



Title	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性能評価
Author(s)	當間, 愛晃; 遠藤, 聡志; 山田, 孝治; 宮城, 隼夫
Citation	琉球大学工学部紀要(60): 113-118
Issue Date	2000-09
URL	http://hdl.handle.net/20.500.12000/14691
Rights	

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性能評価

當間 愛晃*, 遠藤 聡志**, 山田 孝治**, 宮城 隼夫**

Performances Evaluation of an Adaptive Memorizing Immune Algorithm
with Two Memory Mechanisms

Naruaki TOMA*, Satoshi ENDO**, Koji YAMADA** and Hayao MIYAGI**

Abstract

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. Before now, we proposed an Adaptive Memorizing Immune Algorithm (AMIA) with two memory mechanisms for optimizing multimodal functions. In this paper, we evaluate following two performances of the AMIA. First, we apply the AMIA to a 30-bit bipolar deceptive function to investigate a easiness of adjusting parameters for AMIA. Second, the AMIA is applied to Shubert function for clarifying a good performance for multimodal functions.

Key Words: genetic algorithm, adaptive memorizing immune algorithm, performance evaluation, multimodal function, bipolar deceptive function, Shubert function.

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 [11], [8], [5], [7].

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 [2], [9], [10], [12], [14]. 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 [6] や, 多峰性関数最適化 [15], [16], 一個体による多機能型適応システム [17] 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 [3] や, 親和度を用いた抗体産生を調節する枠組の定式化した [1] 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プ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.

これまでに, 我々は, 免疫システムの優れた生体反応である免疫応答や記憶機構に基づいた二種類の記憶を構築し, それを IA に導入することで, 前述のパラメータ調整の困難性を解消し, さらに多峰性関数における複数最適解獲得をより効率良く行う適応的免疫アルゴリズム (Adaptive Memorizing Immune Algorithm : 以下, AMIA) を提案してきた [13]. 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,

1. 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,
2. 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. 本研究では, 上述の

受理: 2000年6月5日

*大学院理工学研究科総合知能工学専攻

(Doctoral Course in Complex Intelligent Systems Engineering, Graduate School of Science and Engineering)

**工学部情報工学科

(Dept. of Information Engineering, Fac. of Eng.)

2つの特徴を検証するため、提案手法をBipolar Deceptive Function[4]、およびShubert関数へ適用し、考察する。

2. 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AMIAの概要を述べる。なお、単に“免疫アルゴリズム”とした場合は、IA[15]、[16]とAMIA両者を指す。

2.1 免疫的最適化

一般的な組合せ問題の適応度地形は、Fig.1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、一つの最適解のみならず、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。




Fig. 1. 多峰性関数と免疫的最適化

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（Fig.1）。

- 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。

2.2 適応的免疫アルゴリズム (AMIA)

二種類の記憶機構をStep4に導入した適応的免疫アルゴリズムAMIAを以下に示す。

- [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 ($Step4_{Mem}$) またはサプレッサー細胞 ($Step4_{Sup}$) へ分化する。この時、通常探索中であれば $Step4_{Mem}$ 、局所探索中であれば $Step4_{Sup}$ へ分化する。なお、初期状態では通常探索中とする。
 - [$Step4_{Mem}$. 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。
 - [$Step4_{Sup}$. 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。

2.3 記憶機構

2.3.1 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 (Fig.2)。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。

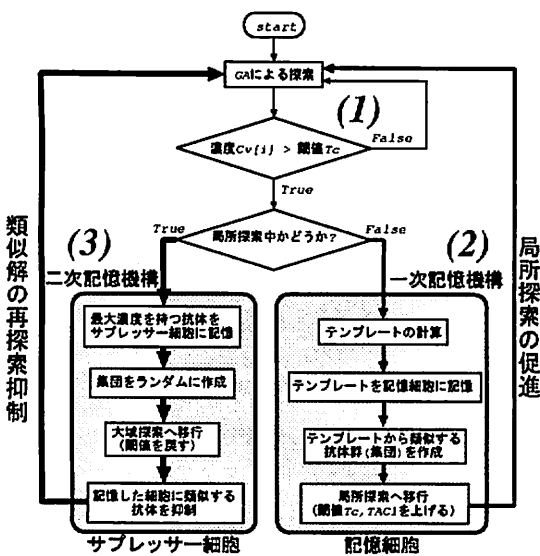


Fig. 2. 記憶機構

2.3.2 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 Fig.3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。




Fig. 3. 一次記憶機構

2.3.3 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 (Fig.4)。

[Step1. 最大濃度の抗体をサブプ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プ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。

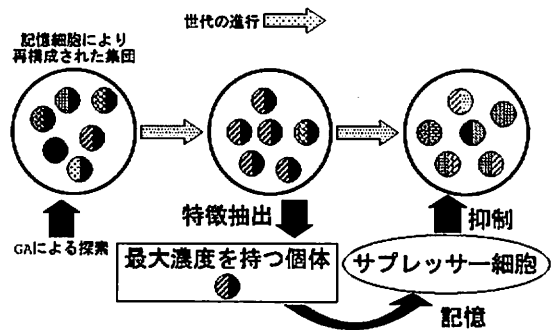


Fig. 4. 二次記憶機構

3. 計算機実験

計算機実験により AMIA の性能評価を行う。評価内容および評価対象問題は以下の通りである。

実験1: 本手法におけるパラメータ調整の容易さを検証するため、Bipolar Deceptive Function を評価問題とし、AMIA と IA におけるパラメータ値の違いが探索動作に与える影響を調査し、比較・検討を行う。

実験2: [13] ではだまし問題のみを評価問題としたが、だましを含まない多峰性関数においても本手法が有効

に機能することを検証することでその結果の一般性を高める。その評価対象として、連続値を扱う Shubert 関数へと適用し、検証する。

3.1 実験1: Bipolar Deceptive Function

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[4]。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 (Fig.5上) は、低次 Walsh 係数を用いて作成した関数 (式5) 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 (Fig.5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5で用いた各パラメータ値は、文献[4]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5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。なお、30-bit 問題は、最適解とそれに準ずる解といった適応度が明確であるという特徴を持つため、30-bit 問題に適用することにより、そのような数多くの候補解をどのように獲得し、また全ての最適解を獲得可能かどうかを検証するための評価問題として非常に有効な評価問題である。

$$f(u, \lambda, 2l) = \sum_{i=0}^{\lambda} w_i \psi'_i(u, \lambda) \tag{5}$$

- 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

$$\psi'_i(u, \lambda) = \sum_{j=0}^i (-1)^j \binom{u}{j} \binom{\lambda - u}{i - j} \tag{6}$$




Fig. 5. 30-bit 問題

3.1.1 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。

$$solution_i = \sum_{j=0}^N sub_solution_{ij} \tag{7}$$

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

3.1.2 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 問題における適応度を求め、それらの総和を計算する (式8)。類似度はハミング距離を用いた (式9)。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

$$fitness_i = \sum_{j=0}^N f(u_{ij}) \tag{8}$$

- u_{ij} : $sub_solution_{ij}$ に含まれる 1 の数
- $f(u_{ij})$: 式5 (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

$$ay_{v, w} = 1 / (1 + H(v, w)) \tag{9}$$

- $H(v, w)$: 解 v と w のハミング距離

3.1.3 シミュレーション設定 AMIA や IA 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 Table2 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 (Table2 の TC 欄、括弧中の値) となるように設定している。Table1 に、 TC, TC_{POWER} の設定例を示した。また、IA と AMIA で用いた他のパラメータは Table2 の通りである。

Table 1. TC, TC_{POWER} の設定

TC for IA, AMIA	0.05	0.15	0.25	0.35
TC_{POWER} for AMIA	7.5	2.5	1.5	1.0714

3.1.4 結果と考察 まず、30-bit 問題が有する全ての最適解を獲得可能であることを検証するため、終了世代数 30 万世代として AMIA と IA を適用した。30-bit 問題は Fig.5 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

Table 2. AMIA・IA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
サプレッサー細胞総数	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	10000

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、TCパラメータの違いが探索動作に与える影響を検証するため、Table1のようにパラメータ値を変え、各々の探索動作を検証した。Fig.6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、「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Table2で設定した記憶細胞総数やサ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。以上の結果より、AMIAはIAと比較した場合、パラメータTC値が探索動作に及ぼす影響が非常に小さいため、パラメータ調整が容易となっていることが検証できた。

3.2 実験2: Shubert関数

[13]においては、二つのだまし問題(TSP, 30-bit問題)を対象として探索動作および性能評価の検証を行った。本稿では、新たな評価対象問題として、(1)だまし問題ではなく、また、多峰性関数におけるより一般性の高い性能評価を行うために、本論文では扱っていない、(2)連続値を扱う関数であるShubert関数を採用した。Shubert関数(式10)は、IAを提案した森らが性能評価問題として採用した評価問題でもあり、18個の最適解を有する多峰性の関数である。

$$f(x, y) = -\left(\sum_{i=1,5} i \cos((i+1)x + i)\right) \times \left(\sum_{i=1,5} i \cos((i+1)y + i)\right) \quad (10)$$

ただし、 $-10 \leq x, y \leq 10$

3.2.1 コーディングと遺伝子操作オペレータ IA・AMIAをShubert関数へ適用するため、コーディングとして実数値x, yを21ビットで表現した42ビットのバイナリ・ストリング、遺伝子操作オペレータとして一点交叉、突然変異を採用しました。

3.2.2 適応度と類似度 適応度関数はShubert関数式(式10)をそのまま用い、類似度関数は30-bit問題でも設定したハミング距離を用いた式9として設定した。

3.2.3 シミュレーション設定 以上の設計に基づき、IA・AMIAで用いるパラメータをTable3として設定し、性能評価実験を行った。

Table 3. IA・AMIAのパラメータ

集団数	100
エリート保存率	0.10
交叉確率	0.6
突然変異確率	0.05
記憶細胞総数	100
サプレッサー細胞総数	100
TC (記憶用閾値)	0.30 (0.39)
TAC1 (濃度計算用閾値)	0.3
TAC2 (抑制用閾値)	0.65
MemoryT (テンプレート作成)	0.6
TC _{power}	1.3
終了世代数	2000

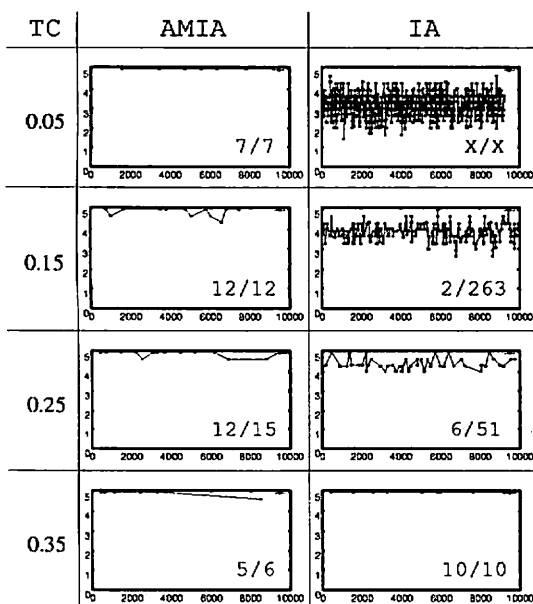


Fig. 6. TCの違いによる探索結果

3.2.4 結果と考察 AMIA と IA を Shubert 関数へ適用した結果、二つの手法ともに全ての最適解を獲得できた。Fig.7は、AMIA が獲得した候補解の例を示しており、候補解が最適解近辺に集中していることが確認できる。また、終了世代数までに獲得した候補解の個数は、AMIA で平均56.8個、IA で平均38.8個であった。

次に、その候補解を獲得した探索動作の違いを検証するため、候補解獲得の様子を Fig.8に示した。Fig.8は、横軸に世代数、縦軸に獲得した記憶の適応度をとっており、獲得した適応度の適応度推移を観察することができる。同図より、AMIA は全ての最適解を獲得する前に準最適解を獲得しているのが確認できる。しかし、30-bit 問題と同様に、獲得した準最適解は非常に高い適応度を示していることから非常に優れた優位解であり、また、そのような準最適解の獲得に要した世代数の点でも IA と比較して優位な結果を示している。従って、AMIA の候補解獲得効率、分散値のだまし関数だけでなく、連続値を扱う Shubert 関数においても優れた性能を示したことから、本手法が多峰性関数一般において有効に機能するものと考えられる。




Fig. 7. AMIA により獲得した候補解の例

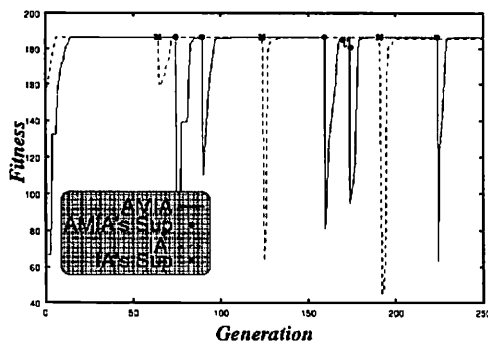


Fig. 8. 獲得した候補解の適応度と世代数の推移

4. おわりに

本研究では、二種類の記憶機構を導入することで、パラメータ調整を容易とし、さらに探索効率を向上させた AMIA の性能評価実験を行った。計算機実験では、(1) AMIA・IA をパラメータ TC 値を変えて 30-bit 問題に適用し、その探

索動作の違いから AMIA が適切に動作するためのパラメータ値調整が容易であることを検証し、また、(2) AMIA・IA を連続値を扱う多峰性関数である Shubert 関数へ適用し、AMIA が多峰性関数一般において有効に機能することを検証した。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。

本研究は、平成12年度科学研究費補助金（特別研究員奨励費）の補助を受けて行った。

文献

- [1] H.Bersini and F.J.Varela : "The Immune Recruitment Mechanism : A Selective Evolutionary Strategy", Proc. of ICGA 91, (1991) .
- [2] D.Dasgupta (editor) : "Artificial Immune Systems and Their Applications" (1999) .
- [3] S.Forrest and A.S.Perelson : "Genetic Algorithm and the Immune System", Proc. of PPSN 90, pp.320-325, (1990) .
- [4] Devid E. Goldberg, Kalyanmoy Deb, and Jeffrey Horn : "Massive Multimodality, Deception, and Genetic Algorithms", PPSN 2 (1992) .
- [5] John H. Holland : "Adaptation in Natural and Artificial Systems", MIT Press (1992) .
- [6] Y.Ishida : "Fully Distributed Diagnosis by PDP Learning Algorithm : Towards Immune Network PDP Model", Proc. of IJCNN 90, pp.777-782 (1990) .
- [7] Stuart Russell and Peter Norvig : "Artificial Intelligence: A Modern Approach", Prentice-Hall (1995) .
- [8] Thomas Back (editor) : "Proceedings of The Seventh International Conference on Genetic Algorithms, Morgan Kaufmann" (1997) .
- [9] 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) .
- [10] 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) .
- [11] 北野 宏明 : "遺伝的アルゴリズム", 産業図書株式会社 (1993) .
- [12] 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) .
- [13] 常間 愛晃, 遠藤 聡志, 山田 孝治 : "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", 人工知能学会, 投稿中 (2000) .
- [14] 多田 富雄 : "免疫の意味論", 青土社 (1993) .
- [15] 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) .
- [16] 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) .
- [17] 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) .