

# 遺伝的進化・個体学習・社会学習が相互作用する 進化的計算が持つ問題解決特性

藁科 克英 橋本 敬

北陸先端科学技術大学院大学 知識科学研究科

**概要:** 進化と学習の相互作用、特に遺伝的進化・個体学習・社会学習の3者の相互作用に注目したマルチエージェントシステムを開発し、NK 適応度地形上でその特性を研究する。本論では、学習のコスト、エピスタシスの程度、環境の動的性を変化させ、各要素が個体集団に与える影響や学習回数の遷移を調べた。その結果、社会学習が有効になる条件として、10 倍以上の個体学習コストと社会学習コストの差異、教えることがベネフィットとなる、低エピスタシス環境、動的環境が考えられる。

## Problem-Solving Characteristics of Evolutionary Computation Using Interaction among Genetic Evolution, Individual Learning and Social Learning

Katsuhide Warashina Takashi Hashimoto

School of Knowledge Science, Japan Advanced Institute of Science and Technology

**Abstract:** In this paper, we study the interaction between evolution and learning, especially focusing on that among genetic evolution, individual learning and social learning. We investigated the characteristics of the interaction by constructing a simple multi-agent system with the NK fitness landscape, both under static and dynamic environments. In the result of the computer simulations, we found the conditions for effective social learning: the cost of social learning is lighter about 10 times than the cost of individual learning, beneficial teaching action, low epistasis and dynamic environment.

### 1. はじめに

実世界のように開放性や動的性などの複雑さを有する環境下では、環境全体の完璧な挙動予測は不可能である。そのため、あらかじめ全ての環境条件と最適行動を列挙した完全なクラシファイアシステムを構築する事は現実的ではない。一方、実世界の生物や生物集団といったシステムは常に最適ではないものの、こうした実世界の環境変動に適応可能な生物種も多い。そのため、それら実世界のシステムを模した適応手法が研究されてきた。代表的な例として、遺伝的進化を模した遺伝的アルゴリズム、脳の処理を模したニューラルネットなどが挙げられる。

高等生物において進化と学習の相互作用が適応性を高めているという事実から、近年、進化と学習の相互作用に注目した適応手法が研究されている(Hinton and Norlan, 1987; Mayley, 1996; Best, 1999; 鈴木・有田, 2004)。本研究が注目するのもそうした進化と学習の相互作用に注目した適応手法である。

学習は大きく個体学習と社会学習に分けられる。前者は、運動による筋肉の増強や試行錯誤などの単体で行われる出生後の変化である。後者は、知

識の伝達や蓄積、模倣など個体間の伝達である。前者の個体学習は広範の生物に見受けられるが、後者の社会学習はその特性上、社会性をもつ一部の生物種にしか見られない。その代表例は、類人猿やヒトである。

その一部の生物群が社会学習を採用した理由はなんなのだろうか？本研究ではその理由を社会学習の適応アルゴリズムとしての問題解決特性にあると考え、遺伝的進化、個体学習、社会学習の3要素の相互作用を取り入れたマルチエージェントシステムによる実験を行った。

本実験では環境モデルとしてNK 適応度地形モデル(Kauffman, 1993)を使用した。このモデルはもともと遺伝子座間の相互作用を取り入れた適応度地形であるが、NK 適応度に単純化できる組み合わせ最適化問題は多分野において考えられる。実際、NK 適応度地形モデルの NP 完全性が証明されている(Wright et al., 2000)。このような特徴から、遺伝的進化、個体学習、社会学習の3つの適応的变化が相互作用する適応的計算アルゴリズムの特性を調べるための環境として、NK 適応度地形モデルを採用した。本論では、適応度地形が変化しない静

的環境と、時間的に変動する動的環境の2種類で特性を調査する。

## 2. モデル

エピスタシス  $K$  を持つ NK 適応度地形上で、遺伝的進化、個体学習、社会学習を行う個体群を以下のようにモデル化する。

### 2.1 エージェントの遺伝子構造

各エージェントは遺伝子構造として、遺伝子型  $G$  (長さ  $N$  のビット列)、個体学習限界回数  $IL_{MAX}$ 、社会学習因子  $SLFactor$  を持つ。個体学習と社会学習の最高回数、および、その合計値はそれぞれ  $IL_{MAX}$ 、 $SL_{MAX}$ 、 $L_{MAX}$  で制限される。 $L_{MAX}$  は全個体共通のパラメータである。各個体は、社会学習において教師か生徒になるか、あるいは、どちらにもならないかが遺伝的に決まっている。それぞれ  $SLFactor=\{t,s,i\}$  で表される。

### 2.2 初期集団生成

初期集団を次の手順で生成する。まず、全エージェント同一の遺伝子型をランダムに生成する。そして、各エージェントの遺伝子型をビットあたり  $1/N$  の確率で反転させる。個体学習限界回数は  $0 \sim L_{MAX}$  の一様乱数、社会学習因子は  $\{t,s,i\}$  から一様乱数で決定する。

### 2.3 個体学習

個体学習は以下の手順で行われる。

0. エージェントの遺伝子型  $G$  を表現型ビット列  $P$  にコピーし、個人学習カウンタ  $IL$  を 0 にする。

1. どのビットを反転させても  $P$  の NK 適応度  $F_{NK}(P)$  が上昇しない場合は 4 の操作に移行する。そうでない場合は、 $P$  のランダムな 1 ビットを反転させたビット列  $P'$  を作成する。

3.  $IL < IL_{MAX}$ 、かつ、 $F_{NK}(P') > F_{NK}(P)$  であれば、 $P'$  を  $P$  にコピーし、 $IL$  を 1 増やし、1 の操作に移行する。そうでなければ 4 へ。

4. 個体学習を終了させ、エージェントの個体学習後適応度を  $F_{indi}=F_{NK}(P)$  とする。

### 2.4 社会学習

エージェント集団が個体学習の結果を元に表現型の伝達を行う。

1. 教師因子  $SLFactor=t$  を持つ教師エージェントのみを用いて、 $F_{indi}$  に基づいた教師ランキングを作成する。全教師エージェントの教授カウンタ  $TL$  を 0 に初期化する。

2. 生徒因子  $SLFactor=s$  を持つ生徒エージェントが、教師ランキングに基づくランク選択で教師エージェントを 1 体選択し、その  $F_{indi}$  が生徒自身

の  $F_{indi}$  よりも高いならば、教師として採用する。

3. まず、社会学習カウンタ  $SL$  を 0 に初期化する。生徒エージェントは、自分の表現型  $P$  のうち教師エージェントの表現型  $P_T$  と異なるビットを順に反転し、 $SL$  を 1 ずつ増やしていく。また、教師エージェントは  $TL$  を 1 ずつ増やす。 $SL=SL_{MAX}$  となるか、 $P=P_T$  になった時点で社会学習を終了する。社会学習終了後のエージェントの表現型  $P$  の適応度を教育後適応度  $F_{tought}$  とおく。

### 2.5 適応度

各エージェントの生涯適応度  $F_{lifetime}$  は次式で計算される。

$$F_{lifetime}=F_b \cdot C_{lifetime}$$

$$F_b=F_{indi} \quad \text{if } SLFactor=t \text{ or } i,$$

$$F_{tought} \quad \text{if } SLFactor=s$$

$$C_{lifetime}=C_{indi} \cdot IL + C_{student} \cdot SL + C_{teacher} \cdot TL$$

ここで、 $C_{indi}$ 、 $C_{student}$ 、 $C_{teacher}$  はそれぞれ、個体学習、社会学習、教師のコストで、全個体共通のパラメータである。

### 2.6 次世代作成

交叉と突然変異を経て、現世代エージェントと同数の次世代エージェントを生成する。

まず、 $F_{lifetime}$  を用いたランク選択で両親エージェントを選び出す。両親の遺伝子型を一点交叉させ、片方を次世代エージェントの遺伝子型とする。片親の個体学習限界回数と社会学習因子を次世代エージェントに引き継ぐ。

突然変異は、遺伝子型各ビットの反転、 $SLFactor$  の変化、 $IL_{MAX}$  の増減を、突然変異率  $\mu$  の確率で起こす。 $SLFactor$  は一様乱数で  $\{t,s,i\}$  から選ぶため結果的に変化しない場合もある。また、 $IL_{MAX}$  を増減させた結果、上限 ( $L_{MAX}$ ) か下限 (0) を越える場合には増減操作はキャンセルされる。

## 3. 実験結果と考察

NK 適応度地形を最初に決定したもので固定する静的環境での実験、および、適応度地形が時間的に変動する動的環境での実験を行う。本論では、社会学習がどういう条件で存在しえるか、あるいは、個体学習に対して優位になるかという観点から調べる。

実験では次のパラメータ値を用いる。エージェント数  $Num=100$ 、遺伝子長  $N=20$ 、突然変異率  $\mu=0.02$ 、社会学習コスト  $C_{student}=0.001$ 、合計学習限界回数  $L_{max}=5$ 。各グラフは 10 試行の平均である。

### 3.1 静的環境

静的環境では、初期に NK 適応度地形を次のように生成する。1 ビット分の適応度表として、 $2^k$  個の  $0.0 \sim 1.0$  の一様乱数を生成する。このような表

を  $N$  ビット分作る。個体の適応度は各ビットに対応する表中の対応数値の平均である。

図 1 は各世代における各種適応度の平均達成率（適応度/最適解の適応度）を図示している。実線は生来の適応度  $F_{genotype}$ 、一点鎖線は個体学習後  $F_{indi}$ 、破線は社会学習後  $F_{tought}$ 、点線は生涯適応度  $F_{lifetime}$  の達成率を表す。上記以外のパラメータは、個体学習コスト  $C_{indi}=0.01$ 、教師コスト、 $C_{teacher}=-0.001$ 、エピスタシス  $K=2$  である。この設定では、個体学習が引き上げる適応度幅（実線と一点鎖線の差）と、社会学習による引き上げ（一点鎖線と破線の差）は 20 世代あたりで同じくらいになり、以降は社会学習の効果が大きい状態が続く。




図 1：適応度達成率の世代変化

実際にどれだけ学習が起きているかをみるため、平均学習回数の推移を図 2 にしめす。実線は平均個体学習回数、破線は平均個体学習限界回数で、これは全個体での平均である。一点鎖線は平均社会学習回数で、生徒エージェントでの平均である。初期に個体学習が使われるが、じょじょに使われなくなっていく。個体学習がコストになっているため遺伝的同化が起きていると考えられる。実際、生来適応度が個体学習後のものにしばらくして追いつくという動きを 50 世代くらいまでは見せている。それに対し、社会学習コストを個体学習の 1/10 に設定しており、減少幅が低く抑えられる。




図 2：平均学習回数の世代変化

社会学習コスト、教師コストを固定して、個体学習コスト  $C_{indi}$  を変化させて学習回数を調べたものが図 3 である。縦軸は 20 世代における学習回数をとっている。やはり個体学習のコストが社会学

習に比べてそれほど悪くないとき ( $C_{indi}<0.01$ ) は  $IL>SL$  である。 $C_{indi}>0.01$  で  $IL<SL$  となり、社会学習が安定的に存在するようになる。 $C_{indi}$  が非常に大きい場合は、個体学習を行う個体が淘汰されてしまい同化も起きず、個体学習限界回数も 0 となる。




図 3：個体学習コストと学習回数の関係

上記に見た結果の設定では教師コスト  $C_{teacher}$  を負にしている。すなわち、教えることがコストではなくベネフィットであるという設定で、社会学習にかなり有利である。 $C_{teacher}$  を正にした場合には教師因子に淘汰圧がかかるため、教師が突然変異的に出現するだけとなり、社会学習の発生が不安定となる。すなわち、突発的に社会学習回数が上昇しすぐ 0 になるという動きを繰り返す。

エピスタシスの程度を変えた場合に学習がどう使われるかを図 4 に示す。 $K$  を X 軸に、20 世代での平均学習回数を Y 軸に取っている。 $K=3$  で社会学習回数と個体学習回数が使われる回数が入れ替わる。 $K \geq 5$  では社会学習は非常に低くなり、個体学習限界回数が最大値である合計学習限界回数に近くなっている。エピスタシスが高い環境では適応度を上げることが困難であり、個体学習を使い続けざるをえず、このような結果になっていると考えられる。




図 4：エピスタシスと学習回数の関係

### 3.2 動的環境

つぎに環境変動がある場合の社会学習の効果を調べる。環境変動の方法は、ランダムに選んだ 1 ビットの部分に対応する NK 適応度の表を生成しなおすというものである。すなわち、ある遺伝子座の適応度を变化させるような環境変動が起きると考える。以下の実験ではこの環境変動を 5 世代ごとに起こす。パラメータ値は  $C_{indi}=0.01$ 、 $C_{studenti}=0.001$ 、 $C_{teacher}=-0.001$ 、 $K=2$  で、図 1～2 の静的環境と全く同じ条件である。

適応度達成率の変化（図 5）では、静的環境

(図1)と比べ生来適応度  $F_{genotype}$  が低く押さえられ、25 世代以降ほとんど上昇しない。これは、環境変動が短期間で起きるため学習結果の同化が不可能であることに起因する。それに対し、社会学習による上がり幅が大きくなっている。




図5：動的環境における適応度の世代変化

個体学習と社会学習の回数を静的環境と動的環境で比べたものが図6である。両環境下で社会学習回数に特に明確な差が見られ、動的環境では平均2.0回あたりで安定して存在している。




図6：静的環境と動的環境における、個体学習回数と社会学習回数の比較

#### 4. まとめと考察

このモデルにおいて遺伝的進化・個体学習・社会学習の3者が相互作用していく流れは大まかには以下のようなものである。個体学習によって山登りの適応度地形を探索し、その結果を社会学習によって集団内へ伝播、遺伝的進化に各種学習コストがもたらす選択圧によって、それら学習結果の表現型が遺伝子型へと同化されていく。

個体学習と社会学習の1回の操作は同じ1ビット反転という操作であるが、同一コストレベルでは個体学習が優先される。社会学習を優位にするには両者の間に10倍以上のコスト差が存在し、教師行動が利益とならなければならない。

これは、現在のモデルでは様々な要因で社会学習が発生する条件が厳しいからである。個体学習による個体の適応度上昇が起こらなければ、社会学習が集団の適応度上昇に貢献する手段は遺伝的優位性の伝播によるのみである。そして、社会学習の前に常に個体学習を行うようにしている。また、

個体間にある程度差が無くては社会学習が起きない。一方、社会学習回数が制限されているため、常に教師エージェントの表現型をすべてコピーできるとは限らない。エピスタシスがある状況で不完全なコピーが起きると、適応度を下げてしまう可能性が高い。すなわち、社会学習が有効になるには、集団に多様性が必要であるが、違いすぎていてもいけない。このような社会学習の困難さは、必ずしも本論のモデルにのみ存在するわけではなく、社会学習そのものの性質であろう。

結果には示さなかったが、社会学習が働く突然変異率は  $0.01 < \mu < 0.04$  程度の範囲であった。上述のとおり、社会学習が働くには多様性供給のため変異率が小さすぎてもいけない。一方、変異率が高すぎる場合は同化が困難なため、 $IL_{MAX}$  が下がらず  $L_{MAX}$  に近い値で留る。すなわち、学習能力のほとんどが個体学習に使われており、教師・生徒エージェントが存在するにもかかわらず、社会学習を行う余力がなくなってしまう。

静的環境では、 $K > 5$  で学習能力が個体学習のみに使われることを見た。Mayley(1996)は、エピスタシスが大きくなると個体学習がうまく働かないことを示唆している。この知見から考えると、個体学習が優位な状況といってもエピスタシスが大きな場合は、個体学習がどう働いているかをより詳しく調べる必要がある。

動的環境では、個体学習が使われる程度や効果は静的環境とそれほど変化がなかったが、社会学習が個体学習を上回って継続的に存在し、適応度上昇にも貢献する場合がある。しかし、動的環境の実験はまだ不十分である。環境変動の起こし方、エピスタシスやコストの程度など、よりインテシブな調査が必要である。

#### 参考文献

Best, M. L.: How culture can guide evolution: an inquiry into gene/meme enhancement and opposition, *Adaptive Behavior*, **7**(3-4), 289-306 (1999)

Kauffman, S.: *The Origins of Order: Self-Organization and Selection in Evolution*, Oxford University Press (1993)

Hinton G. E., Nowlan, S. J.: How learning can guide evolution, in *Complex Systems*, **1**, 495-502 (1987)

Mayley, G.: Landscapes, learning costs and genetic assimilation, *Evolutionary Computation*, **4**(3), 213-234 (1996)

鈴木麗璽, 有田隆也: 進化と学習の相互作用における学習の役割の変移, 第18回人工知能学会全国大会予稿集, 2H4-01 (2004).

Wright, A. H., Thompson, R. K. Zhang, J.: The computational complexity of N-K fitness functions, *IEEE Transactions on Evolutionary Computation*, **4**(4) 373-379 (2000)