RasID $_i$ を、また、エージェント j には RasID $_j$ を行動戦略の探索のために使用するが、RasID のパラメータはすべて Table 3 と同一の値を使用した。前述のように、共生学習は合計 20000 ステッ

表 3 RasID のパラメータの設定値

Table 3. Typical values of parameters in RasID algorithm

β_0	β_1	α	ϕ_0	$\phi_{\min}$	I_{sf0}	P_{sf0}
0.1	1000	0.995	0.1	0.001	10	0.58
ΔI_{sf1}	ΔI_{sf2}	$I_{sf \max}$	K_{cr}	c_i	c_d	
0.02	0.5	100	1.001	1.01	0.995	

ブであるが, RasID i と RasID j が交互に 1 回ずつそれぞれ 10000 ステップの共生学習を行っている。また, RasID i 学習と RasID j 学習の間で 1 ステップのネットワークのダイナミック計算を行うものとする。

なお, Fig.7 の例では, エージェント間の相互の重みによるフィードバックループが形成されているため, 各ステップごとにノード出力が収束するまで複数回の繰り返し計算を必要とする。以下の計算では 3~4 回の繰り返し計算で収束することを確認している。

また, シミュレーションでは, エージェント i とエージェント j の学習を交互に行っているが, 必ずしも交互に学習を行う必要はない。例えば, エージェント i のエージェント j に対する共生戦略のみを考える場合には, エージェント j の重みを固定し, エージェント i のニューラルネットワークの重みのみを学習することになる。これは, 例えば, 企業 i が企業 j に対して淘汰の戦略を実施するのに対して, 企業 j が企業 i に対してなんら手を打たないことに対応する。従って, エージェント i とエージェント j の学習の頻度は考慮する問題の設定に依存することになる。本論文では, お互いに同頻度で学習を行う事を前提に, エージェント i とエージェント j が交互に学習を行う事とした。

〈5・2・2〉シミュレーションの結果と考察 シミュレーション 1~4 において, エージェント i と j の行動戦略を交互に学習し, 各エージェントの個体数(出力)の時間的推移を調べた (Fig.9 参照)。

まず, シミュレーション 1 (共利 & 共利) の結果について考察する。エージェント i および j は自エージェントの個体数のみならず, 相手エージェントの個体数も増加させるように行動戦略を変更するが, Fig.9 を見ると, 確かに, エージェントの行動戦略の変更により両エージェントの個体数が増加しており, 正しく共利共利関係を満たすように行動戦略の学習が行われていることがわかる。

シミュレーション 2 (競争 & 競争) では, エージェント i および j は自エージェントの個体数のみならず, 相手エージェントの個体数も減少させるように行動戦略を修正するが, Fig.9 を見ると, 確かに, エージェントの行動戦略の変更により両エージェントの個体数が減少しており, 正しく行動戦略の学習が行われ, 競争競争関係を満たしていることがわかる。

シミュレーション 3 (搾取 & 搾取) では, エージェント i および j は自エージェントの個体数を増加させ, 相手エージェントの個体数を減少させるように行動戦略を学習する。Fig.9 より, 搾取の学習のため, エージェント j は一時個体数が減少するが, 両エージェントの個体数は最終的には増加しており, 行動戦略の学習が主に自エージェントの個体数の増加に強く影響していることがわかる。

また, シミュレーション 4 (利他 & 利他) では, エージェント i および j は自エージェントの個体数を減少させ, 相手エージェントの個体数を増加させるように行動戦略を変更している。Fig.9 より, エージェント i の個体数は減少し

(シミュレーション 1: 共利 & 共利)
(simulation 1: Mutualism & Mutualism)

(シミュレーション 2: 競争 & 競争)
(simulation 2: Competition & Competition)

(シミュレーション 3: 搾取 & 搾取)
(simulation 3: Predation & Predation)

(シミュレーション 4: 利他 & 利他)
(simulation 4: Altruism & Altruism)

図 9 2 個エージェントのシミュレーション
におけるエージェントの個体数の推移

Fig.9. Output values of the agents in simulations with two agents

ており、行動戦略の学習が自エージェントの個体数の減少に強く影響していることがわかる。しかし、エージェント j の個体数は最終的には増加しており、この場合、行動戦略の学習が相手エージェントの個体数の増加に強く影響していることがわかる。

上記のシミュレーションにおいて、比較的簡単な共生関係の学習を行っているにも関わらず、エージェントの個体数が単調に増加あるいは減少しない理由は、搾取や利他の場合、自エージェントの要求と相手エージェントの要求が矛盾する場合があること、さらには、例題のように2個の階層型ネットワークが相互に結合した動的なネットワークシステムでは時々刻々エージェントの入力が変動するため、必ずしも共生学習時のネットワークの入力条件と実際に動作する入力条件が同じにはならないからである。

〈5・3〉 3 個のエージェントの共生学習のシミュレーション 本節では、3 個のエージェントが比較的複雑な共生関係を学習するマルチエージェントシステムについて検討した。

〈5・3・1〉 シミュレーションの条件 3 個のエージェント i, j および k は Fig.10 のように、各エージェントの2個の入力が他の2つのエージェントの出力となるように接続されている。また、Fig.10 では図示していないが、前述のシミュレーションの場合と同様、自エージェントの行動戦略の変更が他エージェントの行動評価に直接影響を及ぼすように、エージェントの出力から重みを介して他エージェントの出力層の入力に接続されている。

また、各エージェントの内部構造は、Fig.11 のように入力層2、中間層8、出力層1個の各ノードからなる階層型ニューラルネットワークで構成している。

エージェントの数は3とし、極力一般的な共生関係を前提とした考察を行うため、エージェント間の共生関係を Fig.12 のように設定した。Fig.12(上図) では、エージェント i はエージェント j, k に対してそれぞれ共利、搾取の共生関係

図 10 3 個のエージェント間の接続
Fig. 10. Connection among three agents

図 11 エージェントの内部構造
(3 個のエージェントの接続)

Fig. 11. Structure of agent constructed by layered neural networks (Three agents are connected)

図 12 エージェント間の共生関係
Fig. 12. Symbiotic relation among agents

を考慮して行動戦略を変更し、エージェント j はエージェント i, k に対してそれぞれ搾取、利他の共生関係を考慮して行動戦略を変更し、また、エージェント k はエージェント i, j に対してそれぞれ利他、競争の共生関係を考慮して行動戦略を変更するように共生学習を行う。

また、Fig.12(下図) では、エージェント i のエージェント j に対する共生学習を変更した場合、つまり、エージェント i のエージェント j に対する共利学習を搾取学習に変えた場合のシミュレーションを行う。

初期時刻 ($t=0$) の各エージェントの出力は各々0.3, 0.5, 0.7とし、RasIDを使用してエージェント i 、エージェント j およびエージェント k が交互にそれぞれ 10000 ステップの学習を行う、従って、合計 30000 ステップの共生学習を行う方式を採用した。本シミュレーションでの各エージェントの交互の学習も、前途同様、各エージェントが同頻度で学習を行う事を前提としたこととする。

前途のシミュレーションと同様、RasID 学習間に 1 ステッ

図 13 エージェントの個体数の推移
Fig. 13. Output values of the agents
in the simulations with the three agents

ブのネットワークのダイナミック計算を行うものとする。
他の設定は、〈5.2.1〉のシミュレーションの条件と同じである。

〈5・3・2〉シミュレーションの結果と考察 Fig.12の両共生関係において、エージェント i の j に対する行動戦略、同様、 $i \rightarrow k, j \rightarrow i, j \rightarrow k, k \rightarrow i, k \rightarrow j$ の順に学習した結果の各エージェントの個体数（出力）の時間的推移をそれぞれ Fig.13に示す。

まず、Fig.12(上図)の共生関係を学習した場合の各エージェントの個体数（出力）の時間的推移（Fig.13（上図）参照）について調べる。エージェント i の個体数は、エージェント i の j に対する共利学習により増加、エージェント i の k に対する搾取学習により増加、エージェント j の i に対する搾取学習により減少およびエージェント k の i に対する利他学習により増加するのだが、これらの中で増加の方が大きく影響し、エージェント i の個体数は時間とともに増加している。また、エージェント j の個体数は、エージェント j の i に対する搾取学習により増加、エージェント j の k に対する利他学習により減少、エージェント i の j に対する共利学習により増加およびエージェント k の j に対する競争学習により減少するのだが、具体的には増加と減少の影響が同じくらいなので、エージェント j の個体数は時間とともに増加したり減少したりしている。また、同様にエージェント k の個体数は、エージェント k の i に対する利他学習により減少、エージェント k の j に対する競争学習により

減少、エージェント i の k に対する搾取学習により減少およびエージェント j の k に対する利他学習により増加するのだが、減少の影響の方が大きいので、エージェント k の個体数は時間とともに減少している。

次に、エージェント i の j に対する共生関係を変えた場合、つまり、Fig.12（上図）のエージェント i の j に対する共利学習を搾取学習に変えた場合の特性（Fig.12（下図）参照）について検討する。Fig.13（下図）を見ると、この共生関係の変更に直接関係しているエージェント j の個体数は減少する。またそれに伴い、エージェント j の個体数は増加しやすくなる。その結果、エージェント i の j への搾取学習が受け入れられにくくなり、かつ、エージェント j の i への搾取学習が受け入れられやすくなるので、エージェント i の個体数は減少する。また、エージェント k の j への競争学習が受け入れられにくくなり、かつ、エージェント j の k への利他学習が受け入れられにくくなるので、エージェント k の個体数の増減はエージェント j との関係においては一意に決まらない。しかし、エージェント i の個体数が減少したことにより、エージェント i の k への搾取学習が受け入れられやすくなり、かつ、エージェント k の i への利他学習が受け入れられやすくなるので、エージェント k の個体数はエージェント i との関係において減少する。しかし、エージェント i の個体数の減少によるエージェント k への影響は、エージェント j の変化の影響からは間接的であるため、その影響がそれほど大きくないことが Fig.13（下図）より確認できる。

Fig.13(下図)に関する上述の解析は3個のエージェントの相互作用の一部が変更した場合の解析であるが、エージェントの数が3個ゆえに現象の推定がある程度可能である。しかし、エージェント数が増大するにつれて、推定は困難となり、計算された現象はある種の創発現象とみなす事ができる。このことが共生学習進化に基づく複雑システムを取扱う Masbiole が、具体的な社会現象をモデル化する手法として有効になることを示唆している。

6. おわりに

本来、複雑大規模な動的システムは、複数個のエージェントが共利、競争、搾取、利他等の共生関係に基づいて学習進化していくシステムとしてモデル化可能であるという立場に立ち、新しいマルチエージェントシステムの学習と進化のための方式、Masbiole を提案した。

本論文では、Masbiole の解はパレート最適解となることを明らかにし、学習型と進化型 Masbiole の学習進化アルゴリズムを提案した。また、進化よりも特に学習に着目し、階層型ニューラルネットワークで構成された複数個のエージェントを Masbiole で共生学習する具体例により、Masbiole の基本的な特性を明らかにした。今後の課題は、Masbiole を進化システムへ展開すること、Masbiole を各種の応用システムに展開すること、および、本論文ではあらかじめ与えられていた共生関係をも学習進化させるメタ学習進化の

アルゴリズムを確立することである。
(平成 13 年 3 月 28 日受付, 同 13 年 10 月 31 日再受付)

文 献

- (1) 坂和, 石井, 西崎: ソフト最適化, 朝倉書店, 1995.
- (2) 林, 古橋: ファジィ・ニューラルネットワーク, 朝倉書店, 1995.
- (3) 坂和, 田中: 遺伝的アルゴリズム, 朝倉書店, 1995.
- (4) 中西, 平澤, 胡: 共生進化を考慮したマルチエージェントシステム, 第 39 回計測自動制御学会学術講演会予稿集, 2000.
- (5) 中西, 平澤, 胡, 村田: ニューラルネットワークによる共生進化マルチエージェントシステムの研究, 第 10 回インテリジェントシステムシンポジウム予稿集, 2000.
- (6) 江口, 平澤, 胡: Genetic Network Programing を用いた共生学習進化型マルチエージェントシステム, 第 40 回計測自動制御学会学術講演会予稿集, 2001.
- (7) K.Hirasawa, X.Wang, J.Murata, J.Hu, C.Jin: Universal learning network and its application to chaos control, Neural Networks, 13, pp.239-253, 2000.
- (8) 平澤, 東郷, 胡, 大林, 村田: ニューラルネットワークの適応的ランダム探索最適化手法-RasID-, 計測自動制御学会論文集, 34 巻, 8 号, pp.1088-1096, 1998.
- (9) J.Hu, K.Hirasawa, J.Murata: RasID - Random Search for Neural Network Training, Journal of Advanced Computational Intelligence, Vol.2, No.4, pp.134-141, 1998.

胡 敬 炉 (正員) 1985 年中国中山大学大学院修士課程修了。同年, 同大学電子工学科助手, 1988 年同講師。1993 年来日, 1997 年九州工業大学情報工学研究科博士後期課程修了。同年 4 月九州大学ベンチャービジネスラボラトリ非常勤研究員を経て, 同年 8 月同大学システム情報科学研究科助手, 現在に至る。計測自動制御学会, 電気学会の各会員。情報工学博士。

平 澤 宏太郎 (正員) 1942 年 1 月 26 日生。1964 年 3 月九州大学工学部電気工学科卒業。1966 年 3 月同大学大学院工学研究科修士課程電気工学専攻修了。同年 4 月(株)日立製作所入社 日立研究所勤務, 1989 年 8 月同研究所副所長。1991 年 8 月同大みか工場主管技師長。1992 年 12 月九州大学工学部教授, 1996 年 5 月同大学院システム情報科学研究科教授, 現在に至る。計測自動制御学会, 電気学会, 情報処理学会, IEEE の各会員。工学博士。

吉 田 英 正 (非会員) 1976 年 10 月 7 日生。1999 年九州大学工学部電気工学科卒業。同年, 同大学大学院システム情報科学研究科修士課程入学。現在, 電気電子システム工学専攻在学中。

中 西 賢 精 (非会員) 1977 年 11 月 2 日生。2000 年九州大学工学部電気工学科卒業。同年, 同大学大学院システム情報科学研究科修士課程入学。現在, 電気電子システム工学専攻在学中。