

二種類の記憶機構を導入した 適応的免疫アルゴリズムの提案と評価

The Proposal and Evaluation of an Adaptive Memorizing Immune Algorithm with Two Memory Mechanisms

當間 愛晃
Naruaki Toma

琉球大学大学院理工学研究科総合智能工学専攻
Doctoral Course in Complex Intelligent Systems Engineering, Graduate School of Science and Engineering, University of
the Ryukyus
tnal@eva.ie.u-ryukyu.ac.jp, <http://www.eva.ie.u-ryukyu.ac.jp/~tnal/>

遠藤 聡志
Satoshi Endo

琉球大学工学部
Faculty of Engineering, University of the Ryukyus
endo@ie.u-ryukyu.ac.jp, <http://www.eva.ie.u-ryukyu.ac.jp/~endo/>

山田 孝治
Koji Yamada

(同上)
koji@ie.u-ryukyu.ac.jp, <http://www.eva.ie.u-ryukyu.ac.jp/~koji/>

keywords: genetic algorithm, adaptive memorizing immune algorithm, multimodal function, traveling salesman problem, bipolar deceptive function

Summary

The immune system is one of the adaptive biological systems whose functions are to identify and to eliminate foreign material. Applying this system to the engineering problems, these processes are regarded as an effective search and optimization. In this paper, we propose an optimization algorithm, called Adaptive Memorizing Immune Algorithm (AMIA), based on an immune system with two memory mechanisms. The one, primary memory mechanism is used 1) to memorize antibodies that have useful characteristics as solutions and 2) to improve ability of local searching. The other, secondary memory mechanism is used to restrain re-searching of memorized solutions. Some computer simulations are designed to investigate the performance of the immune algorithm. The results of simulations represent that the immune algorithm shows good performance for multimodal functions.

1. ま え が き

ニューラルネットワーク、遺伝的アルゴリズム (Genetic Algorithm: 以下, GA) などの適応アルゴリズムは、従来の工学的最適化手法にはない、生物の優れた情報処理機能に基づいており、その有効性は様々な研究により示されている [北野 93, Back 97, Holland 92, Russell 95].

近年、脳神経系、遺伝適応系と並ぶ第三の生体システムとして免疫システムが取り上げられている [Dasgupta 99, 石黒 97, 石田 98, 高橋 98, 多田 93-a]. 免疫システムは、多様性のある抗体の産生およびその自己調節機構、抗体の特異性や免疫学的記憶に基づいた一次免疫応答および二次免疫応答などの様々な高次情報処理機構により構成されている。このような特徴を持つ免疫システムを扱った先行研究は、分散型診断アルゴリズム [Ishida 90] や、多峰性関数最適化 [森 93, 森 97], 一個体による多機能型適応システム [和田 92] など、免疫システムを応用したアプリケーションだけに限らず、免疫学的記憶の性質を解析した [Forrest 90] や、親和度を用いた抗体産

生を調節する枠組を定式化した [Bersini 91] など、非常に幅広い分野において研究がなされている。森らにより提案された免疫アルゴリズム (Immune Algorithm: 以下, IA) は、GA の多点探索による大域探索を基本動作とし、解候補の獲得を行なう記憶細胞と、探索点の移動を行なうサブレッサー細胞を加えた構成をとる。同アルゴリズムは、獲得した解候補に対し再探索の抑制を行なうことにより探索点を移動することで、多峰性関数における複数最適解の獲得が可能であることが示されている。しかしながら、パラメータの設定が適切でない場合には、探索した解全てを記憶する、または逆に全く記憶を得ることができないなど、適切な探索を行なうために必要不可欠であるパラメータの調整が困難という問題点がある。このパラメータ調整の困難さは、記憶獲得と探索抑制が一つの連動したシステムとして導入されている点に原因がある。

一方、免疫システムには、免疫学的記憶を活用した効率の良い抗原排除を実現する生体反応があり、二次免疫応答と呼ばれている。このような効率の良い抗原排除は、

実際の免疫システムにおいては二度目以降の抗原排除時にのみ用いられているが、それを工学システムとして応用する際には、二次免疫応答を一度目の抗原排除時にも活用することでより優れたシステムを構築することが可能である。このような考えに基づき、探索空間の絞り込みによる局所探索を行う一次記憶機構を構築した。また、先に述べた IA におけるパラメータ調整の問題は、記憶獲得を構築した一次記憶機構で行い、探索抑制をそれとは独立した二次記憶機構へと分離することで解決を図る。

本論文では、多峰性関数における探索効率化を目的とし、パラメータ調整の簡単化および局所探索能力を加えた適応的免疫アルゴリズム (Adaptive Memorizing Immune Algorithm: 以下, AMIA) を提案する。導入する記憶機構は 2 つの情報処理機構で構成される。

一次記憶機構: 探索中に発見した優位解の特徴を記憶し、それを基に増殖プロセスを積極的に支援することで、探索空間の絞り込みを行う。

二次記憶機構: ある局所解に収束しつつある探索点を記憶し、それを基に再探索の抑制を行う。

上記の機構を持つ AMIA は、

- 優位解の記憶獲得と再探索抑制が二つの機構に分離されているためにパラメータ設定が容易、
- 探索空間の絞り込みによる局所探索能力の向上、

という特徴が期待される。すなわち、大域探索と局所探索を使い分けることで、探索効率化を図る。本アルゴリズムの有効性を検証するため、二つのだまし問題、巡回セールスマン問題 (Traveling Salesman Problem: 以下, TSP) および、Bipolar Deceptive Function (以下, BDF) [Goldberg 92] へ適用する。

2. 免疫システム

免疫システムとは、生体内に侵入する未知の抗原に対応するため、抗体の再構築を行なって抗原に対応する抗体を産生し、抗原を排除する生体監視防衛機構である (図 1)。この抗原に対する一連の処理は免疫応答と呼ばれる。

Step1. 抗原の認識機構

Step2. 抗体の再構成機構

Step3. 抗体による抗原の排除機構

Step4. 排除に利用された抗体の記憶機構

Step5. 抗体の抑制機構

ここで、提案手法に導入した一次記憶機構は抗体の再構成機構および抗体の記憶機構、二次記憶機構は抗体の抑制機構に相当する。

実際の免疫システムにおける免疫応答には、最初に免疫した場合に見られる一次免疫応答と、二度目以降の免疫によって見られる二次免疫応答がある。二次免疫応答では、一次免疫応答と比べ比較的早い段階で抗原に対応可能な抗体が大量に血清中に現れる。このような免疫システムの記憶を免疫学的記憶という [藤原 97, 多田 93-b]。

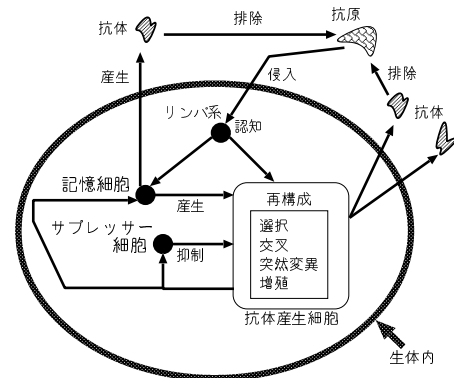


図 1 免疫システム

二種類の免疫応答を探索アルゴリズムとして応用するため、その処理機構の役割を検討する。一次免疫応答により得られる記憶は、侵入した抗原を排除するために行われた学習結果である。免疫システムでは、一度排除した抗原が再度侵入して来た場合、その学習結果を活用することにより効率の良い抗原排除を実現している。抗原排除を問題解決と見做すと、このような学習結果の応用を一度目の問題解決時にも実行する事により、より優れた解決策を獲得する事が可能である。提案手法における一次記憶機構とは、この記憶獲得と二次免疫応答を応用した機構である。

二次免疫応答を模倣した研究は [Ishida 96, 森 97] など多数報告されているが、これらはあくまで二度目以降の問題解決時のみ活用するという、免疫学上の二次免疫応答を模倣したものである。本論文の新規性は、一度目の問題解決時にも活用可能となるよう拡張を施した点にあり、免疫学的記憶の活用方法が従来研究とは異なる。その結果、二次免疫応答のような効率の良い問題解決を一度目の問題解決時にも実現することが可能となった。

3. 免疫アルゴリズム

本章では、免疫的最適化について述べ、それをアルゴリズム化した先行研究 IA [森 93, 森 97] の問題点を明確にする。また、問題点の改善を行った AMIA を示し、アルゴリズムの詳細を説明する。なお、単に“免疫アルゴリズム”とした場合は、IA と AMIA 両者を指す。

3.1 免疫的最適化

一般的な組合せ問題の適応度地形は、図 2 のように多峰性関数となる。通常的最適化では、その適応度地形の最大適応度となる解 (大域的最適解) 発見を目的とする。しかしながら、実際に獲得した解を用いて問題解決として利用する場合、幾つかの問題が生じる。例えば、データとして扱う適応度地形そのものにシステム利用者の主観が入るため、真に必要な解が最適解とはならないことがある。また、対象とする問題の諸条件が変化する場面も考えられる。以上の理由から、一つ的最適解のみ

ならず、複数の最適解や局所解を発見する事が最適化にとって有効である。

免疫的最適化は、GA による探索を実行中に以下の4つの処理を加える事により、複数の最適解を獲得する(図2)。

Step1.探索点の収束度合を計算. その収束度合がある閾値を越えた場合に手続き2以下を実行

Step2.閾値を越えた解を記憶として獲得

Step3.別の探索点へと移動

Step4.再探索を抑制

これらの処理を行うため、免疫アルゴリズムでは適応度、類似度、濃度、期待値を用いる。

[適応度 $fitness_v$] 解 v の評価値

[類似度 $ay_{v,w}$] 2つの解 v,w に共通する遺伝子の割合

[濃度 c_v] 解 v が遺伝子プールに存在する割合

$$c_v = \left(\sum_{w=0}^{PopSize} ac_{v,w} \right) / PopSize \quad (1)$$

$$ac_{v,w} = \begin{cases} 1 & ay_{v,w} \geq TAC1 \\ 0 & otherwise \end{cases} \quad (2)$$

• $PopSize$: GA 集団サイズ

• $TAC1$: 閾値

[期待値 e_v] 解 v の次世代への残りやすさ

$$e_v = fitness_v \times \prod_{s=1}^S (1 - as_{v,s}) \quad (3)$$

$$as_{v,s} = \begin{cases} ay_{v,s} & ay_{v,s} \geq TAC2 \\ 0 & otherwise \end{cases} \quad (4)$$

• S : サプレッサー細胞総数

• $ay_{v,s}$: 解 v とサプレッサー細胞との類似度

• $TAC2$: 閾値

適応度と類似度の計算式は問題に固有の設定である。免疫アルゴリズムは、手順(1)で用いる収束度合を濃度として計算し、その濃度値がある閾値を越えた場合に手順(2)以下を実行する。閾値を越えた濃度値を持つ解は、解集団内に占める割合が高い解であることから、適応度の高い部分解(スキマタ)を多く含んでいる。そのような解を全て記憶として獲得し、さらに獲得した解に類似する探索点の再探索を抑制することで探索の効率化を図る。再探索の抑制は、抑制対象であるサプレッサー細胞との類似度が閾値 $TAC2$ を越えた場合に、期待値を下げることで実現している。




図2 多峰性関数と免疫的最適化

3.2 IA の特長と問題点

森らにより提案されたIAは、GAに基づく解の再構成、記憶細胞による優位解の記憶、サプレッサー細胞による記憶解の再探索抑制により構成される探索アルゴリズムである(図3)。

IAが複数最適解を獲得するには適切なパラメータ設定が必要不可欠だが、そのパラメータ設定問題は解決されておらず、また、獲得した優位解の利用形態に関しても検討の余地がある。

(1)パラメータ調整の困難性: IAは、閾値を越えた濃度を持つ解が現われると、記憶獲得および再探索抑制を同時に行う。そのため、探索中の峰における最適解を獲得する前に、低い適応度の解を獲得した場合、それ以降の探索が抑制されるため最適解を獲得することができない。しかしながら、十分に探索した後に記憶させるために閾値を高く設定すると記憶が得られず、逆に閾値が低い場合には適切でない解までも記憶してしまう。

(2)記憶細胞を活用した探索能力の向上: 探索中に獲得した記憶を元に、記憶に類似した探索点の局所探索を行なうことで局所的最適解の探索可能性を高めることが可能である。また、探索に要する世代数の観点からは、大域探索のみで局所的最適解を探索するよりも、局所探索を行なうことで世代数の減少が見込める。

上記の検討点を改善するため、提案手法では二種類の記憶機構を導入した。上記の検討点(1)は、記憶獲得と再探索抑制を二種類の記憶機構として各々独立させることにより、パラメータ調整を容易にした。検討点(2)は、免疫システムにおける記憶獲得と二次免疫応答を、一度目の問題解決時にも活用することにより、探索能力を向上させた。

3.3 拡張アルゴリズム; AMIA

二種類の記憶機構をStep4に導入した拡張アルゴリズムAMIAを図4に示す。

[Step1. 抗原の認識] 抗原を入力情報として認識する。

[Step2. 初期抗体群の生成] ランダムに、もしくは学習結果である記憶細胞を用い、抗体群を作成する。

[Step3. 適応度および類似度の計算] 抗体 v の適応度 $fitness_v$ と、2つの抗体 v,w の類似度 $ay_{v,w}$ を計算する。

[Step4. 記憶細胞またはサプレッサー細胞への分化] 全ての抗体の濃度を計算し、抗体 v の濃度 c_v が閾値 TC を越えた場合、記憶細胞(Step4Mem)またはサプレッサー細胞(Step4Sup)へ分化する。この時、通常探索中であればStep4Mem、局所探索中であればStep4Supへ分化する。なお、初期状態では通常探索中とする。

• [Step4Mem. 一次記憶機構] 記憶細胞への優位解の特徴獲得および、記憶を活用した局所探索の実行。




図3 免疫アルゴリズムの枠組み

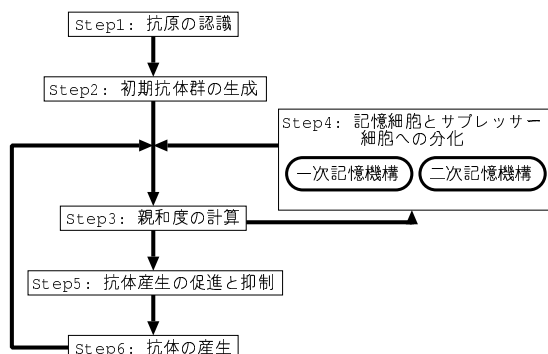


図 4 二種類の記憶機構を導入した免疫アルゴリズム

• [Step4_{sup}. 二次記憶機構] サプレッサー細胞への候補解の獲得, 再探索抑制および探索点の移動.

[Step5. 抗体産生の促進と抑制] 次世代に残る抗体 v の期待値 e_v を計算する.

[Step6. 抗体の産生] 期待値に基づいた選択, 交叉, 突然変異により抗体の再構成を行う. 以下, 世代があらかじめ設定した最終世代に達するまで Step3~6 を繰り返す.

免疫アルゴリズムは, 類似度・濃度から探索点の収束度合を計算する. 収束度合を次世代への残りやすさである期待値に用いることにより, 抗体の産生を自己調節し, 多様な抗体を産生する免疫システムのモデル化を実現している.

3.4 記憶機構

§1 記憶機構の特徴

記憶機構は, (1) GA による探索, (2) 一次記憶機構による局所探索, (3) 二次記憶機構による再探索抑制, の 3 サイクルにより構成される (図 5). 同図における局所探索中かどうかの判断処理では, 初期状態では GA による通常の大域探索であることから一次記憶機構へ処理が移行し, 局所探索を実行する. 局所探索中に同判断処理に移った場合, 二次記憶機構へと移行し, 通常の大域探索へと戻る. なお, 局所探索中か大域探索中かを判断するためには TC を用いており, TC が初期設定値である場合を通常探索とし, TC が TC_{POWER} を乗じた値である場合を局所探索として判断する. このように, 一次記憶機構と二次記憶機構を交互に用いることで優位解の獲得, 探索点の移動という探索動作を行なう.

既提案の IA におけるパラメータ調整の困難さは, 記憶細胞とサプレッサー細胞を個別の記憶機構として分離することにより解消している. また, 探索中に獲得した記憶を活用した探索として局所探索を行なう一次記憶機構を導入している. 提案する二種類の記憶機構を用いた AMIA は,

- 記憶細胞を活用した優位解の獲得および, 獲得した解を活用した局所探索の促進
- サプレッサー細胞を活用した探索点のシフトおよび, 再探索抑制

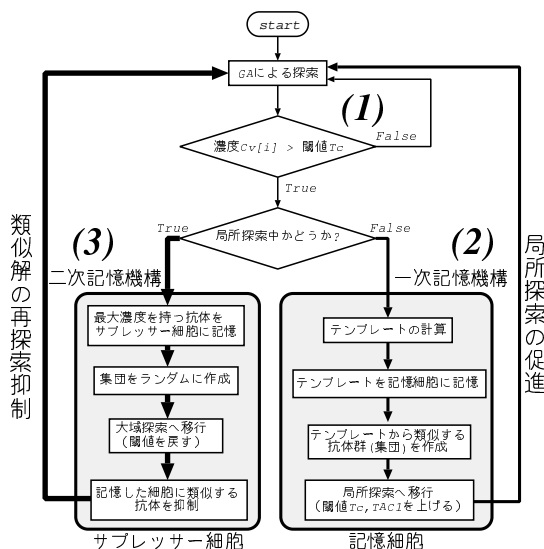


図 5 記憶機構

を動作原理とするため, 複数の最適解を獲得できる. 複数解の優位解を獲得する点では IA と同一であるが, AMIA は 1) パラメータ調整の簡単化, 2) 局所探索能力の向上による探索効率化, という拡張を行った.

§2 一次記憶機構

一次記憶機構では探索効率の改善のため, 次に示す 2 点を実装する.

記憶の洗練: 優位な解をそのまま記憶するのではなく, 冗長な情報を省くことでスキマタを抽出する.

局所探索能力の向上: 部分解を共通に含む集団を作成することで探索範囲を制限する. その結果, GA の不得手とする局所探索の向上が可能となる.

これらを実現するために記憶細胞を活用したアルゴリズムを示す. その概念図を図 6 に示す. ただし, 同図では集団内の各個体は 2 種類の特徴を持つと仮定している.

[Step1. テンプレートの計算] 最大濃度を持つ抗体との類似度が閾値 $TAC1$ を越える抗体群に共通するパターンを集めてテンプレートとする.

[Step2. テンプレートを記憶細胞に記憶] 記憶最大数を越える場合, 最も共通するパターンを持つテンプレートと入れ換え, 互いに共通性の少ないテンプレートを残す.

[Step3. テンプレートから類似する抗体群を作成] テン

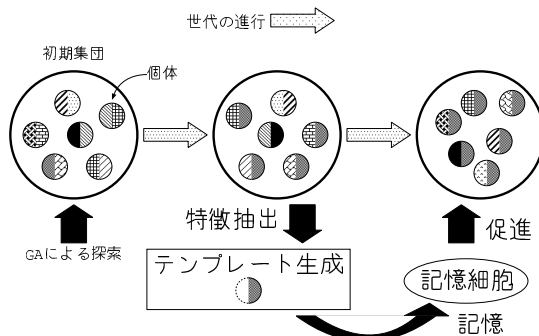


図 6 一次記憶機構

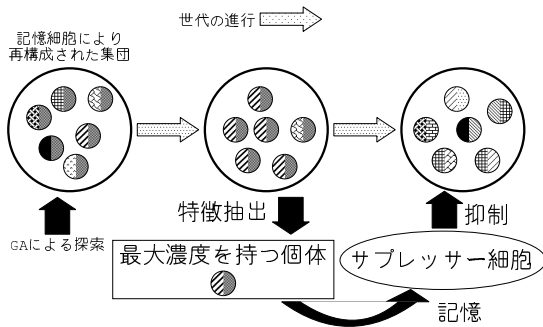


図 7 二次記憶機構

プレートを含むように解を作成し、解として不足している情報はランダムに作成する。

[Step4. 局所探索へ移行] 閾値 TC を上げることにより、ある探索点に収束するまで探索を行なう。

§ 3 二次記憶機構

二次記憶機構では、一次記憶機構により促進された局所探索終了後、候補解の獲得・探索点の移動・再探索抑制を目的とする(図7)。

[Step1. 最大濃度の抗体をサブレッサー細胞に記憶] 記憶最大数を越える場合、最も類似度の高いサブレッサー細胞と入れ換える。

[Step2. 集団をランダムに作成] 探索点の移動を行う。

[Step3. 大域探索に移行] 一次記憶機構により上げられた閾値を戻すことで、通常の大域探索に戻る。

[Step4. 記憶した細胞に類似する抗体を抑制] 記憶した候補解に類似する解産生の期待値を下げる(式3)ことで再探索を抑制する。

4. 計算機実験

AMIA の有効性検証のため、二つの計算機実験を行う。初めに、AMIA の探索動作を確認するため、TSP におけるだまし問題へ適用する。次に、多峰性関数における複数最適解の獲得効率を検証するため、Bipolar Deceptive Function へ適用する。

4.1 巡回セールスマン問題；TSP

記憶機構の有効性を検証するため、組合せ最適化問題の典型例である巡回セールスマン問題におけるだまし問題[山村 92]へ適用する。ここで、だまし問題とは2重の同心円上に同数の都市が均等に並んだ都市配置における最短経路を探索する問題である。だまし問題では、図8に示すように2つの特徴的な優良解が存在し、内外円の半径比によって最適解、局所解が入れ替わる。図8は都市数48の例である。同図(a)はどちらか一方の円を巡回してから他方を巡回するプランすなわち C-type が最適解となる例、同図(b)は外円と内円を交互に巡回するプランすなわち O-type が最適解となる例である。

図9は、だまし問題における AMIA の動作原理を概

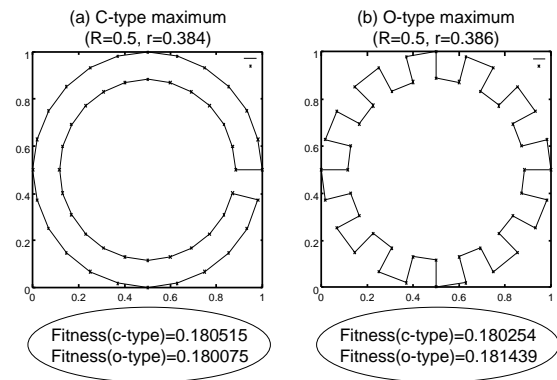


図 8 C-type と O-type




図 9 類似問題の Fitness Landscape

念的に示している。IA は同図における再探索抑制のみを行っており、AMIA では更に一次記憶機構による局所探索能力を有するため、より高適応度を持つ解の探索を効率良く行うことが可能である。

§ 1 コーディングと遺伝子操作オペレータ

TSP に免疫アルゴリズムを適用するためには、抗体を文字列表現する必要がある。免疫アルゴリズムの一評価尺度である濃度は、表現型における類似度から計算される。ここでは、TSP 解の類似度を、都市を巡回する巡回経路の共通度合いと定義する。そこでコーディングには、共通する部分を抽出しやすい構造であるパス表現を用いる。パス表現された遺伝子に交叉操作を適用する際、致死遺伝子を作成しないような手法が必要となる。その手法として、形質の保全にマッチしたサブツアー交換交叉[山村 92]を採用する。また、任意の2都市を交換する突然変異を採用する。

ここで実装したサブツアー交換交叉は以下のように変更したものである。

Step1: 親 A と親 B の交叉部分(サブツアー)をランダムに決定する

Step2: 親 A と親 B の交叉部分が集合として一致しているならば交叉する。

サブツアー交換交叉の例を図10に示す。この交叉によって生まれる子孫1, 2はどちらも親 A と親 B の形質を遺伝していることがわかる。なお、このように修正した交叉方法では、ある一組の親に対し交叉を実行する場合、ランダムに決定されたサブツアーが一致しない場合が極




図 10 サブツアー交換交叉

めて多く、十分にその機能を果たしていない。本実験では、一組の親にランダムなサブツアーの決定を複数回行うことで、交叉数を集団数の 2~3 割程度となるように調整を行った。

§ 2 適応度と類似度

免疫アルゴリズムにおいては、適応度、類似度、濃度、期待値の計算尺度を求める必要がある。濃度と期待値については 3.1 節で定義した式 (1)~(4) を用いる。以下では、TSP における適応度と類似度を定義する。

[適応度]: 解の評価値

$$fitness_i = 1 / (Cost * Cost_w) \quad (5)$$

Cost: 巡回経路長

Cost_w: Cost の重み

[類似度]: 2 つの解に共通する巡回経路の割合

$$ay_{v, w} = common_path / m \quad (6)$$

common_path: 2 つの抗体に共通する順路の都市数

m: 都市数

§ 3 実験設定

提案する記憶機構の有効性を検証するため、二つの実験を設定する。実験 1 では、AMIA をだまし問題に適用し、一度の問題解決で解の特徴が得られることを検証する。具体的には、前述した異なる特徴を持つ二種類の解、C-type と O-type の特徴抽出を試みる。実験 2 では、1) AMIA, 2) 森らにより提案された IA, 3) サブツアー交換交叉を実装した GA, を実験 1 と同一問題に適用し、最大適応度の比較により最適化アルゴリズムとしての性能比較を行う。なお、サブツアー交換交叉を実装した GA との比較を行うため、ここで扱うだまし問題の問題サイズは文献 [山村 92] と同一 (48 都市 TSP) とした。

§ 4 実験 1: シミュレーション設定

特徴抽出が可能であるかを検証するために、初期記憶無しの状態のだまし問題の探索を行う。問題設定を表 1, AMIA のパラメータを表 2 に示す。表 2 において TC の括弧内の値は、局所探索時の閾値であり、TC_{power} を掛けた値となっている。TC_{power} とは、一次記憶機構と二次記憶機構で行う探索の割合を示す閾値を変化させるためのパラメータである。

§ 5 実験 1: 結果と考察

AMIA による探索の結果、各世代毎の最大適応度の推移と記憶細胞 (Mem1~Mem4) およびサブプレッサー細胞

表 1 問題設定

最適解のタイプ	C-type
都市数	48
外円の半径	0.500
内円の半径	0.384
世代数	100000

表 2 AMIA のパラメータ

集団数	200
エリート保存率	0.05
交叉確率	1.0
突然変異確率	0.01
記憶細胞総数	5
サブプレッサー細胞総数	5
TC (記憶用閾値)	0.5 (0.5675)
TAC1 (濃度計算用閾値)	0.9
TAC2 (抑制用閾値)	0.5
MemoryT (テンプレート作成)	0.9
TC _{power}	1.135

細胞 (Sup1~Sup3) へ記憶した世代を図 11 に示す。また、その探索において得られた記憶細胞およびサブプレッサー細胞を図 12 に示す。

図 11 において、Mem1 や Mem2 など記憶細胞に記憶後の最大適応度も安定して上昇していることから、一次記憶機構による記憶細胞を用いた集団の再構成が局所探索として役立っていると考えられる。また、サブプレッサー細胞 Sup1 に記憶後の探索では、Sup1 に対する探索が二次記憶機構により抑制される。その後得られたサブプレッサー細胞 Sup2 や Sup3 は Sup1 よりも低い適応度となっていることから、Sup1 とは別の探索点に収束している、すなわち探索点の移動が実現したと考えられる。次に、図 12 に示した、得られた記憶細胞およびサブプレッサー細胞から記憶内容の検証を行なう。

- [Mem1] 外円を連続して巡回するという最適解 C-type の特徴が現れている。
- [Sup1] Mem1 を用いた局所探索後では最適解 C-type そのものが得られた。その後の探索においては C-type に類似する解の抑制が行われる。
- [Mem2] 外円と内円を交互に巡回するという特徴が現れ始めていることから、C-type の特徴から O-type への特徴へと移行する段階と考えられる。
- [Sup2] Mem2 を用いた局所探索後では局所解 O-




図 11 最大適応度の推移と記憶した世代数

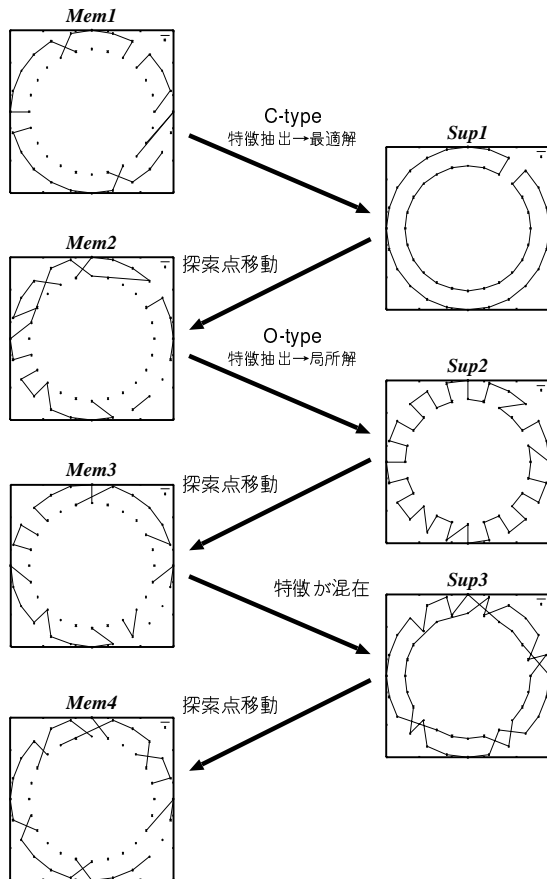


図 12 記憶細胞とサブプレッサー細胞

type に類似した解が得られた。その後の探索においては O-type に類似する解の抑制が行われる。

最適解が得られるのに要した世代数と比較し、局所探索時の世代数に減少が見られた。これは、探索の進行方向を決定する圧力が、選択操作による高期待値の解探索を促進する正の圧力だけでなく、再探索抑制による探索済の探索点から追い出す負の圧力が存在するためと思われる。

- [Sup2 以降] 最適解と局所解への再探索抑制が行われた結果, Mem3, Mem4 や Sup3 は、両方の解に類似していないもしくは両方の特徴が混在した特徴を有している。

Sup2 を獲得する際には世代数の減少が見られたが, Sup3 の場合は逆に増大する傾向が見られた。Sup2 以降の探索では、比較的優良となる二種の解に対する探索が抑制されるため、フィットネス・ランドスケープは低適応度であるピーク群のみから構成されると考えられる。すなわち、あるピークに収束したくても他の探索点へシフトされやすい状態となるため、収束に要する世代数が増大したと思われる。

このような探索動作は、一次記憶機構による特徴の獲得、二次記憶機構による探索点の移動により得られた結果といえる。

§ 6 実験 2：シミュレーション設定

表 1 に示した問題を、1) AMIA, 2) IA, 3) GA, 各々に適用し、その結果を比較する。ここで用いた GA は、4.1.1 節で説明したサブツアー交換交叉および突然変異を採用したものである。また、適応度関数は式 (5) と同一である。GA のパラメータ (集団数, エリート保存率, 交叉確率, 突然変異確率) は表 2 と同じ設定とした。

§ 7 実験 2：結果と考察

実験の結果、3 手法により得られた最大適応度推移の比較を図 13 に示す。IA では探索中に記憶を得られない場合があったため、記憶が得られた場合を memory, 得られなかった場合を no memory として同図に記載している。

- [AMIA と IA (memory)] IA (memory) は、記憶を約 35200 世代で獲得しており、その後から記憶に類似する抗体集合の適応度が下がるため、異なる探索点へシフトしている。そのため、獲得した記憶は最適解に到達していないにも関わらず、より高適応度となる C-type の解の探索を実行できない。

一方、AMIA は、実験 1 で示したように Mem1 を獲得後さらに局所探索を行なうため、より高適応度となる解を探索し続けている。

- [AMIA と IA (no memory)] IA (no memory) の探索動作は GA の単調な右上がりの傾向と類似しており、記憶を得ることが探索動作に与える影響が重要であると分かる。しかし、優位解を獲得しさらに探索点を移動するという両者の条件を満たすように閾値を調整することは非常に困難な問題である。そのため、IA は記憶を獲得出来ない場合がある。

AMIA は、記憶獲得と抑制を独立した機構として実装しており、各々の閾値を適切に設定することが容易である。これにより、安定した記憶獲得を行なうことが可能となった。

- [AMIA と GA] AMIA が Mem1 を獲得する約 850 世代までは、GA とほぼ同じ振舞いを示している。しかし、AMIA は記憶獲得後も適応度が上昇し続けていることから、記憶を活用した局所探索が最適化の面においてより効率の良いものであるといえる。

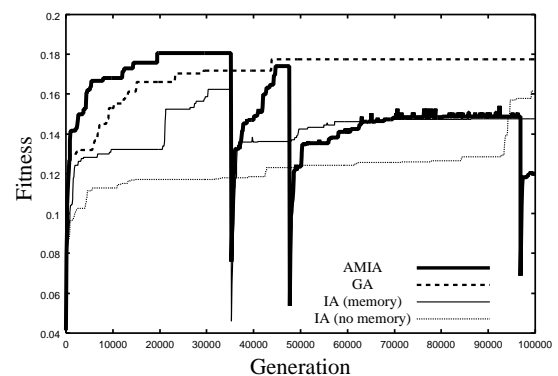


図 13 最大適応度の推移の比較

4.2 Bipolar Deceptive Function ; BDF

Bipolar Deceptive Function とは, Goldberg により多峰性関数の探索能力を検証するために提供された多峰性のだまし関数であり, 多数の大域的・局所的最適解を持つ [Goldberg 92]. 特に, 計算機実験では, 6-bit Bipolar Deceptive Function (以下, 6-bit 問題とする) を五つ結合して作成した 30-bit 問題を扱う.

6-bit 問題 (図 14 上) は, 低次 Walsh 係数を用いて作成した関数 (式 (7)) であり, 2 個の大域的最適解と, 20 個の局所的最適解を含む多峰性関数である. 6-bit 問題を結合して作成した 30-bit 問題 (図 14 下) は, $2^5 = 32$ 個の大域的最適解と, $(20+2)^5 =$ 約 500 万個の局所的最適解を有する. 式 (7) で用いた各パラメータ値は, 文献 [Goldberg 92] と同一な値 ($2l = 6, w_0 = 0.4350960, w_2 = -0.020048, w_4 = 0.060024$) を採用した. また, 式 (7) において $\lambda = 2l$ とおくと, 6-bit 問題における適応度関数 $f(u)$ となる.

$$f(u, \lambda, 2l) = \sum_{i=0}^{\lambda} w_i \psi'_i(u, \lambda) \quad (7)$$

- u : 1 の数 (unitation)
- λ : 関数のオーダー
- $2l$: 関数のサイズ (6-bit)
- w_i : Walsh 係数
- ψ'_i : Walsh 係数 w_i から作成した Walsh 関数

$$\psi'_i(u, \lambda) = \sum_{j=0}^i (-1)^j \binom{u}{j} \binom{\lambda - u}{i - j} \quad (8)$$

§1 コーディングと遺伝子操作オペレータ

免疫アルゴリズムを 30-bit 問題へ適用するため, コーディングとしてバイナリ・ストリング, 遺伝子操作オペレータとして一点交叉, 突然変異を採用した.

$$solution_i = \sum_{j=0}^N sub_solution_{i_j} \quad (9)$$

- $sub_solution_{i_j}$: 6-bit binary string
- N : 6-bit 問題の結合数

§2 適応度と類似度

適応度は, 30-bit のバイナリ・ストリングを 6-bit に分割し, 各々分割したストリング毎に 6-bit 問題における

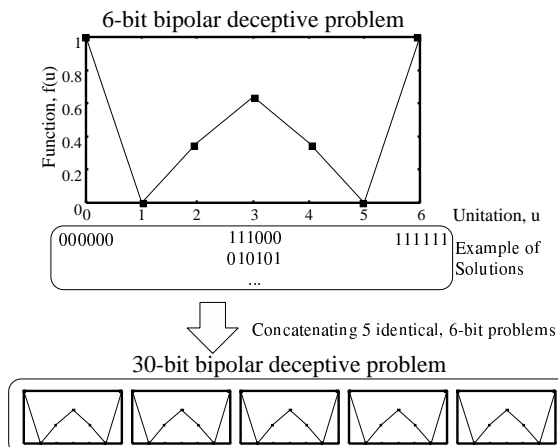


図 14 30-bit 問題

適応度を求め, それらの総和を計算する (式 (10)). 類似度はハミング距離を用いた (式 (11)). 濃度と期待値については 3.1 節で定義した式 (1)~(4) を用いる.

[適応度]: 解 i の評価値

$$fitness_i = \sum_{j=0}^N f(u_{i_j}) \quad (10)$$

- u_{i_j} : $sub_solution_{i_j}$ に含まれる 1 の数
- $f(u_{i_j})$: 式 (7) (ただし, $\lambda = 2l$)

[類似度]: 2 つの解 v, w に共通する遺伝子の割合

$$ay_{v, w} = 1 / (1 + H(v, w)) \quad (11)$$

- $H(v, w)$: 解 v と w のハミング距離

§3 実験 3: シミュレーション設定

多峰性関数における探索能力を検証するため, IA と AMIA を 30-bit 問題へ適用し, 比較検証・考察を行う. AMIA のパラメータを表 3 に示す.

§4 実験 3: 結果と考察

30-bit 問題は図 14 に示したように, 最適解近辺の平均適応度よりも局所解近辺がより高いため, 探索点が局所解へ収束しやすいだまし問題である. そのような多峰性関数にも関わらず, 二つの手法とも 32 個全ての大域的最適解を獲得できた. そして, 全最適解の獲得に要した平均世代数は, AMIA で約 14 万世代, IA で約 21 万世代を要した. また, 最終世代までに獲得した優位解の平均個数は, AMIA で約 220 個, IA で約 40 個であった. これらの結果より, 多峰性関数における複数最適解を獲得する探索手法として, AMIA がより優れたアルゴリズムであることを示した.

次に, IA と AMIA の各世代毎の最大適応度の推移および, 獲得したサブレッサ細胞 (図 15 では Sup) の適応度と世代数を図 15 に示す. 同図より, AMIA は全ての大域的最適解 (適応度 5.0) を獲得する前に, 次に高い適応度 (4.640576) を持つ準最適解を獲得している. 特に, 約 1400 世代目・2300 世代目・3800 世代目に獲得したサブレッサ細胞は, 探索中に大域的最適解を発見しているにも関わらず, 準最適解である. 一方, IA は多くの場合, 探索中に大域的最適解を発見した場合, それをサブレッサ細胞として獲得している. しかしながら, この準最適解の探索に要した世代数を含めても, AMIA が IA より少ない世代で全ての大域的最適解を発見している. よって, AMIA の探索動作は, 局所探索を用いた

表 3 AMIA のパラメータ

集団数	100
エリート保存率	0.05
交叉確率	0.9
突然変異確率	0.01
記憶細胞総数	1000
サブレッサ細胞総数	1000
TC (記憶用閾値)	0.25 (0.375)
$TAC1$ (濃度計算用閾値)	0.6
$TAC2$ (抑制用閾値)	0.96
$MemoryT$ (テンプレート作成)	0.6
TC_{power}	1.5
終了世代数	300000




図 15 獲得した記憶の適応度と世代数の推移

ことにより準最適解への収束可能性が高くなるが、それ以上に複数最適解獲得に要する世代数が減少し、また獲得した優位解の数が約 5 倍近いことから、多峰性関数における探索手法として有効であると結論づけられる。

§ 5 パラメータ調整に関する実験と考察

IA や AMIA の探索動作はパラメータ ($TC, TAC1, TAC2$) 値に大きく依存するため、それを適切に設定する必要がある。その点、AMIA は IA と比較した場合パラメータ値による影響が少ないため、その調整が容易である。その容易さを検証するため、 TC を 0.05~0.40 まで 0.05 刻みで変更し、他のパラメータを表 3 と同一とした場合の AMIA と IA における獲得する候補解の違いを比較した。なお、 TC_{POWER} は、 TC に乗じた結果が 0.375 (表 3 の TC 欄、括弧中の値) となるように設定している。

図 16 は、横軸を候補解を獲得した世代数、縦軸を獲得した候補解の適応度とし、両手法の獲得した候補解の適応度推移を示している。また各推移図の右下の数値は、




図 16 TC の違いによる探索結果

「候補解に含まれている最適解の個数 / 獲得した候補解の個数」を意味する。なお、個数が X と記述されている結果は、論文中の表 3 で設定した記憶細胞総数やサブプレッサー細胞総数を越えたことを表している。

実験の結果、AMIA は全ての TC 値において適応度 4 以上となる優位解を獲得可能しており、パラメータ設定が容易であることが検証できた。同じ設定における IA の結果は、 TC が 0.05~0.15 という低い値では適応度が 4 未満の解までも獲得しており、優位解獲得が有効に機能していなかった。

5. おわりに

適切な記憶を獲得するためのパラメータ設定が困難である IA に対し、その調節の簡単化および局所探索能力の付加による探索効率化を行なう探索アルゴリズム AMIA を提案した。AMIA は、優位解の記憶と探索点のシフトを二種類の記憶機構で個別に行なうため、パラメータ調整が容易である。実験では、AMIA による解の特徴抽出が可能であることを検証した。さらに、AMIA を用いた探索では、高適応度の解探索可能性、記憶獲得の安定性、局所探索による探索効率化を実現したことを比較実験により示した。このことから本アルゴリズムは、多峰性関数である種々の課題に対して有効に機能すると考えられる。

謝 辞

本論文を執筆するにあたり、Lymphocyte Biology Section, Laboratory of Immunology, National Institute of Allergy and Infectious Diseases, National Institutes of Health, Bethesda MD 20892 の伊藤靖氏から、免疫学における適切な御指摘を頂いた。また、人工免疫の設計・応用に関し、北海道大学大学院工学研究科システム情報工学専攻複雑系工学講座調和系工学分野の皆様から、貴重な御意見、御討論を頂いた。ここに謝意を表する。

本研究は、文部省科学研究費(課題番号 10780240)の補助を受けて行った。

◇ 参 考 文 献 ◇

[Back 97] T.Back (editor): "Proceedings of The Seventh International Conference on Genetic Algorithms, Morgan Kaufmann" (1997).
 [Bersini 91] H.Bersini and F.J.Varela: "The Immune Recruitment Mechanism: A Selective Evolutionary Strategy", Proc. of ICGA 91, (1991).
 [Dasgupta 99] D.Dasgupta (editor): "Artificial Immune Systems and Their Applications" (1999).
 [Forrest 90] S.Forrest and A.S.Perelson: "Genetic Algorithm and the Immune System", Proc. of PPSN 90, pp.320-325, (1990).
 [Goldberg 92] D.E.Goldberg, K.Deb, and J.Horn: "Massive Multimodality, Deception, and Genetic Algorithms", PPSN 2 (1992).
 [Holland 92] J.H.Holland: "Adaptation in Natural and Artificial Systems", MIT Press (1992).

- [Ishida 90] Y.Ishida : “Fully Distributed Diagnosis by PDP Learning Algorithm : Towards Immune Network PDP Model”, Proc. of IJCNN 90, pp.777-782 (1990) .
- [Ishida 96] Y.Ishida and N.Adachi : “Active Noise Control by an Immune Algorithm : Adaptation in Immune System as an Evolution”, Pro. ICEC 96, pp.150-153 (1996) .
- [Russell 95] S.Russell and P.Norvig : “Artificial Intelligence: A Modern Approach”, Prentice-Hall (1995) .
- [石黒 97] 石黒 章夫, 近藤 敏之, 渡邊 裕司, 白井 靖浩, 内川 嘉樹 : “免疫ネットワークに基づく自律移動ロボットの分散型行動調停機構の創発的構築に関する一手法”, 電学論 C, 117 巻 7 号 (1997) .
- [石田 98] 石田 好輝 : “免疫型システムとその応用 -免疫系に学んだ知能システム-”, コロナ社 (1998) .
- [北野 93] 北野 宏明 : “遺伝的アルゴリズム”, 産業図書株式会社 (1993) .
- [高橋 98] 高橋 和彦, 山田 孝行 : “免疫機構のニューラルネットワークの学習への適用に関する一考察”, 第 8 回インテリジェント・システム・シンポジウム, pp.369-372 (1998) .
- [多田 93-a] 多田 富雄 : “免疫の意味論”, 青土社 (1993) .
- [多田 93-b] 多田 富雄, 谷口 克, 奥村 康, 宮坂 昌之 : “免疫学用語辞典 第三版”, 最新医学社 (1993) .
- [藤原 97] 藤原 道夫 : “コア免疫学”, 丸善株式会社 (1997) .
- [森 93] 森 一之, 築山 誠, 福田 豊生 : “多様性を持つ免疫的アルゴリズムの提案と負荷割り当て問題への応用”, T.IEE Japan, Vol.133-C, No.10, pp.872-878 (1993) .
- [森 97] 森 一之, 築山 誠, 福田 豊生 : “免疫アルゴリズムによる多峰性関数最適化”, T.IEE Japan, Vol.117-C, No.5, pp.593-598 (1997) .
- [山本 97] 山本 芳嗣, 久保 幹雄 : “シリーズ [現代人の数理]12 巡回セールスマン問題への招待”, 朝倉書店 (1997) .
- [山村 92] 山村 雅幸, 小野 貴久, 小林 重信 : “形質の遺伝を重視した遺伝的アルゴリズムに基づく巡回セールスマン問題の解法”, 人工知能学会誌, Vol.7, No.6, Nov, pp.117-127 (1992) .
- [和田 92] 和田 健之介, 和田 佳子 : “山登り飛び虫の進化と免疫システム論について”, 数理科学, NO.353, NOVEMBER, pp.12-23 (1992) .

(担当委員 : XXOO)

19YY 年 MM 月 DD 日 受理

著者紹介

菅間 愛晃(学生会員)

1998 年 3 月琉球大学工学部卒業, 2000 年 3 月琉球大学大学院理工学研究科博士前期過程修了, 現在, 日本学術振興会特別研究員として琉球大学大学院理工学研究科総合知能工学専攻に在学. 情報処理学会, 人工知能学会各学生会員.

遠藤 聡志(正会員)

1990 年北海道大学大学院工学研究科電気工学専攻修士課程修了. 同年, 北海道大学工学部情報工学科助手, 1995 年琉球大学工学部情報工学科講師を経て現在琉球大学工学部情報工学科助教授, システム工学, 複雑系工学の研究に従事. 情報処理学会, 計測自動制御学会, 人工知能学会各会員.

山田 孝治(正会員)

1995 年 3 月, 北海道大学大学院工学研究科博士後期課程修了. 博士(工学). 同年, 琉球大学工学部情報工学科助手, 1996 年同講師, 1999 年同助教授. 知能ロボットに関する研究に従事. 人工知能学会, 情報処理学会, 機械学会, ロボット学会各会員.