

競合型共進化アルゴリズムにおける過度の特殊化問題に対する 適応度共有法の適用

佐藤 竜也^{†1} 有田 隆也^{†1}

競合型共進化アルゴリズムにおける過度の特殊化問題とは、集団中の個体が偏った進化をしてしまう問題であり、良解を得ることを妨げる。特に 2 集団の場合は、個体の評価が相手集団の個体の表現型に依存するため、一方の集団の個体の表現型多様性の偏りが相手集団個体の評価の偏りを生み、過度の特殊化問題を発生させる。本研究では、このような問題を、表現型多様性の制御機能を一方の集団に持たせ、相手集団に対し適切な進化圧を与えて解決する方法を比較評価することを目的とする。その際、多様性制御手法として、遺伝子型/表現型の類似度ではなく、振舞いの類似度を用いた適応度共有法、および、他手法と組合せ可能なエリート抑制手法を提案する。そして、両提案手法が表現型多様性の維持により相手集団の安定した進化を実現することを確認した。

Applying Fitness Sharing to Overspecialization in Competitive Coevolutionary Algorithms

TATSUYA SATO^{†1} and TAKAYA ARITA^{†1}

In the framework of competitive coevolutionary algorithms, focusing refers to the ability of coevolving opponents to challenge one another by testing weak dimensions of performance. An issue which arises in this context is overspecialization. In particular, since the fitness of individuals depends on comparisons with opponents, biased diversity of phenotype in one population biases diversity of phenotype in the other population. In order to solve this issue, we attempt to create ideal evolutionary pressure for one population by applying a method which controls diversity of phenotype to another population. This paper proposes a method of fitness sharing based on the similarity of behavior of individuals to solve this issue.

1. はじめに

共進化とは、ある生物の種とその同種・他種間の相互作用によって現れる進化のことである。これに基づいた共進化アルゴリズムは、従来の進化的計算のように静的に与えられた適応度関数を用いるのではなく、個体間の相互作用によって適応度が決定する。個体の適応度はそれを評価するための集団によって違うため、適応度地形は世代に応じて動的に変化する。また、その相互作用の定義によって競合型、協調型の 2 種類に分けられる。協調型は個体間の関係が相利共生であり、競合型は一方の適応度の増加が他方の減少につながる。

競合型共進化アルゴリズムの代表的な適用例に、ホスト/パラサイト共進化型遺伝的アルゴリズム (HPGA) によるソーティングネットワークの設計⁽¹¹⁾ があげられる。ホスト個体にソーティングネットワーク、パラ

サイト個体としてホスト個体を評価するためのテストデータをおき、両集団を共進化させることで効率の良いソーティングネットワークを得た。そのほかに、分類問題に対するニューラルネットの進化⁽²⁰⁾、セルオートマトン密度分類問題^{(14),(15),(21)} やミニマックス問題への適用^{(1),(12)}、ゲームプレイヤーの戦略の進化^{(14),(22)} などがある。これらの問題において、従来の遺伝的アルゴリズムを適用した場合に比べて良い解を得たとの報告がなされている。

競合型共進化アルゴリズムを適用することにより期待される利点として、Watson らは以下の 3 つをあげている⁽²⁶⁾。

- (1) 勾配の提供
相手集団よりも優位になろうという進化圧を相互にかけあうことにより、共進化は適応度の勾配を提供する。
- (2) オープンエンドな進化
各集団はそれまでに発見した最良個体よりも良い個体を発見する可能性がつねに存在する。

^{†1} 名古屋大学大学院情報科学研究科

Graduate School of Information Science, Nagoya University

(3) フォーカシング

まだ最適化されていない部分を最適化する方へ集団の進化の方向を集中させる。

しかし、このような利点がつねに得られることは保証されていない。さらに、Watson らは個体間の競合関係を単純な 2 人ゲームとして表現したナンバーズ・ゲームを提案し、その上で競合型共進化アルゴリズムに起きる問題点として以下の 3 つをあげた。

(1) 勾配の喪失

一方の集団が他方に対して圧倒的に優位に進化した場合、各集団中の個体間の適応度差がなくなり、選択がほぼランダムになってしまうため、進化が進みにくくなること。

(2) 相対主義

個体の適応度が相手集団に依存した相対的なものであるため、ある世代で高い適応度の個体が次の世代では低い場合がありうる。そのため、進化の方向が本来望まれる方向と一致することが保証されない。

(3) 相手集団の弱点への集中

一方の集団が、相手集団中の個体の多くが持つ弱点に対して優位になるように進化することにより、一般的な良い個体ではなく特化した個体に進化してしまうこと。

勾配の喪失問題の解決方法として、逆噴射機能を有する HPGA がある¹⁷⁾。これはパラサイト集団の適応度の平均がホスト集団の適応度の平均よりある一定以上超えたときに、得られた利得が低いパラサイトほど適応度が高くなるように適応度を変換するものである。また、勾配の喪失問題の原因である集団間の進化の速さの違いに注目したパラサイト毒性緩和がある²⁾。これは、各世代において最大適応度を持つパラサイト個体を基準として、ある程度高い適応度を持つパラサイト個体の適応度を最も高くすることにより、進化の速さを落とす方法である。

相対主義問題に対する解決方法として、殿堂入り²²⁾ やナッシュ・メモリ⁹⁾、多目的最適化の概念を用いたパレート・アーカイブ^{3)-5),18)} などのメモリ・メカニズムがある。これらの方法の方針は、各世代で得られた最良の個体をメモリに確保し、それを適応度評価に使うことで獲得した形質が失われるのを防ぐことである。

3 番目の問題点は過度の特殊化問題とも呼ばれ、この問題の解決には、集団に多様性を持たせることが必要であると指摘されている^{13),21)}。その多様性維持手法として資源共有法が提案されている^{14),22)}。これは相手個体による評価から得られる利得を、その相手か

ら同じ値の利得を得た個体どうしで分配することにより、多様性を得ようという方法である。また、適応度共有法による探索の効率化²⁵⁾、多目的最適化の概念を用いたパレート共進化^{8),19)} がある。

なお、推移律が成立しない問題に競合型共進化アルゴリズムを適用した場合、(2)の相対主義問題により解空間のある部分で探索が停滞することがある。その原因は、偏って進化した形質の変化に由来すると考えることができる。よって(3)の過度の特殊化問題の解決が上記問題の解決につながる可能性があると考えられる。

本研究では、過度の特殊化問題の解決方法として、一方の集団の多様性を制御することにより解決することを目的として提案された代表的な従来手法を比較評価する。その際、遺伝子型あるいは表現型空間の多様性ではなく、個体の振舞いの類似度の多様性を保つ適応度共有法の導入を提案し、その有効性を検討する。評価実験で比較する従来手法として適応度共有法、資源共有法、パレート共進化を用いた。問題としては、ナンバーズ・ゲームとセルオートマトン(CA)密度分類問題を用いた。これらの比較的シンプルな問題を使用した理由は、競合型共進化アルゴリズムでは適応度が相対的であり挙動が複雑化しやすいので解析を容易にすることと、提案手法で用いられてきた問題をベンチマークとして用いることにより比較評価をしやすくするためである。

2. 過度の特殊化問題

2.1 過度の特殊化の例

2次元のナンバーズ・ゲーム(4.1節で詳述)の最適な戦略の探索に基本的な競合型共進化アルゴリズムを用いた際に過度の特殊化問題が発生した例における個体の分布を図1に示す。図中、popAとpopBは両集団中の各個体を表す。ナンバーズ・ゲームの純粋戦略は2次元平面上の各点であり、2点間の差が最小である座標の値を比較し、大きい値を持つ方が利得を得る。ナンバーズ・ゲームにおいて理想的な進化は、x座標もy座標も大きい値になることだが、図1では、x軸方向に偏った進化をしている。

図2は、各集団のx座標、y座標の平均値の推移をプロットしたものである。330世代付近から両集団のx座標の平均値の差が小さく、そしてy座標の差が大きくなっており、競合のほとんどがx座標の比較により決定している。そのため、x座標値の大きい個体ほど適応度が高くなり、それらが次世代に選択されやすくなる。同図から、それ以降ではx軸方向への過剰な進化が発生していることが分かる。x軸方向への偏つ




図1 ナンバース・ゲームにおける過度の特殊化の例

Fig. 1 A typical example of overspecialization in the numbers game.




図2 各集団の座標の平均値の変化

Fig. 2 Average values in each dimension.

た進化が発生している間、 y 座標に関する評価がされず、 y 座標の変化は突然変異によるランダムウォークである。

過度の特殊化問題の解決方法として、個体の評価すべき特徴の偏りを防ぐことがあげられる。競合型共進化アルゴリズムでは、競合する集団中の表現型が互いに相手集団の適応度地形を決定しているため、一方の集団中の表現型多様性を維持することにより、過度の特殊化問題を解決できると考えられる。

2.2 適応度共有法

過度の特殊化問題を解決するための多様性を制御する方法として、一般的な遺伝的アルゴリズムなどで用いられる適応度共有法¹⁰⁾の導入が考えられる。適応度共有法とは、集団中の個体の多様性を維持するために、遺伝子型/表現型空間上に分布する個体の密度に応じてその部分の適応度を下げる適応度計算手法である。個体が適応度地形のある1つの解候補の周辺に密集した場合、適応度共有法は一時的にその周辺の適応度を下げ、密度が疎である他の解候補の適応度を相対的に上げる。この操作により、それらが次世代に残る確率が上がり、多様性が生まれる。

適応度共有法による適応度の計算式を以下に定義する。

$$F_{fs}(i) = \frac{F(i)}{\sum_{j \in P} sh(d(i, j))} \quad (1)$$

ここで、 P は集団を表す個体の集合、 $F(i)$ は適応度共有法を適用する前の個体 i の適応度、適用後が $F_{fs}(i)$ である。関数 sh はシェアリング関数と呼ばれ、空間上で個体間が与える影響の度合いを表す。この関数の出力は、個体 i と j が同一である場合には1、そうでない場合は距離 d に比例して0に近づく。シェアリング関数は、一般に以下のものが用いられる。

$$sh(d) = \begin{cases} 1 - (d/\sigma_{share})^\alpha & \text{if } d < \sigma_{share} \\ 0 & \text{otherwise} \end{cases} \quad (2)$$

σ_{share} は個体間が影響を与え合う距離の閾値、 α は距離が及ばず影響の度合いを調整するパラメータである。

一般に、距離関数 $d(i, j)$ の定義により適応度共有法は遺伝子型 (G-FS) と表現型 (P-FS) の2種類に分けられる。

2.3 資源共有法

競合型共進化アルゴリズムにおける多様性を制御する方法として資源共有法 (Resource Sharing, RS) がある^{14), 22)}。ある相手個体による評価から得られる利得は、従来の競合型共進化アルゴリズムでは自集団中の他個体の影響を受けることはないが、RSでは相手個体から同じ値の利得を得た個体どうして利得を均等に分配する。ある相手個体から得られる利得は、同じ利得を得た個体の普及率が高い場合は低くなり、普及率が低い場合には高くなる。

本研究では、個体 a の資源共有法による適応度 $F_{rs}(a)$ を以下のように定義した。

$$F_{rs}(a) = \frac{E(a, b)}{\sum_{b \in P_B} \sum_{a' \in P_A} count(a, a', b)} \quad (3)$$

$$count(a, a', b) = \begin{cases} 1 & \text{if } E(a, b) = E(a', b) \\ 0 & \text{otherwise} \end{cases} \quad (4)$$

ここで、 $E(a, b)$ は個体 a が個体 b との相互作用により得る利得、 P_A と P_B は各集団の個体の集合とする。関数 $count$ は、個体 b から個体 a が得た利得と同じ利得を得た個体が集団 P_A 中にどれだけ存在するかを表す。個体 b から得られる利得は、その数に反比例した値になる。

なお、資源共有法を基にした拡張と考えられる手法に、セルオートマトンの状態遷移ルールとセルの初期状態との共進化に対する種分類を用いた手法がある⁷⁾。この手法の目的は、セルの初期状態の集団が極端に難しいものへ進化させずに、状態遷移ルールの集団中に

存在するスキーマで処理できるものの中から徐々に難しい個体へ進化させることである*1。

2.4 パレート共進化

競合型共進化アルゴリズムの性質により現れる問題を防ぐために、多目的最適化で用いられるパレート最適の概念を取り入れたものがパレート共進化である。提案手法は適応度計算手法であるため、数あるパレート共進化手法の中からパレート最適の概念を適応度計算に用いている文献8)の手法を、本論文では比較する手法として取り上げる。

パレート共進化では、提案手法を適用する場合と同じように、2集団に別々の役割(最適解を探索する集団、相手集団に適切な進化圧を与える集団)を与え、それぞれを学習者集団と教師集団と呼ぶ。

2.4.1 学習者集団

解 x がすべての目的関数値において解 y に劣ることなく、なおかつ少なくとも1つの目的関数値においては解 y より優れているときに、 x は y を優越するという。解の集合 S の中で他の解に優越されない解の集合を S のパレートフロント、 S から S のパレートフロントを除いた集合を被支配集合と呼び、それぞれを $F^0(S)$ 、 D^0 と記述する。以上を用いて、

$$F^n = F^0(D^{n-1}), D^n = D^{n-1} - F^n (n \geq 1) \quad (5)$$

のように拡張し、各 F^n をパレート層と呼ぶ。

学習者集団は、相手集団(教師集団)の各個体による評価を目的関数と見なし、評価結果に基づいて学習者集団の各個体をパレート層に分類し、その分類に基づいて適応度を計算する。パレート層に関して昇順になるように個体をソートし、このランクのみで適応度を決定すると、世代が進むにつれパレートフロントにほとんどの個体が含まれるようになってしまい、選択圧が極端に弱まるという問題点がある。これを解決するため、Ficiciらは各パレート層内の個体をさらに順位付けする層内ランキングを用いている。層内ランキングは、各層内で資源共有法を適用し、その適応度に基づいて層内でソートすることにより決まるランキングである。最終的に得られた集団内のランクの2乗を適応度とする。

2.4.2 教師集団

教師集団は、学習者集団の探索を助けるため、学習

者集団中の個体の組合せの多くに差を持たせる個体が高い適応度を与える。学習者 l が教師 t との相互作用によって得られる利得を $E(l, t)$ 、各集団の個体数を N と表す。まず、学習者と教師との各相互作用により得られる利得をもとに、学習者の各組合せに対して各教師がどのように区別したかを表す $N \times (N^2 - N)$ 行列 M を生成する。学習者 x, y の組 $k = (x, y)$ と教師 j において、 $E(x, j) > E(y, j)$ であるときに行列 M の要素 $M_{j,k}$ は1、そうでないときは0とする。この行列 M を用いて各教師 j の適応度 s_j を、ここでもまた資源共有法と似た、以下の式によって決定する。

$$s_j = \sum_k \frac{M_{j,k}}{d_k}, \quad d_k = \sum_i M_{i,k} \quad (6)$$

3. 提案手法

3.1 Behavior-based Fitness Sharing

過度の特殊化問題を防止するためには集団中の表現型の多様性が重要である。特に、相手集団に適切な進化圧を与えるためには、単に遺伝子型/表現型空間上についてではなく、個体が相手集団に対して与える特徴に関する評価基準の多様性を考慮したうえで、表現型の多様性維持を行うことが重要であると考えられる。

そのような多様性を生み出す手法として、本研究では Behavior-based Fitness Sharing (B-FS) を提案する。これは、相手集団による評価結果を個体の振舞いとして定義し、遺伝子型/表現型空間上での個体間の近さではなく、個体の振舞いの類似度を距離関数として用いた適応度共有法である。個体が相手集団にどのような評価基準を与えているかは、相手集団による評価結果に反映されていることが期待できるため、評価結果の多様性を維持することで評価基準の多様性維持を行う。

具体的には、集団 B による集団 A の個体 a の評価結果を以下のようにベクトル t_a として表す。

$$t_a = (E(a, b_1), E(a, b_2), \dots, E(a, b_{N_B})) \quad (7)$$

ここで、 N_B は集団 B の個体数、 $E(a, b)$ は個体 a が個体 b との相互作用により得る利得を表す。この評価結果のベクトル間の距離をその個体間の類似度とし、適応度共有法を用いる。本論文ではベクトルの距離関数として、ベクトルの差の1次ノルム*2を用いた。

B-FS は各個体の評価結果に基づいており、そこから相手集団に対して与える評価基準の類似度を判別できると考えられる。

*1 具体的には、この目的のために、初期状態がある状態遷移ルール以外のうちのどれだけ多くのものに処理されているかを状態遷移ルール個体の種分類の結果を用いて測り、その値を初期状態個体が状態遷移ルール個体から得る利得、および関数 $count$ の戻り値として用いている。ここで種分類とは、初期状態集団による評価結果に基づいたクラス分析手法を用いたグループ化のことである。

*2 n 次元ベクトル \vec{p} の1次ノルム $\|\vec{p}\|_1 = \sum_{i=1}^n |p_i|$

3.2 エリート抑制

前述のように、競合型共進化アルゴリズムにおいて、その個体が相手集団に対してどの特徴に関する評価基準を与えているかが重要である。また、複数の評価基準において優れた個体が多数いる集団よりも、様々な評価基準のそれぞれについて優れた個体が多様に存在する集団の方が相手集団の評価関数として適切であると考えられる。これは、後者のような集団に対しては、ある評価基準について特化した相手個体は一部の個体からしか利得を得られず、より多くの評価基準について優れた相手個体ほど多くの利得を得る状況を生み出すことが期待できるためである。ここで、複数の評価基準において優れた個体は相手集団に対して全体的に優位であり、単一の評価基準において優れた個体は一部の相手個体に対して優位であると考えられる。

そこで、相手集団に対して全体的に優位であればあるほど適応度を抑制する手法を検討することにした。具体的には、個体が相手集団にどれだけ優位であるかを表す指標として個体が得た正の利得 ($E(p, q) > 0$) の合計を用い、その値に応じて元の適応度を割り引く適応度計算手法をさらに検討した。本論文では、これをエリート抑制と呼ぶ。具体的には、エリート抑制による適応度 $F_{es}(i)$ を以下のように定義した。

$$F_{es}(i) = weight(point(i)) \times F(i) \quad (8)$$

$$weight(p) = 1 - \left(\frac{p}{MAX_POINT} \right)^\beta \quad (9)$$

$$point(i) = \sum_{j \in P_{opponent}} \max\{E(i, j), 0\} \quad (10)$$

$$MAX_POINT = win_payoff \times |P_{opponent}| \quad (11)$$

ここで、個体 i の適応度 $F(i)$ 、 win_payoff は得られる正の利得の最大値、 $P_{opponent}$ は相手集団中の個体の集合、 $point(i)$ は個体 i が得た正の利得の合計、 MAX_POINT は正の利得の合計の最大値を表す。関数 $weight$ は、元の適応度に対する割り引き後の適応度の割合を表す単調減少関数である。この関数により、エリート抑制による適応度は得た正の利得の合計が高い個体ほど多く割り引かれ、相手集団中の全個体に対して優位になった個体、すなわち $point(i) = MAX_POINT$ である個体の場合、0 となる。

$point(i)$ に対する割り引きの度合いを、パラメータ β により調整する。 β を低く設定した場合には $point(i)$ に対して全体的に割り引きの影響が現れるが、高く設定した場合には、高い $point(i)$ を持つ個体の適応度でのみ割り引きの影響が現れる。特に、 $\beta \rightarrow \infty$ のときは、相手集団中の全個体に対して優位になった個体のみが割り引かれる。

エリート抑制は、B-FS を含めた各多様性維持の手法と組み合わせることができる。

4. ナンバース・ゲームによる評価実験

4.1 ナンバース・ゲーム

本研究では、個体間の競合関係として、2 人対称ゼロ和ゲームであるナンバース・ゲーム⁹⁾を用いる。ナンバース・ゲームの純粋戦略は、 n 次元ベクトルである。ベクトルの各要素は、区間 $[0, k]$ の値をとる。純粋戦略 p が q と対戦した際に得る利得 $E(p, q)$ は以下の式で与えられる^{*1}。

$$E(p, q) = sign \left(\sum_{i=1}^n g_i \right) \quad (12a)$$

$$g_i = \begin{cases} p_i - q_i & \text{if } h_i = \min_j h_j \\ 0 & \text{otherwise} \end{cases} \quad (12b)$$

$$h_i = |p_i - q_i| \quad (12c)$$

ここで、関数 $sign$ は、入力が正の数ならば 1 を、負ならば -1 を、0 ならば 0 を返す関数である。

上式より、ナンバース・ゲームにおける 2 戦略間の利得は、差が最小である次元の値が大きい値を持つ方が 1、小さい方が -1 となり、両戦略ともに同じ値ならば 0 となる。ベクトルの各要素の値が大きいほどより多くの戦略から利得を得ることができるため、最大値 k を各要素に持つベクトル (k, k, \dots, k) が最適な戦略である。また、ナンバース・ゲームでは、たとえば 3 つの戦略 $(3, 6)$ 、 $(1, 5)$ 、 $(4, 4)$ のように、推移律が成立しない。

ナンバース・ゲームはシンプルであり、推移律が成立しない。また、先述のように、ベクトルの各要素が大きいほどより多くの戦略から利得を得ることができることから、ベクトルの全要素の和を戦略の絶対的な良さを表す指標（絶対適応度）とすることができるので、共進化アルゴリズムの比較評価に適している。

4.2 実験設定

文献 9) に従い、以下のとおり設定した。個体の表現型は n 次元のナンバース・ゲームの純粋戦略であり、遺伝子型として長さ nk のビット列 $\langle b_1, b_2, \dots, b_{nk} \rangle$ を用意し、 $\left(\sum_{i=1}^k b_i, \sum_{i=k+1}^{2k} b_i, \dots, \sum_{i=k(n-1)+1}^{nk} b_i \right)$ として表現型であるベクトルを生成する。遺伝的操作は突然変異のみとし、選択にはルーレット選択を用いて次世代の集団を生成する。また、個体の持つ遺伝子のビット列がすべて 0 の状態として初期集団を生成す

*1 文献 9) ではパラメータ ϵ が存在するが、本論文ではそれを 0 と設定している。

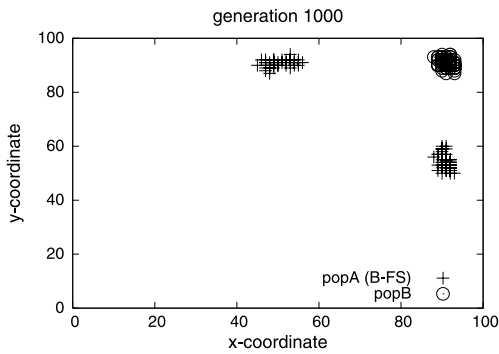


図3 1,000 世代目における個体の分布図 (B-FS)
Fig. 3 Distribution of individuals in the 1,000th population in case of B-FS.

る。競合型共進化アルゴリズムのパラメータとして、各集団の個体数は 100，突然変異確率は 0.005，世代数は 1,000 を用いた。また，ナンバーズ・ゲームのパラメータとして，次元数 n は 2，各要素の区間の最大値 k は 100 と設定した。

本研究では適応度共有法の距離関数として，遺伝子型にはハミング距離を，表現型にはユークリッド距離を用い，そのパラメータ σ_{share} には，最小値は 1，最大値は上述のパラメータと各距離関数から決まる最大距離として，G-FS では 1, 2, ..., 10, 20, ..., 200，P-FS では 1, 2, ..., 10, 20, ..., 140 ($\approx \sqrt{n \times k^2} = \sqrt{2 \times 100^2}$)，B-FS では 1, 2, ..., 10, 20, ..., 200 を用いた。各適応度共有法のシェアリング関数による影響の度合いを決定するパラメータ α は，1 を用いた。また，エリート抑制のパラメータ β に関しては，基本的挙動を把握しようと見なした範囲から選んだ 14 個の値，1, 2, ..., 10, 20, ..., 50 を用いた。

以上の設定で，一方の集団に各手法を適用し，25 試行ずつ実験を行った。各手法を適用した集団を集団 A，もう一方を集団 B とする。パレート共進化において，前者は教師集団，後者は学習者集団にあたる。

4.3 比較評価

集団 B 中の絶対適応度の最大値の 800 世代から 1,000 世代までの平均値を各試行の評価値とし，各手法のパラメータ σ_{share} にはその評価値の平均が最大であったもの (G-FS では 10，P-FS では 6，B-FS では 8) を比較に用いた。

図 3 に，B-FS を適用した場合の 1,000 世代目における個体の分布を示す。同図のように各手法を適用した場合には，集団 A 中の個体が x 軸，y 軸方向へ分かれているため，集団 B に対して両方向への進化圧がかかり，過度の特殊化を防ぐことができる。

図 4 に，各世代における集団 B 中の絶対適応度の最




図4 各手法における集団 B の絶対適応度の変化
Average objective fitness of the best individuals in population B (without elite suppression, numbers game).




図5 エリート抑制のパラメータ β による評価値の変化
Objective fitness in case with elite suppression when varying the parameter β .

大値の平均を示す。およそ 200 世代目まで，パレート共進化の値は，何も適用しない場合 (図中の NONE) や他の多様性維持手法を適用した場合よりも低い状態のままであった。200 世代以降において，何も適用しない場合には過度の特殊化が起きたために 165 を超えることはなかったのに対し，パレート共進化および各多様性維持手法を適用した場合には，先述のように集団 A が各方向へ分裂することにより過度の特殊化を防ぐことができているため高い値を示している。パレート共進化は安定して高い値を維持し続けるのに対し，B-FS を含め，多様性維持手法は若干下がることが見られた。これは，後者では集団 A が各方向へつねに均等に分裂せず，一時的に偏る傾向があり，それにより集団 B もまたその偏った方向へ特化するためである。B-FS では集団 A がより最適解へ近いほうへ進化することがあるため，P-FS より良い性能であったが，G-FS やパレート共進化に比べて進化の後半においてやや下回っている。

図 5 に，エリート抑制のみを適用した場合における




図 6 エリート抑制を組み合わせさせた場合における集団 B の絶対適応度の変化

Fig.6 Average objective fitness of the best individuals in population B (with elite suppression, numbers game).

表 1 ナンパズ・ゲームにおける各手法の評価値

Table 1 Performance of each method (numbers game).

多様性維持手法	エリート抑制	
	なし	あり
なし	1.577×10^2	1.796×10^2
G-FS	1.812×10^2	1.855×10^2
P-FS	1.678×10^2	1.855×10^2
RS	1.559×10^2	1.823×10^2
PARETO	1.923×10^2	1.989×10^2
B-FS	1.727×10^2	1.846×10^2

パラメータ β による評価値の 25 試行平均の変化を示す。 β の値が 10 を超えると、その評価値は大きく下がる。これは、関数 weight によりエリートと見なされる適応度の範囲が狭くなり、エリート抑制の効果が小さくなるためである。エリート抑制のみを適用した場合においても、図 3 のように集団 A 中の個体が各方向へ分裂する現象が確認された。これは、 x と y の値がともに大きな値を持つ個体は得点が高くなりやすく、エリート抑制によって淘汰されやすくなるためである。

図 6 に、エリート抑制と各多様性維持手法を組み合わせさせた場合における集団 B の絶対適応度の変化を示す。各組合せにおけるパラメータ β は、多様性維持手法を適用しない場合（図中 NONE）では 3.0、G-FS では 9.0、P-FS では 7.0、RS では 9.0、パレート共進化では 4.0、B-FS では 5.0 を用いた。先ほどの図 4 と比較すると、各手法においてその値が 180 付近で安定している。B-FS においては、集団 A がより最適解へ近い方へ進化するという先述の問題点が、エリート抑制により解決された。

表 1 に、各手法の評価値の 25 試行平均を示す。エリート抑制を用いない場合、多様性維持手法を導入す

ることによる性能は、パレート共進化が最も良く、続いて、G-FS、B-FS、P-FS の順である。エリート抑制と組み合わせることにより、全手法において性能の向上が見られた。

5. CA 密度分類問題による評価実験

5.1 CA 密度分類問題

セルオートマトン (CA) 密度分類問題とは、初期 (ステップ $t = 0$) において全セル中に含まれる状態 1 であるセルの割合 (以降、密度) ρ_0 が閾値 ρ_c を超えているかいないかを判定する CA の状態遷移ルールを探索する問題である。もし超えていた場合には全セルの状態を状態 1 へ、超えていない場合には状態 0 へ M ステップ以内に CA を遷移させる。本研究では 1 次元 CA 密度分類問題を対象とし、その閾値 ρ_c は $1/2$ とする。

状態遷移ルールの集団と初期状態の集団とを競合させることにより CA 密度分類問題へ競合型共進化アルゴリズムを適用した場合に過度の特殊化問題が発生することが確認されており、初期状態の集団には多様性が必要であることが指摘されている^{(14),(15),(21)}。

5.2 実験設定

$\rho_c = 1/2$ の CA 密度分類問題を、CA の状態遷移ルールの集団と全セルの初期状態の集団との共進化アルゴリズムにより行う。CA の設定として、近傍の半径に $r = 3$ 、セルの格子数に $N = 149$ 、最大ステップ数に $M = 320$ を用いた。

文献 14) に従い、以下のとおり設定した。状態遷移ルールは近傍の状態の各パターンに対する出力を列挙することで記述できるので、その遺伝子型を長さ 128 ($= 2^{2r+1} = 2^7$) の 2 進数列として表す。初期状態の遺伝子型も状態遷移ルールの場合と同様に、長さ N の 2 進数列として表現する。

状態遷移ルールの適応度は、正確に処理することができた初期状態の数である。それに対し初期状態の適応度は、その初期状態を正確に処理することができなかった状態遷移ルールの数である。

状態遷移ルールの初期集団中の個体は、区間 $[0, 1]$ の一様乱数により決定した λ パラメータ¹⁶⁾ に基づいて生成される。初期状態も同様に、区間 $[0, 1]$ の一様乱数により決定した密度 ρ_0 に基づいて生成される。各集団中の個体数は 100 個体とし、世代交代は、まず適応度について上位 90 個体をそのまま残し、その中から適応度に比例した確率で親を選び、交叉と突然変異を用いて残り 10 個体を生成する。このように次世代に個体数を多く残す理由は、一般にこの問題において

は共進化過程で集団の個体の構成が激変しやすく、共進化による安定した改善のためには、世代間のギャップを小さくする必要があるためであり、文献 14) でも 95% の個体を残す設定している。1 ビットあたりの突然変異確率は 0.002 とする。

初期状態の個体は遺伝子型と表現型が同一であるため、従来の適応度共有法は G-FS のみ適用し、距離関数にはハミング距離を用いた。そのパラメータ σ_{share} には、最小値を 1, 最大値を各距離関数における最大距離として、G-FS では 5, 10, 20, 50, 149, B-FS では 5, 10, 20, 30, 40, 50, 100 を用い、シェアリング関数のパラメータ α には 1 を用いた。また、エリート抑制のパラメータ β には 1, 2, 5, 10, 20, 50 を用いた。

以上の設定を用い、多様性維持手法については各手法を初期状態の集団に適用し、パレート共進化については状態遷移ルールの集団と初期状態の集団をそれぞれ学習者集団、教師集団として実装し、それぞれ 40 試行ずつ実験を行った。

5.3 比較評価

各世代において最大適応度を持つ状態遷移ルールに対して、一様乱数により決定した密度 ρ_0 に基づいて初期状態を 10^4 個生成し、そのうち正確に処理した割合（正答率）を計算し、それを各手法の比較評価に用いた。正答率の全世代の平均を各試行の評価値とし、各手法のパラメータ σ_{share} にはその評価値の平均が最大であったもの（G-FS では 50, B-FS では 20）を用いた。

図 7 に、最大適応度を持つ状態遷移ルールの正答率の試行平均の変化を示す。多様性維持手法を適用しない場合では過度の特殊化が起きるため、正答率は 0.5 付近を保っている。G-FS を適用した場合には正答率の緩やかな上昇が見られ、最終世代においては 0.719 であった。それに対し、B-FS を適用した場合にはおよそ 180 世代にかけて正答率が 0.8 付近にまで上昇する。そして、G-FS に比べて B-FS は高い正答率の状態遷移ルールを安定して得ることができた。これは初期状態の密度 ρ_0 が $1/2$ 付近に収束した際に、G-FS では $1/2$ より上または下のどちらか一方へ収束するのに対し、B-FS ではその両方に分布させることができたためだと考えられる。RS を適用した場合においても、上述の B-FS と同様の初期状態の分布が見られたが、その進化の速度が遅く、高い正答率を得ることができなかった。これは、文献 14), 15) のように、RS は両集団に対し適用することでその効果が現れるためだと考えられる。パレート共進化を適用した場合は、




図 7 各手法ごとの状態遷移ルールの正答率の変化

Fig. 7 Average accuracy rate of the best individuals in population B (without elite suppression, CA density classification).

初期状態の密度と λ パラメータがともに 0.5 付近へ収束するが、正答率はおよそ 0.5 を維持したままであった*1。

エリート抑制のみを適用した場合、パラメータ $\beta = 1, 2, 5, 10, 20, 50$ における評価値の 40 試行平均はそれぞれ 0.5010, 0.4999, 0.5024, 0.5003, 0.5003, 0.5005 となり、各パラメータ値において、過度の特殊化が起きることが確認された。エリート抑制は相対的に難しいものほど適応度を低くするため、初期世代において相対的に難しい初期状態の集団は相対的に簡単なものへ進化する。そのため、初期状態の集団の中で次世代に残りやすい個体は、密度 ρ_0 が $1/2$ に近いものではなく、1 または 0 に近いものである。状態遷移ルールの集団においてもまた、 λ パラメータが 1 または 0 に近いものが残りやすくなるため、初期集団中の個体数の偏りにより次世代の集団に偏りが生まれる。

図 8 に、エリート抑制と各多様性維持手法とを組み合わせ合わせた場合における正答率の変化を示す。各組合せにおけるパラメータ β は、多様性維持手法を適用しない場合には 5, G-FS では 5, RS では 5, パレート共進化では 20.0, B-FS では 50 において正答率の平均が最大となった。エリート抑制のみ（図中 NONE）と B-FS の傾向は、エリート抑制を組み合わせる以前との大きな違いは見られなかったが、G-FS と PARETO

*1 文献 8) では、本実験結果より良い、83.9% より高い正答率がパレート共進化によって得られたことが報告されているが、1) 密度を表す実数値を初期状態を表す個体の遺伝子表現に用い、2) 初期状態を表す個体が状態遷移ルールを表す個体を評価する際に、適応度評価においてその初期状態を表す個体の遺伝子が表す密度を持つ初期状態を 40 個生成することで評価回数を多くし、3) 世代交代でまったくランダムな個体を追加するなど、問題と手法に特化したテクニックを用いていることによると考えられる。




図 8 エリート抑制を組み合わせた場合の状態遷移ルールの正答率の変化

Fig.8 Average accuracy rate of the best individuals in population B (with elite suppression, CA density classification).

表 2 CA 密度分類問題における各手法の評価値

Table 2 Performance of each method (CA density classification).

多様性維持手法	エリート抑制	
	なし	あり
なし	0.4962	0.5024
G-FS	0.6820	0.6232
RS	0.5095	0.5586
PARETO	0.4975	0.4960
B-FS	0.7698	0.7699

では正答率の減少, RS では若干の上昇が見られた。

表 2 に, 各手法の評価値の 40 試行平均を示す。同表より, エリート抑制を用いることにより, G-FS と PARETO を除き, 性能を向上させること, および, エリート抑制の適用の有無にかかわらず, B-FS が最も良い性能を示したことが分かる。

B-FS により最終世代で得られた最良の状態遷移ルールに対し, 先に述べた方法に従って生成した 4×10^7 個の初期状態を用いて正答率を再計算したところ, 84.24% であった。また, 250 から 350 世代までの間におよそ 95% の正答率を持つ状態遷移ルールが現れていることを確認した。Juillé らが RS によって得た最良の状態遷移ルールの正答率は 86.3%¹⁴⁾, Ficci らがパレート共進化によって得た最良の状態遷移ルールの正答率は 84.0%⁸⁾, そして遠藤らの種分類による手法では 89.0% の正答率を持つ状態遷移ルールを得ている⁷⁾。{状態遷移ルール数/初期状態数, 進化世代数} に関しては, Juillé らの設定, Ficci らの設定, 遠藤らの設定, 本実験での設定で, それぞれ, {1,000/1,000, 5,000}, {150/100, 1,300}, {500/5,000, 1,200}, {100/100, 1,000} となっている。特に, 遠藤らの設定では, 初期状態の個体を非常に多くすることで多様性を維持

し, なおかつ状態遷移ルールの種分類による状態遷移ルールの探索の効率化によって, 高い正答率が獲得できたと考えられる。

それらに対して本実験の設定は個体数と世代数とともに少ないことで結果的に評価回数が少ない状況であり, 初期状態集団の適応度計算を改良しただけの単純な手法であるにもかかわらず, B-FS を用いることにより従来研究の結果に匹敵する正答率の状態遷移ルールを得ることができた。

6. おわりに

本論文では, 2 集団の競合型共進化アルゴリズムにおいて, 多様性を維持する機能を一方の集団に適用することによって過度の特異化問題を解決しうること, ナンバース・ゲームと CA 密度分類問題を対象とした比較評価実験によって示した。ナンバース・ゲームにおいて B-FS は何も適用しない場合との性能比が 9.5% であり, パレート共進化と遺伝子型適応度共有法に比べ若干下回る結果だが, CA 密度分類問題においては, B-FS は何も適用しない場合との性能比が 55.1% であり, 今回比較した手法の中で一番良い結果を得た。また, 両問題の結果から, エリート抑制を組み合わせることにより, 性能を改善することができることを確認した。

B-FS がナンバース・ゲームにおいて CA 密度分類問題ほどの性能を出せなかった理由は, 評価される個体の特徴が 2 つの問題で異なるためであると考えられる。ナンバース・ゲームでは, 相手集団個体との評価結果だけからは, その結果がどちらの次元によってもたらされたかを判断できないので, 評価結果を用いて多様性を維持する B-FS は, それぞれの次元に特化した個体群を集団中にバランス良く存在させることに關して不利な面があるからである。

本論文で行った実験の目的は関連する従来手法との比較, そして従来研究との比較であったため, 基本的には, 選択や遺伝的操作は従来研究で用いられていたものを用いていた。そのため, 適切な選択, 遺伝的操作を導入することで, 各手法の性能が向上すると思われる。特に, ナンバース・ゲームに関する実験で用いたルーレット選択, および CA 密度分類問題の実験における親個体の選び方は, 適応度に依存した確率に従うものであり, 各手法の挙動に強く影響していると考えられる。

競合型共進化アルゴリズムでは計算量削減のため, 相手集団中の全個体ではなく, サンプリングした個体のみを各個体の適応度評価に用いる場合がある^{6), 23), 24)}。

B-FS で用いられるベクトル (式 (7)) の次元数は適応度評価に用いる個体数であり, サンプルングが B-FS の性能に影響すると考えられる. この点を調べるために, 2次元ナンバーズ・ゲームにおいて 100 個体中 75 個体をランダムサンプルングした予備実験を行ったところ, 表 1 の結果に比べ若干低下する値 (1.671×10^2) が示された. 詳細な議論は別報で行う予定である.

謝辞 本研究の一部は, 文部科学省 21 世紀 COE 「計算科学フロンティア」の援助による.

参 考 文 献

- 1) Barbosa, H.J.C.: A Coevolutionary Genetic Algorithm for a Game Approach to Structural Optimization, *Proc. 7th International Conference on Genetic Algorithms*, pp.545–552 (1997).
- 2) Cartledge, J. and Bullock, S.: Combating Coevolutionary Disengagement by Reducing Parasite Virulence, *Evolutionary Computation*, Vol.12, No.2, pp.193–222 (2004).
- 3) De Jong, E.D.: The Incremental Pareto-coevolution archive, *Proc. Genetic and Evolutionary Computation Conference*, pp.525–536 (2004).
- 4) De Jong, E.D.: Towards a Bounded Pareto-Coevolution Archive, *Proc. Congress on Evolutionary Computation*, pp.2341–2348 (2004).
- 5) De Jong, E.D. and Pollack, J.B.: Ideal Evaluation from Coevolution, *Evolutionary Computation*, Vol.12, No.2, pp.159–192 (2004).
- 6) Dolin, B., Bennett III, F.H. and Rieffel, E.G.: Co-Evolving an Effective Fitness Sample: Experiments in Symbolic Regression and Distributed Robot Control, *Proc. 2002 ACM Symposium on Applied Computing*, pp.553–559 (2002).
- 7) 遠藤聡志, 山田孝治, 亀島 力: 種分類を用いた共進化によるセルオートマトンの近傍則獲得, 情報処理学会論文誌: 数理モデル化と応用, Vol.45, No.2, pp.110–118 (2004).
- 8) Ficici, S.G. and Pollack, J.B.: Pareto Optimality in Coevolutionary Learning, *Advances in Artificial Life: Proc. 6th European Conference* (2001).
- 9) Ficici, S.G. and Pollack, J.B.: A Game-Theoretic Memory Mechanism for Coevolution, *Proc. Genetic and Evolutionary Computation Conference*, pp.286–297 (2003).
- 10) Goldberg, D.E. and Richardson, J.: Genetic Algorithms with Sharing for Multimodal Function Optimization, *Proc. 2nd International Conference on Genetic Algorithms*, pp.41–49 (1987).
- 11) Hillis, W.D.: Co-Evolving Parasites Improve Simulated Evolution as an Optimization Procedure, *Artificial Life II*, pp.313–324 (1992).
- 12) Jensen, M.T.: A New Look at Solving Minimax Problems with Coevolution, *Proc. 4th Metaheuristics International Conference*, pp.103–107 (2001).
- 13) Juillé, H. and Pollack, J.B.: Co-evolving Interwined Spirals, *Proc. 5th Annual Conference on Evolutionary Programming*, pp.461–468 (1996).
- 14) Juillé, H. and Pollack, J.B.: Coevolutionary Learning: A Case Study, *Proc. 15th International Conference on Machine Learning*, pp.251–259 (1998).
- 15) Juillé, H. and Pollack, J.B.: Coevolving the Ideal Trainer: Application to the Discovery of Cellular Automata Rules, *Proc. 3rd Annual Genetic Programming Conference*, pp.519–527 (1998).
- 16) Langton, C.G.: Computation at the Edge of Chaos: Phase Transitions and Emergent Computation, *Physica. D*, Vol.42, No.1-3, pp.12–37 (1990).
- 17) 三井富雄, 有田隆也: 進化圧を自動調整するホスト/パラサイト共進化型遺伝的アルゴリズム, 人工知能学会全国大会論文集, 2C3-04 (2001).
- 18) Monroy, G.A., Stanley, K.O. and Miikkulainen, R.: Coevolution of Neural Networks using a Layered Pareto Archive, *the 8th Annual Conference on Genetic and Evolutionary Computation*, pp.329–336 (2006).
- 19) Noble, J. and Watson, R.A.: Pareto Coevolution: Using Performance against Coevolved Opponents in a Game as Dimensions for Pareto Selection, *Proc. Genetic and Evolutionary Computation Conference*, pp.493–500 (2001).
- 20) Paredis, J.: Coevolutionary Computation, *Artificial Life*, Vol.2, No.4, pp.355–375 (1995).
- 21) Paredis, J.: Coevolving Cellular Automata: Be Aware of the Red Queen!, *Proc. 7th International Conference on Genetic Algorithms*, pp.393–400 (1997).
- 22) Rosin, C.D. and Below, R.K.: Methods for Competitive Co-evolution: Finding Opponents Worth Beating, *Proc. 6th International Conference on Genetic Algorithms*, pp.373–380 (1995).
- 23) Rosin, C.D.: Coevolutionary Search Among Adversaries, Ph.D. Thesis, University of California, San Diego, CA (1997).
- 24) Sims, K.: Evolving 3D Morphology and Behavior by Competition, *Proc. Artificial Life IV*,

pp.28–39 (1994).

- 25) Smith, R.E. and Gray, B.: Co-Adaptive Genetic Algorithms: An Example in Othello Strategy, *Proc. Florida Artificial Intelligence Research Symposium*, pp.259–264 (1994).
- 26) Watson, R.A. and Pollack, J.B.: Coevolutionary Dynamics in a Minimal Substrate, *Proc. Genetic and Evolutionary Computation Conference*, pp.702–709 (2001).

(平成 19 年 5 月 23 日受付)

(平成 19 年 10 月 2 日採録)



佐藤 竜也

1981 年生まれ．2004 年群馬大学工学部情報工学科卒業．2006 年名古屋大学大学院情報科学研究科博士課程（前期課程）修了．現在，同大学院博士課程（後期課程）在学中．進

化的計算手法の研究に従事．



有田 隆也（正会員）

1960 年生まれ．1983 年東京大学工学部計数工学科卒業．1988 年同大学大学院工学系研究科博士課程修了．工学博士．名古屋工業大学講師，カリフォルニア大学ロサンゼルス校客員研究員を経て，現在，名古屋大学大学院情報科学研究科教授．人工生命や情報科学の研究に従事．複雑適応系，進化ダイナミクス，言語の進化等に興味を持つ．著書に『人工生命』（医学出版，2002 年），『心はプログラムできるか』（ソフトバンククリエイティブ，2007 年）等．