

分類子システムによるエージェントの共進化とマーケティングシミュレーション

石川 泰志 寺野 隆雄
筑波大学大学院 経営システム科学専攻
〒112-0012 東京都文京区大塚 3-29-1 • 03-3942-6855
email: {yasushi, terano}@gssm.otsuka.tsukuba.ac.jp

あらまし 本稿では、学習分類子システムを用いたエージェント指向の社会シミュレーションについて報告する。本エージェントは、(1)多目的問題を処理し、(2)多様な問題解決行動を行い、(3)同一環境に異種のエージェントが共存し、(4)エージェントが依拠する環境が複数存在する、という特徴を持つ。エージェントの学習手段として、同一種エージェント間の進化を促進する「行動の模倣」と「行動規範の模倣」の2つの組織学習方法および、異種エージェントクラス間の共進化をもたらす「行動への介入」の組織学習方法について提案し、その効果について示す。本システムの適用分野は、環境マーケティングである。

キーワード 学習分類子システム、マルチエージェント、組織学習、多目的問題、共進化、環境マーケティング

Co-evolution of Multiagents via Organizational-Learning Classifier System and its Application to Marketing Simulation

Yasushi ISHIKAWA, Takao TERANO
Graduate School of Systems Management, the University of Tsukuba, Tokyo
3-29-1 Otsuka, Bunkyo-ku, Tokyo 112-0012, Japan • +81-3-3942-6855
email: {yasushi, terano}@gssm.otsuka.tsukuba.ac.jp

Abstract This paper proposes an agent-based social simulation system with Organizational-Learning Oriented Classifier System. The system is characterized by the agents that (1) solve multi-objective problems, (2) pursue different goals, (3) form classes to behave and/or learn and (4) live in multiple environments. We report three organizational learning techniques, "Copy of other's actions" and "Copy of other's rules", that accelerate the evolution of intra-class agents, and "Intervention to other's actions" that accelerates co-evolution between different kinds of agents.

We implement the system applied to "Ecological Marketing", which reveals interesting agent behaviors on the domain.

key words Learning Classifier System, Multiagent, Organizational Learning, Multi-objective problem, Co-evolution, Ecological Marketing

1. はじめに

分類子システムをベースとして、複数のエージェントが互いに協調しあって問題を解決するような、マルチエージェントシステムに関する研究が盛んに行われている。また、マルチエージェントの組織学習についての研究も進展している [9]。組織学習の定義には様々なものが存在する [1], [2], [5] が、我々はここでは組織学習を、「組織を構成する個々のエージェントでは解けない問題群に対して、組織全体で学習を行うことである」と定義する [8]。

マルチエージェントの学習による問題解決の研究は、大きく 2 種類に分類することができる。ひとつは、システム内のエージェントが同一のゴールを目指して活動するもの、もうひとつは、異なるゴールを目指すエージェントが互いに影響しあいながら活動するものである。組織学習の観点から考えると、前者は主に適応行動方法をエージェント間で交換あるいは模倣することによって、よりよい問題解決を互いにを目指す組織学習であり、後者はエージェントの活動によって変化していく環境からのフィードバックを通してそれぞれの協調行動方法を互いに獲得していく組織学習であるといえる。

分類子システムをベースとした場合、エージェントの組織学習はエージェントが持つ分類子を交換することで行われることがある [7]。ただし分類子の交換は、エージェントの内部モデルが同一である場合にのみ有効なため、同一のゴールを目指すエージェントの組織学習でのみこの方法は意味がある。異なるゴールを目指すエージェントの組織学習は、通常の分類子システムによる強化学習の方法である、エージェントが置かれた環境からのフィードバック、あるいはスーパーバイザーによるエージェントの行動の制御によって組織学習が進められる。

本稿は、2 章の研究の目的、3 章のシステムの概要、4 章の環境マーケティングシミュレーション、5 章の組織学習に関する考察、6 章の共進化に関する考察で構成される。

2. 研究の目的

社会システムのシミュレーションをエージェントベースで行う際には、エージェントの組織学習は上記のような 2 種類の学習のどちらかであるとして單

純化することは非常に難しい。単純化をはばむ要因は、主に以下の 4 つで説明することができる。

2.1. 多目的問題を処理するエージェント

エージェントはある活動によって、複数の目的を同時に達成する必要があることが多い。すなわち、エージェントは多目的問題を処理する。たとえば車を運転するエージェントは、目的地にできるだけ早くたどり着きたいが、交通違反で警察官エージェントに捕まることは避けなければならない。よって車を運転するエージェントは、この二つの目的を車の運転という活動において達成しなければならない。

2.2. エージェントの多様性

エージェントがある活動を行うときに、活動の目的に対する重みはエージェントによって多様である。制限速度以上では絶対に走らないエージェントもいれば、暴走行為自体が目的のエージェントも存在するなど、車の運転という同一の活動における、エージェントの目的に対する重要度には無視できない差が存在する。

2.3. エージェントクラスの多種性

エージェントがあるゴールのために活動する環境下には、多種のエージェントが共存している。別の言い方をすると、1 つの環境は複数の種類のエージェントによって共有されている。同一のゴールを持つエージェントのグループをエージェントクラスと呼ぶことにすると、エージェントの活動する環境下には複数のクラスのエージェントが同時に存在し、エージェントは同一クラスのエージェントの活動を模倣して組織学習するとともに、他のクラスのエージェントの活動に適合するための組織学習も同時に実行なければならない。例えば自動車を運転するエージェントは、安全運転のためには他の自動車を運転するエージェントの行動に適合して覚えなければならないし、警察官エージェントに捕まらなければならないようにする方法を警察官エージェントの行動に適応して覚えなければならない。警察官エージェントは交通安全週間や VIP の来日などの要因によって行動を変化させてるので、その対処法を学習する必要もある。

2.4. エージェントを取り巻く環境の多様性

エージェントが行う活動は、実は複数の環境からの要請を受けている。エージェントは複数の環境からの要請をそれぞれ満たすこと自身の目的の一つとして活動しなければならない。例えば、警察官エージェントは、交通安全という環境からの要請によっ

て我々の交通安全のために取り締まりをしているわけであるが、一方では警察署という環境から交通違反の検挙ポイントをノルマとして要請されるので、彼らは交通安全とノルマ達成の二つの養成に対応するために、一方通行の入り口ではなく出口で取り締まることになるわけである。

このように、多目的かつ多様性を持つ、マルチクラスのエージェントが、多様な環境下に置かれているというごく一般的な社会を、分類子システムを用いてシミュレーションする方法を開発することが本研究の目的である。

3. 組織学習指向型分類子システムとその改良

本章では、これまで説明してきたような特徴を持つエージェントをシミュレーションするための方法について説明する。

3.1. 全体の構成

図1は、学習分類子システム (LCS: learning classifier system) [3]に組織学習の仕組みを組み入れた本システムのアーキテクチャを示す。エージェント全体に与えられた問題を各エージェントが個別に学習しているだけでは解けない場合でも、それぞれのエージェントが得た良いルールを互いに交換することで、解決することができるようになることを特徴とする。ベースとなる方法は、組織学習指向型分類子システム (OCS: Organizational-learning oriented Classifier System) [7]であり、本システムは、ここで取り扱いたいエージェントの特徴にあわ

せて [7] で提案されている OCS を改良したものである。

全体のアーキテクチャについて共通の部分は [7] に説明を譲り、以下に本システムにおける拡張部分や OCS との相違点について述べる。

3.2. 多目的問題への対応

まず、個体知識 (individual knowledge) 記憶メモリであるが、本システムが取り扱うエージェントが多目的問題を処理するという特徴から、個体が記憶する知識を表現する分類子 (classifier) の形式を変更した。ここでは、遺伝的アルゴリズムで多目的問題を取り扱う方法のひとつである、VEGA [6] を参考にし、これを分類子システムに応用して実現した。各分類子は、目的ごとに個別の適合度を保持する。各適合度は、後で述べるエージェントの評価方法によって、目的に対する結果の善し悪しを保持するものであり、これを繰り返すことで個体の学習を進めること。

エージェントは、エージェントが属するクラス毎に同一の活動と活動の目的を持っており、目的は環境からの要請であるとここではとらえる。VEGA を拡張した本システムでは、エージェントは以下の手順で行動を決定する。

1. ある活動を行うための n 個の目的から確率的にある一つの目的を選択する。
2. 次に分類子システムの受容器 (detector) に適合するルールを選択する。
3. さらにそのルールの中から一つのルールをその目的に対する適合度を基準にルーレット選択し

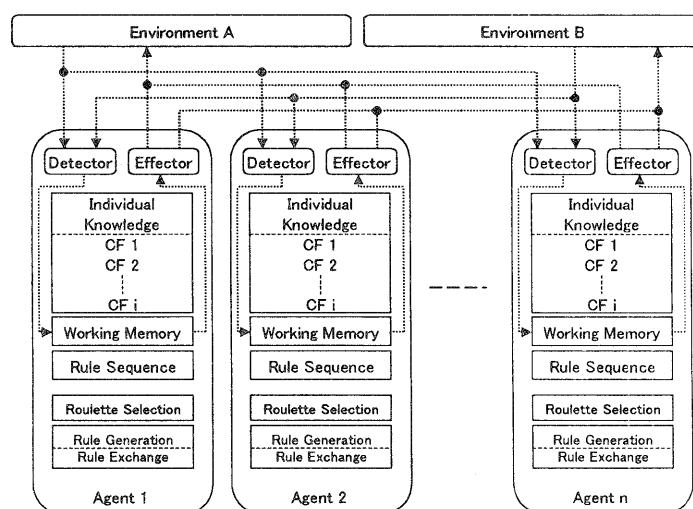


図1 全体のアーキテクチャ

で活動を決定する。

- 最後にこれを効果器 (effector) が実際の行動に変換する。

このシステムでは n 個の目的に対しそれぞれが選択される重みをエージェントごとに持つており、この重みに従って n 個の目的の中から確率的にひとつが選択されることとなる。この研究で取り扱うエージェントの特徴のひとつである、エージェントの多様性は、重みの個体間の相違によって表現される。

分類子は、遺伝的アルゴリズムにより世代学習が行われるが、このシステムでは以下の手順で世代学習を行う。

- エリート選択を行う。 n 個の目的に対して特に優れた分類子を、決められた数だけ優先的に残す。目的に対して残す割合は、エージェントの目的に対する重みに従う。
- 交差の対象となる分類子の選択を行う。まず、全分類子の中から 2 つの分類子をランダムに選択する。この 2 つの分類子をトーナメント選択によって選択する。やはり目的に対する重みによって、選択の基準となる目的別の適合度を決定し、この適合度が高い方を交差の対象となる分類子として選択する。
- その後、交差、次世代に残す分類子の選択、突然変異と、遺伝的アルゴリズムの一般的な方法によって世代学習を行う。

3.3. マルチクラスエージェントへの拡張

次に大きく異なるのは、マルチクラスエージェントへの拡張である。図 2 に示すとおり、複数のクラスのエージェントが環境を共有するが、エージェントのクラスごとに環境を認識し解釈する観点と、これを行動に結びつける活動目的や、実際の活動内容

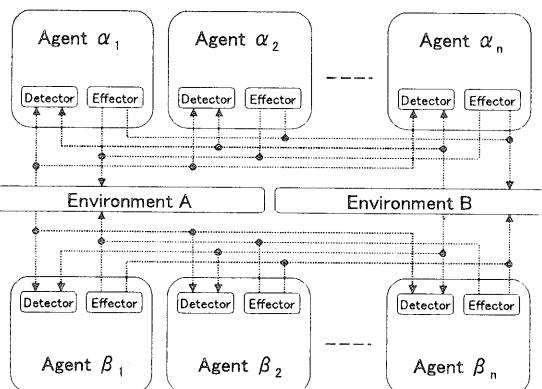


図 2 マルチクラスの対応

が異なっていることを表現するために、クラスごとに受容器と効果器の定義を行う。これによって、エージェント内部のアーキテクチャは同一のまま、マルチクラスエージェントについて OCS を拡張することができる。

3.4. 多様な環境への対応

次に、多様な環境と、その要請によってエージェントが持つ複数の目的に適応するための、エージェントの評価方法について述べる。

エージェントは、エージェントが属するクラス毎に同一の活動と活動の目的を持っており、目的は環境からの要請であるとここではとらえる。先ほど述べたとおり、エージェントはある活動を行うための n 個の目的から確率的にある一つの目的を選択し、分類子システムの受容器に適合するルールを選択し、そのルールの中から一つのルールを選んで活動を決定するが、その活動の結果を多様な環境にすべて反映させる。各エージェントは、自分の活動の目的に対して要請している環境の変化（すなわち、同一クラスの全エージェントの、目的に対する活動の結果）について、その結果の平均と自身の活動結果とを比較し、自身の評価を行うようとする。この方法だと、ある目的によって活動した結果をすべての環境に対して反映させるので、自身の目的とは異なる目的のために活動したエージェントの結果をも含んだ形で自身の活動を評価することになる。

しかし、多様性がある多目的なエージェントを前提とすると、かならずしも同じ目的によらない同一の活動をエージェント自身が評価することになるわけであるから、自身の活動目的を基準にして他者の活動を評価することは妥当であると考える¹。また、この方法で評価すると、全体の活動の平均が変化しても柔軟に評価可能となる²。これらのことは、環境に照らし合わせて評価するから可能であるのであって、エージェントが絶対的な評価を内包する仕組みであると、環境によらずに自分は最適な活動を行っていると評価することになってしまい、様々なエ

¹ 例えば、安全運転を目的としたエージェントが自身の運転を評価する場合には、早くたどり着くことを目的として運転しているエージェントは危険な運転をしているエージェントであると評価することになってしまってそれは差し支えないし、自分がどれだけ安全に運転できたかという評価は、すべてのエージェントの安全運転度と比較して評価することもいささかも不自然ではない。

² 例えば大阪では平均的な運転として評価されても、東京では乱暴だと評価されるということが可能となる。

ジェントによって環境がダイナミックに変化するときに、その変化に対応できなくなる。

またこのシステムでは、適合度を評価するための特定の適合度関数を持たない。これは、エージェントがマルチクラスであることに対応するためである。自分たちとは異なる活動を行う別のクラスのエージェントが環境を共有しているため、環境は自分たちの好まざる方向へどんどん変化していくこともあります。その中で自分たちが生き残るために現実的な戦略は、自分たちの活動として理想の状態を最適であると追い求めるよりは、与えられた環境に妥協し、自分たちの中で多少なりとも良い活動ができたエージェントを見習うことである。他のエージェントの活動と比較して自身の適合度を判定する方法は、この意味でも柔軟性が高い。

なおエージェントの活動の評価は、分類子の持つ n 種類の適合度の活動目的に対応した1つにのみ反映され、残りの $n-1$ 個の目的に対する適合度には反映しない。これも上記方針から明らかである。

3.5. 組織学習の方法

同一クラス内のエージェントの組織学習方法として、次の二つの方法を用意した。

3.5.1. 行動の模倣

自身の活動結果が著しく芳しくなかったときに、その行動をもたらした分類子が持つ行動部（分類子が持つif...then....ルールにおけるthen以降）に問題があったと考え、同一の条件時に良い結果を出した同一クラスの別のエージェントが活動に使用した分類子の行動部を、自身の当該分類子の行動部にコピーする。これによって、そのエージェントがまた同じ条件で動作するときに、前回と同じ過ちを繰り返さずに、良い行動をとることができるようになる。

良い結果をもたらした別のエージェントは、悪い結果を招いたエージェントとは別の目的で活動しているかもしれないし、エージェントの内部状態を受容器が内部表現に変換する対象に含んでいる場合などでは、コピーの対象となる両エージェントの分類子の内部状態が必ずしも同一ではないためにコピー対象の分類子間では条件部が同一でないことがあり得るが、これを単純に行動部だけ模倣することから「(規範なき) 行動の模倣」と呼ぶことにする。

3.5.2. 行動規範の模倣

エージェントクラス内の成功例を全エージェントが共有するものである。著しい成功を収めたエー

ジェントが、エージェントクラス共有の場所にその成功をもたらした分類子のセットを、活動の目的ごとに成功例として提供する。GAオペレーションの実行時に、それらの成功例をすべてのエージェントがエリート戦略としてそれらの分類子全体をそのまま受け入れる。これによって、「この条件下ではこの活動を行うと、目的を達成することができる」というルールを得ることができる。これを「行動規範の模倣」という。共有する分類子のセットは目的別に用意することができ、その場合にエリート戦略として受け入れる分類子セットの割合は、やはりエージェントごとの目的に対する重みに従う。

4. 環境マーケティングシミュレーション

環境マーケティングは、環境対応に積極的にコミットしていることを軸として消費者にアプローチする、近年一般的なマーケティング手法の一つである。

この環境マーケティングの構図をきわめて単純にモデル化し、これまで説明してきたアーキテクチャの有用性を確認するためのシミュレーションを行った。ここでのエージェントモデルは以下のようなものである。

- エージェントのクラス
「消費者」と「生産者」の2種類のクラス
- エージェントの環境
「経済活動」と「エコロジー」の2つの環境
- 生産者エージェントの目的
「お金を稼ぐ」と「エコロジーに配慮する」の2つの目的を持って商品を企画し、販売する
- 消費者エージェントの目的
「価格の安い商品を買う」と「エコロジーに配慮する」の2つの目的を持って商品を購入する

生産者の製造する商品の原価は、エコロジーに配慮すると非線形に高くなるという制約がある（図4）。この商品に対し、生産者は製造した商品の価格を自由に設定できる。

また、生産者と消費者は、内部変数として「所持金」と「エコロジー対応度」を持つ。これらはエージェントの活動によって以下のルールで変化する。
生産者クラスの場合：

「所持金」：商品の売り上げによって得られる。ただし商品は2個以上生産しなければならないため、売り上げが2個未満であると、売り残した製品の原価分を損失する。

「エコ対応度」：商品のエコロジー対応度を、売り上げた商品の個数分得られる。ただし売り上げが2個未満であると、売り残した商品は、ゴミを出したということペナルティが課せられる。

消費者クラスの場合：

「所持金」：活動時に市場に存在する商品の平均価格を受け取り、購入した商品の価格との差額を得る。

「エコ対応度」：購入した商品のエコロジー対応度を得る。

本シミュレーションでは、上記2つの内部変数の他に、前回の販売・購買活動の結果や、全エージェントの「所持金」「エコロジー対応度」の平均値などを、それぞれのエージェントクラスの分類子における条件部で変数として使用する。また、分類子の行動部は、生産者の場合は「生産する商品のエコロジー対応度」と「価格として原価に上乗せる割合」を、消費者の場合は「購入する商品の価格」と「購入する商品のエコロジー対応度」を行動部として持つ。分類子の長さ（ビット数）は、生産者が50bit、消費者が40bitである。分類子は、各エージェント内に5000個ずつ持った。

また、GAオペレーションの変数としては、GAオペレーションを行うステップ数を500、全体を初期値に戻すステップ数を2000、エリート選択の割合を0.2、交差の確率を1.0、突然変異率を0.001とした。

まず、クラス内組織学習の効果を測るために、消費者クラスの活動ルールを以下のものに設定した。

- 最初にランダムに商品を選び、この商品よりもエコロジーに配慮した商品で価格が1割以上高くなっているのがあれば、それを選択する
- 最初にランダムに商品を選び、この商品よりも1割以上安い商品があれば、それを選択する

前者のルールは消費者がエコロジーに配慮することを目的にして活動するとき、後者のルールは安く買うことを目的にして活動するときにそれぞれ選ばれる。また、それぞれのエージェントのエコロジーへの配慮の確率は0.5に固定とした（組織学習の効

果を純粋に測定するためにエージェントの多様性をなくして目的選択の確率を同一とした）。

この設定でシミュレーションを行うと、生産者クラス内の組織学習を行わない場合、商品の価格はほとんど原価まで下がってしまい、生産者は軒並み倒産する結果になる。そこで、「お金を稼ぐ」という生産者の目的に対してクラス内組織学習の仕組みを適用してみた。

行動の模倣は、生産者が倒産したときに、過去使用した5回のルールに対して、過去5回でそれぞれもとも売り上げが良かった製品の、生産者の分類子の行動部をコピーするものとして実現した。また行動規範の模倣は、上限までお金稼いだ生産者の過去5回のルールを生産者クラス共有の場所に保存しておく、GAオペレーション時に各エージェントがエリート戦略として受け入れるようにした（保存するルール数は40×5であり、自分が提供したルールは受け入れの対象から除外する）。

クラス内組織学習の効果は、図3,4のグラフに示す通りである。ここで「成功」は、所持金の上限を超えた回数が下限を下回った（倒産）回数の9倍以上ある場合（ただし上限を超えた回数が5回以上）、「失敗」は上限を超えた回数より倒産の回数の方が多い場合（ただし倒産回数が5回以上）と定義し、繰り返し回数2000回で評価した。

この結果を見ると、行動の模倣と行動規範の模倣を組み合わせることによって、「成功すること」と「失敗しないこと」の両方に対して良い結果を残すことができる事がわかる。

また、エージェントの活動結果の比較によって組織学習の効果を測定するほかに、エージェントの活動の結果が反映された環境の変化によって測定する方法も考えられる。図5,6に、生産者の活動の結果としての「エコロジー活動」と「経済活動」について、組織学習の効果を比較したグラフを示す。これらのグラフを見るとわかるように、エージェントの活動がフィードバックされた環境の状態も、両方の組織学習を取り入れた場合において良い結果が得られている。

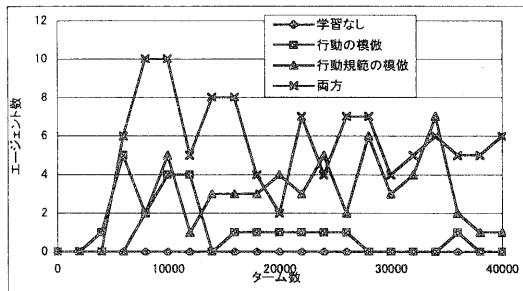


図 3 成功したエージェント

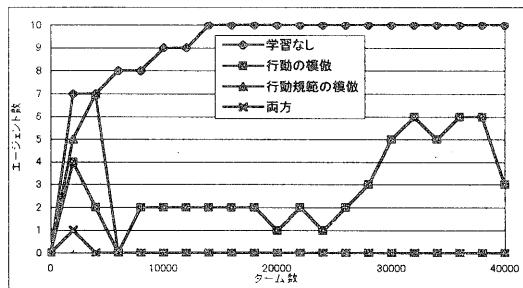


図 4 失敗したエージェント

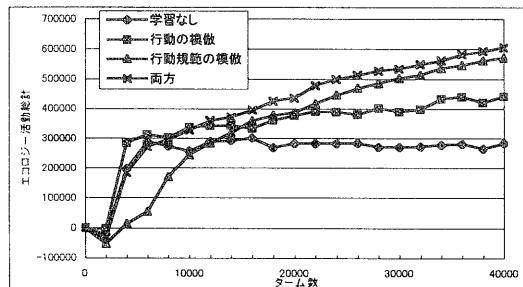


図 5 エコロジー活動の環境へのフィードバック

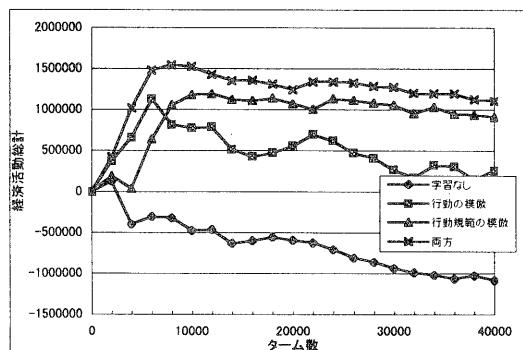


図 6 経済活動の環境へのフィードバック

5. 「行動への介入」による組織学習に関する考察

図 5, 6 からわかるとおり、生産者エージェントの環境に対するフィードバックは、エコロジーについては順調に値が増加するが、経済活動については値がどちらかというと下がる方向に推移している。これは、生産者が「お金を儲ける」ことを犠牲にして「エコロジーに配慮する」ことに傾注しすぎていると考えられ、多目的な生産者が両方の目的を達成するためのそれぞれの目的の選択比率が適当でないと考えられる。そこで次に、環境へのフィードバックの結果を利用して、生産者エージェントが多目的問題をよりよく解決する方法を検討してみた。

生産者エージェントの今回の環境へのフィードバックを、前回の環境へのフィードバックと比較した時に、一方が増加し他方が減少したときには、増加した側の目的に対する選択比率を少し下げる手法を考える。

この手法は、マルチクラスのエージェント間の組織学習手法としても有効であると考えられる。クラス間では、すでに述べた「模倣」による組織学習を適用することができない。「模倣」は、同一のクラス間でなければ、分類子の交換ができないからである。

しかし、クラス間で共有する環境へのフィードバックを、エージェントの目的選択比率を変化させる学習に利用することで、クラスを越えた組織学習が可能となる。たとえば先ほどの方法を生産者と消費者の関係でたとえるならば、儲けることに注力してエコロジー活動を省みない生産者に対し、消費者がエコロジーにより配慮することを消費者運動によって働きかけた結果、生産者がよりエコロジーに配慮する行動をとるという組織学習であると考えることができる。この手法を「行動への介入」と言う。この方法によってエージェントの多目的解を改善する結果を図 7 に示す。ここでの1回の重みの変化量は 0.05 とした。

これを見ると、エコロジーの結果については以前よりも劣るものの、両方の目的について結果を増加させていく方向で学習することができている。つまり、この方法により、多目的問題を解くための最適な選択比率を、リアルタイムに学習することができるようになっている。

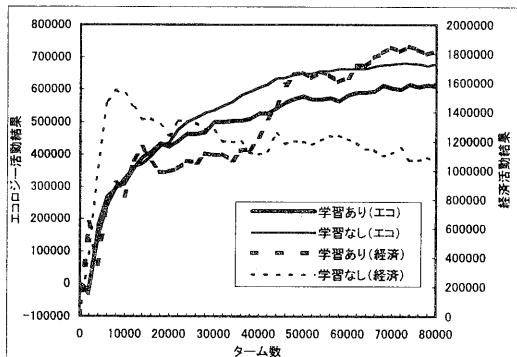


図 7 「行動への介入」による組織学習の結果

6. エージェントの共進化に関する考察

共進化とは、異種の生物が互いに作用を及ぼしながら共に進化することである [4]。本研究のフレームワークでは、エージェントクラス間での協調学習（エコロジーへの配慮という目的について互いに協力し利益を受ける）や、競争学習（お金を儲けたい生産者と安く買いたい消費者が、利害関係を持つ）に相当し、これらの学習はエージェントの行動の環境へのフィードバックと、新しい環境への適応によって基本的に獲得されるものである。

しかし、消費者エージェントも分類子システムで実装しクラス内組織学習を入れてシミュレーションを行うと、この場合も生産者は軒並み倒産してしまい、消費者が競争学習に一方的に勝利してしまう。実社会では、このような結果になると製品の生産が行われなくなり、最終的には消費者にも悪影響が及ぶため、生産者が倒産しない程度の儲けに対しては消費者も協調する余地があるはずである。

「行動への介入」による組織学習は、このエージェントの共進化を進めるために利用可能である。「行動への介入」の学習を共進化のための組織学習に拡張するために、生産者が「儲け」と「エコロジー」の両方で前回より悪い結果を得、かつ消費者が「安く買う」ことで前回より良い結果を得た場合、生産者が消費者に対してエコロジー活動の重みを上げるように介入するものとした。その上で、生産者・消費者の双方を分類子システムによるエージェントで実装し、目的の重みを 0.5、エージェントの多様性を ±0.2 とし、これまで述べた組織学習の方法をすべて取り入れて環境マーケティングシミュレーションを行った結果、生産される商品が、高い環境対応をしつつ安い価格の商品へと収束し、なおかつ生産者も

破産せず利益を出しながら活動できるという結果が得られた。

おわりに

本稿では、現実社会で一般的な、複数の環境から行動について要請を受ける、多様性のある、多目的・マルチクラスエージェントを分類子システムでモデル化し、シミュレーションするための方法の開発と、その組織学習の手法について提案し、その有効性を検証した。その結果、同一クラス間で分類子を交換する「行動の模倣」および「行動規範の模倣」による組織学習と、クラス間で共有する環境へのフィードバックを利用した「行動への介入」による組織学習は、分類子システムによって実装されたエージェントの多目的な活動をより良い結果に導くことを示すことができた。また「行動への介入」がエージェントクラス間の共進化に利用できる可能性についても示すことができた。

今後の課題としては、エージェントの多様性が本モデルのシミュレーションに与える影響や、多様性を利用した新たな組織学習の枠組みについての検討があげられる。

参考文献

- [1] Argyris, C., D. A. Schon: *Organizational Learning*, Addison-Wesley, 1978.
- [2] Duncan, R., A. Weiss: *Organizational Learning: Implications for organizational design*, in Staw, B. M. (Ed.), *Research in organizational behavior*, Vol. 1, JAI Press, 1979, pp.75–123.
- [3] Goldberg, D.E.: *Genetic Algorithms in Search, Optimization, and Machine Learning*, Addison-Wesley, 1989.
- [4] 伊庭斉志：進化論的計算の方法，東京大学出版会，1999。
- [5] Kim, D.: "The Link between individual and organizational learning", *Sloan Management Review*, Fall, 1993, pp. 37–50.
- [6] Schaffer, J.D.: Multiple Objective Optimization with Vector Evaluated Genetic Algorithms. *Proceedings of the First International Conference on Genetic Algorithms and Their Applications*, Lawrence Erlbaum Associates, Inc., Publishers, 1985, pp.93–100.
- [7] 高玉圭樹, 他 : マルチエージェント学習における知識の再利用と電気回路設計への応用. コンピュータソフトウェア, Vol.16, No.5 (1999), pp.37–49.
- [8] 寺野隆雄, 他 : 分類子システムに基づくエージェントの組織学習モデル, 経営情報学会 1997 年秋期全国発表大会 (1997), pp.128–131.
- [9] 寺野隆雄 : 社会科学を実験化学に: エージェントで社会をみる, 1999 年度人工知能学会全国大会(第 13 回) (1999), pp. 34–39.