

問題の複雑性に着目した知識伝搬モデルへの影響分析 中川 裕司[†] 山田 隆志[‡] 寺野 隆雄[‡] 吉川 厚[‡]

† ‡ 東京工業大学大学院 〒226-8502 横浜市緑区長津田町 4259

E-mail: † y-nakagawa@trn.dis.titech.ac.jp, ‡ {tyamada,terano, at_sushi_bar}@dis.titech.ac.jp

あらまし 組織における知識の流れを分析・解析することは非常に難しい。そのため、知識の単純な内容分析以上の解析方法が望まれている。本研究では、組織における知識伝搬を表現する方法として、ナレッジマネジメントにおける個人化戦略に着目してコンピュータ上でその知識の流れを表現するものである。

キーワード 個人化戦略、学習分類子システム、迷路問題、知識伝搬、

Modeling Organizational Learning of a Community through Learning Classifier System

Yuji NAKAGAWA[†] Takashi YAMADA[‡] Takao TERANO[‡] and Atsushi YOSHIKAWA[‡]

† Tokyo Institute of Technology 4259 Nagatsuta-cho, Midori-ku, Yokohama, 226-8502

E-mail: † y-nakagawa@trn.dis.titech.ac.jp, ‡ {tyamada,terano, at_sushi_bar}@dis.titech.ac.jp

Abstract It is hard to extract and analyze knowledge flows for organization management. This paper proposes a multi-agent simulation model to analyze the dynamic knowledge flows. In this model I try to replicate the mechanism of knowledge flows focusing on personalization Strategy.

Keyword Personalization Strategy, Learning Classifier System, Maze Problem, Knowledge Flow

1.はじめに

1.1. 背景

情報技術の発達により、私たちの周りには膨大な情報があふれている。適切な意思決定を行う上で、無秩序かつ無造作なこれらの情報は役に立つどころか重要な情報を隠してしまう場合がある。さらに、企業はめまぐるしく変化する環境に対応するだけではなく、独自性を出すことが求められている。そのためには、社員一人一人が自発的に集まり互いに知識や経験を共有する必要が出てくる。これにより、膨大な情報の取扱選択や、他人の考え方を自分の考えに取り入れることで新たな考えを生み出すことが容易になる。

知識を共有させるナレッジマネジメントの方法として大きく分けるとコード化戦略と個人化戦略が存在する[1]。コード化戦略とは、各々が持つ知識をコード化（書式化）することで形式知に変換して知識を共有する方法である。個人化戦略は暗黙知をそのまま暗黙知として他人と知識を供する方法である。

特に個人化戦略では誰と知識交換を行うことで有用な知識が獲得可能なのかがわからないといった問題

がある。この問題を解決するためには、知識共有の相手をハンドリングして有用な知識交換相手を見つけやすくする必要がある。

組織をハンドリングする手法としてはこれまで、実際に起こった事例を分析する事例研究や、概念モデルを用いた研究などがなされてきた。しかし、事例研究では過去の出来事について分析することができず、未知状態で何が起きたのか分析しにくいことや、概念モデルでは、抽象的すぎるため現実のどの場面で適用可能なのかわからないという問題点もある。そこで、組織をハンドリング方法の検討手法としてシミュレーション技法が注目されている[2]。また、ハンドリング手法を検討するために実在の組織を用いるのは、費用・時間がかかるということや、同じ状態の組織が存在しないため比較することが難しい等が予想されるがシミュレーション技法を用いることでこれらの問題を解決することができる。

シミュレーション技法では重要な要素を抜き出し、要素の相互作用により現象を表現可能なモデルを構築し、その上で抜き出された要素を変化させる。これに

よりハンドリング手法を試すことが可能となる。そのため現実で利用する前にどのようなことが起こるのかを検証することが可能となるものである。

1.2. 目的

本研究ではシミュレーション技法を用いて、個人化戦略による知識共有のモデルを構築する。

これを用いることで、知識共有が与える影響の分析や、ハンドリング手法をシミュレーション内でどの様な影響が起こるのかを分析することで、実際の組織に適用する前の検証に役立てることができることが期待される。

1.3. 先行研究

組織における知識を表現したシミュレーションとして、データベースなどの知識共有システムの効果を分析した研究[3]や、2007年問題における知識の流出問題を取り扱ったモデル[4]、組織行動を分析するモデル[5]などがある。特に、組織行動を分析するモデルでは、実際に社員が強化学習を用いて学習していく中で組織行動の振る舞いを表現したものであるが、本研究で主題としている、本研究の主題である知識交換は表現されていない。本研究では、知識交換が学習効率に与える影響を分析するために各々が学習し、学習して得た知識を交換するモデルを組む必要がある。これは、知識交換の現象だけを表現したのでは、学習効率向上のための交換が行われたことを示すことや、知識交換の相手の選択基準を設けることが難しくなるためである。

組織における各々が行う学習と知識交換による学習をモデル化した研究としては、組織論における組織学習をモデル化した組織学習指向型分類子システム(organized-learning oriented Classifier System:OCS)[6]が提案されている。このモデルでは、学習者がそれぞれ適応度付き学習分類子システム(eXtended learning Classifier System:XCS)[7]を用いて学習し、学習して得た知識を交換することで、分業や学習効率の向上を実現している。しかし、このモデルでは知識交換する相手が無作為に選択されるため、有用な知識交換相手の選択基準が設けられていない。

2. モデルの構造

本モデルでは、エージェント・ベース・シミュレーション(Agent-Based Simulation)を用いて、個別学習と知識交換を表現し、知識交換の相手を選択する中で、各エージェントが主体的に有用な知識交換相手を選択することができるようなモデルを構築する。

エージェントは、事前に用意された複数あるタスクのうちの一つが短時間で処理できるように、学習する。また、学習効率を高めるために各々のエージェントが学習した結果得られた知識を交換するモデルである。

本研究における有用な知識交換の相手とは、同じタスクを与えられたエージェントとする。これは、学習分類子システムにおいて、同じタスクを与えられたエージェントが知識交換を行うことで学習効率の向上が示されているため[8]、学習効率を高める知識交換が予想されるためである。

以下では、本モデルにおいて各エージェントが持つ学習モデルの XCS について、ルールの選択と実行、ルールの強化、ルールの更新について図 1 を用いて説明した後、知識共有の方法について説明する。

2.1. 学習分類子

環境からの入力である状態(State)に対して適切な行動(Action)を実行することで得られる報酬(Reward)の合計を最大化するように学習を行う。

分類子システムでは、分類子群という分類子の集合が存在する。各分類子は条件部、行動部、重複度(num)、予測報酬(p)、予測報酬誤差(ϵ)、適応度(F)から成り立っており、一つの分類子を一つの知識として扱うこととする。

条件部は 0 か 1、もしくは#(ワイルドカード)を与える。このうちワイルドカードは汎化のための構成要素であり、どんな値でもよいことを示している。また、ワイルドカードは、各分類子の生成時に条件部の各ビットに P_i の確率で挿入される。

行動部は整数値をとり、その値を Effector に渡すことで環境に対して Action を取ることができる。

重複度とは、分類子の集約具合を示し、複数の分類子において、一方が他方に対して集約される場合に

一つの分類子とすることである。

予測報酬は小数値をとり、現時点から（条件部に一致した状態）からアクションを起こした結果に得られる報酬の予測の報酬である。

予測報酬誤差は、予測報酬にどの程度の誤差を含んでいるかという指標である。

適応度とは、その分類子がどの程度信用できるかを示している。たとえば、ゴール直前で選ばれる分類子は予測報酬が非常に大きくなりやすいため、他の状態でも条件が一致した場合は選ばれやすくなってしまうが、適応度を用いることでこういった問題を解消している。

2.2. ルールの選択と実行

環境から状態が入力されると、全ての分類子に対して条件部と状態の照合がなされる。合致する条件部が存在する分類子で照合集合（Match Set）を形成する。もし、条件に適合する分類子が存在しない場合は、入力された状態に一致する条件部をもった分類子を新たに生成する（Covering）。

照合集合内の分類子行動部には複数の行動が含むことがある。この中から一つの分類子を選択するために、すべての分類子を行動部が同一なものでまとめ、予測報酬を連ねた予測配列（Prediction Array）を作成する。予測配列における各行動 a_i の予測報酬 P_i は式(1)のように計算される。

$$P(a_i) = \frac{\sum_{cl_k \in [M]|a_i} p_k \times F_k}{\sum_{cl_k \in [M]|a_i} F_k} \quad (1)$$

ここで、 $[M]|a_i$ は照合集合内の行動部に行動 a_i を持つ分類子の集合を表す。この予測配列に基づいて行動選択が行われる。本研究では、予測配列の値を用いてルーレット選択を用いた。さらに、選ばれた行動を行動部に持つ分類子によって行動集合 $[A]$ が形成される。さらに、選択された行動が実行されることによって、行動部の一連のステップが終了する。

2.3. ルールの強化

各ステップにおける実行部の処理が完了した後、最後の行動の行動価値 (P) を求め、行動集合 $[A]$ に含まれる分類子で予測報酬、予測報酬誤差、適応度を環境

から得られる報酬に基づいて更新する。更新時は学習率 β ($0 < \beta < 1$) で更新する。

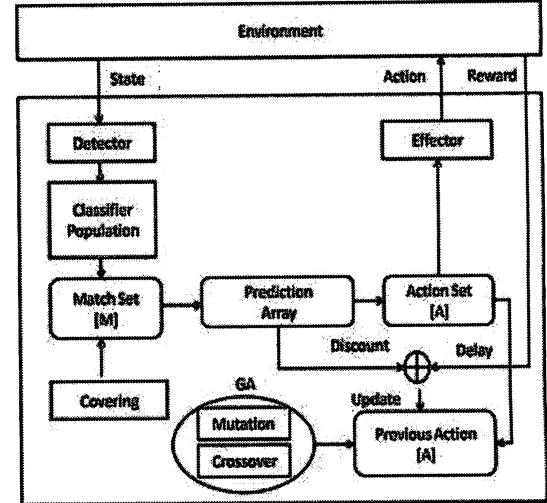


図 1 モデルの流れ

行動価値 P は、報酬 r と行動後の状態における $P(a)$ の最大値を割引率 γ ($0 < \gamma < 1$) で割り引いた値の和であり。式(2-4)により更新される。

$$P \leftarrow r + \gamma \max_a P(a) \quad (2)$$

$$p_i \leftarrow p_i + \beta (P - p_i) \quad (3)$$

$$\varepsilon_i \leftarrow \varepsilon_i + \beta (|P - p_i| - \varepsilon_i) \quad (4)$$

さらに、分類子の予測誤差である ε を用いることで分類子の適応度が更新される。式(5-7)

$$\kappa_i = \begin{cases} 1 & \text{if } \varepsilon_i \leq \varepsilon_1 \\ \alpha (\varepsilon_1 / \varepsilon_i)^{-\nu} & \text{otherwise} \end{cases} \quad (5)$$

$$\kappa'_i = \frac{\kappa_i \times \text{num}_i}{\sum_{cl_k \in [A]} (\kappa_k \times \text{num}_k)} \quad (6)$$

$$F_i \leftarrow F_i + \beta (\kappa' - F_i) \quad (7)$$

2.4. ルールの更新 (GA)

遺伝的アルゴリズム (GA) を用いて新しい分類子の生成、および既存の分類子の精錬を行う。今回は行動集合 $[A]$ 内の分類子の生成されてからのステップ数を用いて、生成されてからのステップ数の平均が閾値を超えた場合 GA を行う。

遺伝的アルゴリズムでは、適応度の大きさを相対

的な選択確率として 2 つの親個体が選ばれ、交叉と突然変異がそれぞれ特定の確率で行われる。さらに、ここで生成された子個体は分類子に追加される。このとき、分類子の量があらかじめ定められた最大値より超えていた場合は、適応度に応じて削除される。これにより、条件に一致する一般化の適切な範囲を探索する。

2.5. 知識共有

提案するシミュレーションモデルではエージェント間で知識の共有を行う。本モデルにおける知識共有とは、自ら持つ知識を他のエージェントに与えることで、自分と同じ知識を他のエージェントにも持たせることを指す。つまり、知識共有は 1 対 1 で行われ、知識を与える側の知識は変化しない。与える際に注意すべき点は、与える相手の選択方法、与える知識の選択方法、与え方が重要になるため、以下ではその 3 点について説明する。

まず、知識を与える相手の選択方法としては、現在保持している知識のうち 1% 以上過去与えられたことのあるエージェントを知識提供の候補として、候補の中からルーレット選択を用いて相手を決定する。

次に、与える知識は提供側のエージェントの中からトーナメント選択を用いて 10 個の知識のうち最も適応度の高いものを選択する。このとき与える量は、提供側が保持している知識の 1% とした。

最後に、知識の提供の仕方は本モデルにおいて、知識を提供される側のエージェントが提供する側のエージェントと同じタスクを与えられているとは限らないため、その分類子を利用するまでその分類子が有益かどうかわからない仕組みとなっている。そのため、提供された知識は、適応度を除いたすべての値がそのまま相手のエージェントに与えられ、適応度は与える側のエージェントの半分とした。これは、他人から与えられる知識が正しいとは限らないため、与えられた知識が unnecessary に多く利用されてしまうことを防ぐためである。

3. 実験

本実験では、提案モデルにおいて行われている知識交換により知識交換の相手に選ばれるエージェント

が与える側のエージェントと同じタスクであることを確認するためのものである。つまり、同じタスクを与えられたエージェント同士での知識交換が、異なるタスクを与えられたエージェント同士での知識交換より活発に行われていることを比較する。さらに、提案モデルが各エージェントの学習に効果的に働いていることを示す。

そこで、各エージェント同士の知識交換回数を用いてグループ化率を定義し、このグループ化率の推移を分析する。また、学習効率が高まっていることを示すために、タスクに要した時間の累積の推移を用いて分析する。

タスク T_i において、エージェント同士が知識交換した回数を E_{Ti} とすると、同じタスクのエージェント同士の平均交換回数 Aes_{Ti} と異なるタスクのエージェント同士の平均交換回数は Aed_{Ti} となり、式 8, 9 に示される通りとなる。そして、 T_i におけるグループ化率 Pg_{Ti} は、式 10 となり、全てのタスクにおけるグループ化率 Pg は、これらの平均となる。この値が 0.5(50%) を超えている場合は、同じタスクのエージェント同士の結びつきが強いことを示し、0.5 を下回る場合は異なるタスクを与えられたエージェント同士が結びついでいることを示す。

$$Aes_{Ti} = \frac{\sum E_{Tj}}{n(Aj)} \quad (T_i = T_j) \quad (8)$$

$$Aed_{Ti} = \frac{\sum E_{Tj}}{n(Aj)} \quad (T_i \neq T_j) \quad (9)$$

$$Pg_{Ti} = \frac{Aes_{Ti}}{Aes_{Ti} + Aed_{Ti}} \quad (T_i = T_j) \quad (10)$$

また、学習効率の性能を見るために、X 軸に実験回数 Y 軸に累積ステップ数として Y の値が低い方が少ないステップ数でゴールにたどり着くことができるため、高い学習効率を持つことを示すことができる。このとき、実験環境に複数のタスクが発生するため、迷路ごとの特性が出ないように、同じ数だけのタスクを知識交換なしで学習した場合と比較した。つまり、タスク数、タスクの種類ともに同じかつ、知識交換を行っていない個別学習のみの結果を比較対象とした。

4. 実験結果と考察

4.1. グループ化率

まず、各実験におけるグループ化率を見る図2を見ると、全ての実験において、学習開始時はグループ化率が上がり、その後は緩やかに下がって行くという結果となった。また、グループ化率の最も高い時期は学習曲線を見ると学習が収束した時と同時のおよそ(50実験前後)あることが分かる。これは、初期では、同じタスクのエージェントにより与えられた知識はそのままでも使えることが多いため、役に立つ知識として残っていることが多いため上昇することが考えられる。その後、学習が収束してしまうと遺伝的アルゴリズムの影響でそれらの知識が精錬され他の知識となってしまうことや、他者から与えられる知識が自分で現在保持している知識より勝るものでなくなってくるために、グループ化率が下がっていると考えられる。つまり、全てのエージェントが学習し終わってしまったために互いの知識交換が有用なものでなくなってきたため、グループ化率が下がったと考えられる。

4.2. 学習効率

ほとんどすべての場合において、学習効率は知識交換を行った場合の方が良くなっている。しかし、迷路の種類が増えるにつれて、だんだん学習効率が落ちてきていることがわかる。エージェント数を10で固定しているため、タスクの種類が増えるたびに有用な知識交換が行える相手は、減っていくことが原因として考えられる。特に、エージェント数とタスクの種類が同じ場合(つまり全員が異なるタスクを与えられた場合)は知識交換を行った場合は学習効率が落ちていることがわかる。これは、特に初期において不必要な知識が多数流れ込んできてしまうことが原因として挙げられる。さらに、他の場合は有用な知識交換の相手がいるため、そのエージェントとのやり取りに集中することで不要な知識の交換を行わなくて済むのにもかかわらず、全てのエージェントが異なるタスクを与えられている場合は、異なる知識のエージェント同士で知識交換をするしかないことがこのことに拍車をかけていると考えられる。また、タスクが5種類である場合(つまり各タスクに対してエージェントは2名ずつ)

でも、若干の学習効率の低下がみられることから、本モデルの場合ではある程度以上の同じタスクを与えていている相手がないと、高い学習効率は得られないということがわかった。

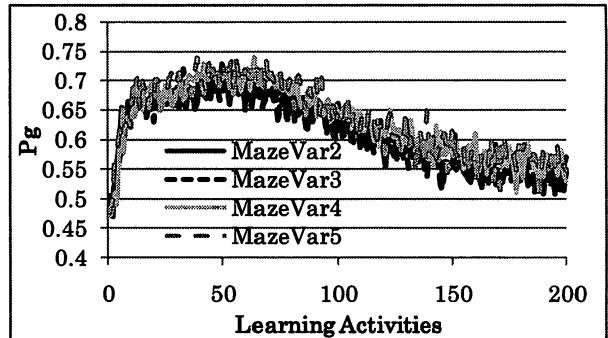


図 2 Probability of Grouping

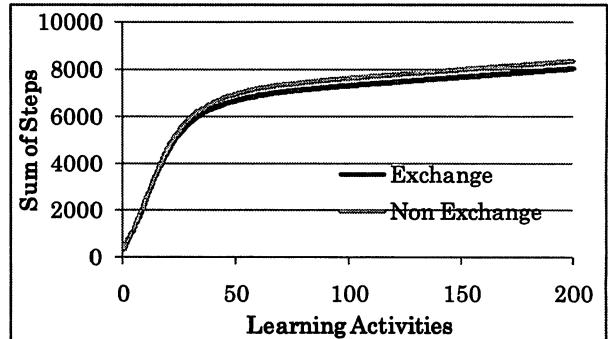


図 3 Learning curve(Maze value 2)

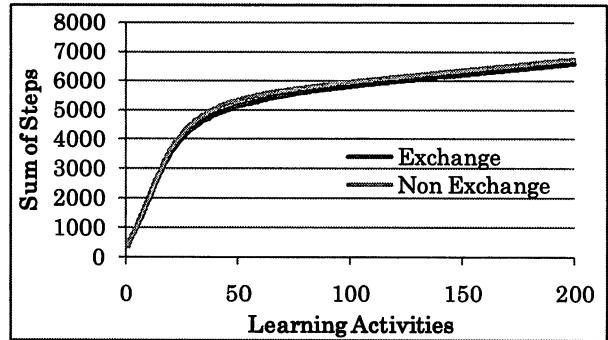


図 4 Learning curve(Maze value 3)

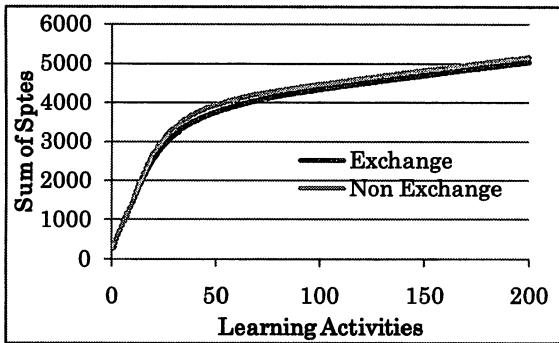


図 5 Learning curve(Maze value 4)

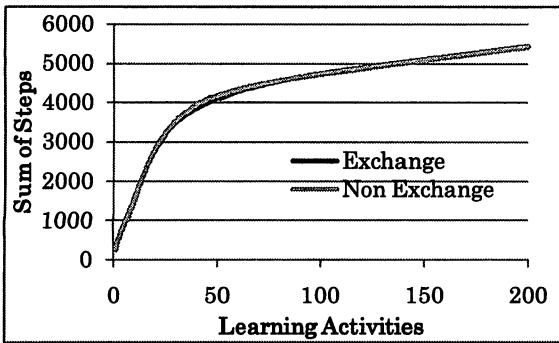


図 6 Learning curve(Maze value 5)

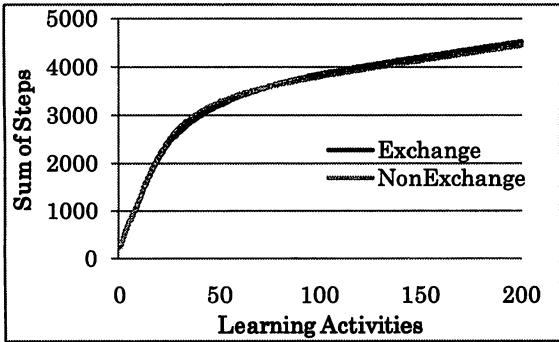


図 7 Learning curve(Maze value 10)

5.まとめ

本モデルによる知識交換により、知識交換による学習効率の向上と、グループ化率の定義から分かるように、知識交換相手に各々のエージェントが同じタスクを与えられたエージェント（有用な知識交換の相手）を選択することができていることを示すことができた。その中で、学習が終息してしまった後にグループ化率が下がっていくことが示された。これは、有用ではない相手とわかれれば離れていくことを示しているため、動的にタスクが変化する問題にも対応可能であること

が予想される。そして、グループ化率についてはエージェント数対タスク種類の比にはば関係なく曲線を描いていることも示すことができた。

6.今後の課題

本研究における知識交換は1対1であったため、わざわざグループ化率を定義して知識交換相手のまとまり具合を示したが、この指標を用いることでエージェントにグループを形成させ、知識交換もその多対多で表現させたい。また、グループ化率の結果から分かるように、与えるタスクを一定期間ごとに変更させていくことで長期的に高いグループ化率の維持が可能になることが予想されるので、これについても検証してみたい。それによって、変化する環境というものが表現可能になると同時に、知識交換の割合をリンクの強さとした極大クリークが出現することが予想される。

文献

- [1] Hansen, M. T., Nohria, N., Tirney, T., What's Your Strategy for Managing Knowledge, Harvard Business Review, March-April, pp106-117, 1999.
- [2] 幡瀬博, ナレッジマネジメントのためのシミュレーション活用の可能性, ナレッジマネジメント研究年報 No. 2 p. 51-74, 2000.
- [3] 藤田幸久, 仲瀬明彦, 中山康子, 烏海不二夫, 石井健一郎, 組織における知識継承のモデル化, 情報処理学会研究報告, Vol. 2006, No. 2 (20060112) pp. 77-82, 2006.
- [4] 鈴木克広, エージェント・ベース・シミュレーションによる製造現場における知識伝達と管理のモデル, 計測自動制御学会システム・情報部門学術講演会 2006 講演論文集, pp. 309-312, 2006.
- [5] 見城幸直, エージェントシミュレーションによる企業の定型業務の分析, 計測自動制御学会システム・情報部門学術講演会 2006 講演論文集, pp. 313-318, 2006.
- [6] 高玉圭樹, 組織学習エージェントによるプリント基板設計問題への接近, 電子情報通信学会論文誌, Vol. J81-D-1, No. 5, 201/204, (1997).
- [7] Wilson, S.: Classifier Fitness Based on Accuracy, Evolutionary Computation, Vol. 3, No. 2, pp. 148-175, 1995.
- [8] 中川裕司, 山田隆志, 寺野隆雄, 吉川厚, 学習分類子システムを用いた知識伝播モデル, 第51回自動制御連合講演会, pp. 826-831, 2008.