1　はじめに

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, Thomas97, Holland92, Russell95]．

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 [Dasgupta99, 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最適化手法として捉えた研究例として，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] などがある．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．

本稿では，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 [Endo98]．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，多峰性関数である Bipolar Deceptive Function（以下，BDF）[Goldberg92] 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．

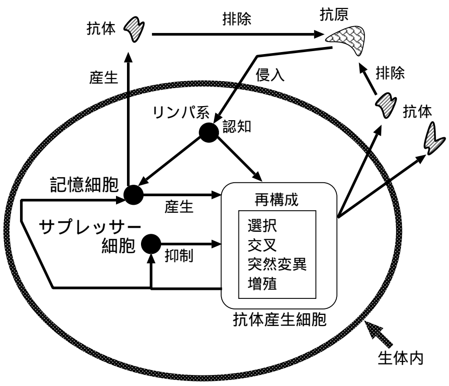

図 1: 免疫システム

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]．

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．

3　免疫アルゴリズム

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．通常の最適化では，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．そこで，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．

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．適応度と類似度の計算式は問題に固有の設定である．

[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

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

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

- $PopSize$: 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

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

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

- 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

3.2 IA の特長と問題点

森らにより提案された 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．

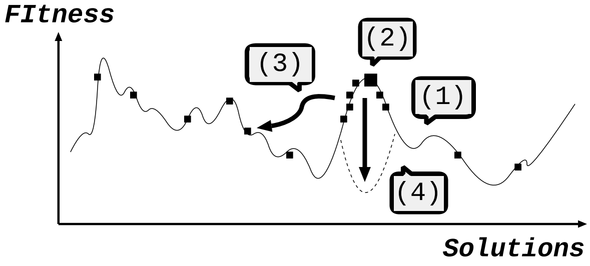

図 2: 多峰性関数と免疫的最適化

(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．

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 3 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 を越えた場合に記憶を行う．通常探索中であれば一次記憶機構，局所探索中であれば二次記憶機構へ分化する．

- **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．
- **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．

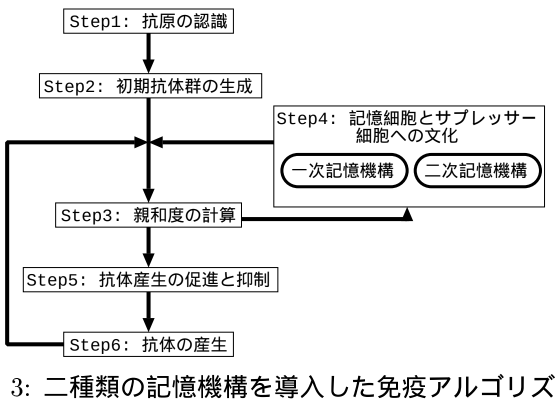

図 3: 二種類の記憶機構を導入した免疫アルゴリズム

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

3.4.1 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4）．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．このように，一次記憶機構と二次記憶記憶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

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．

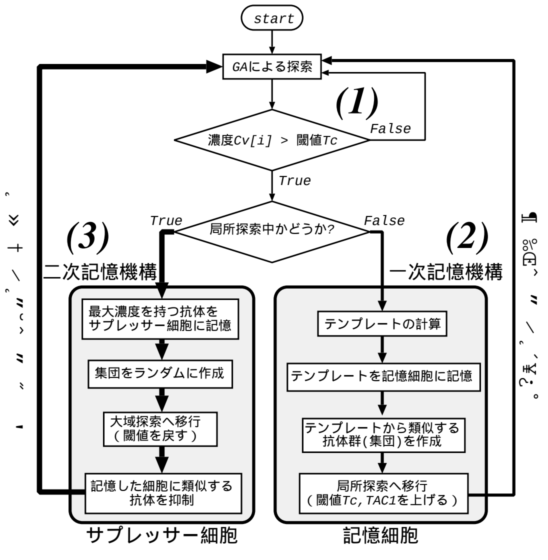

図 4: 記憶機構

3.4.2 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5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．

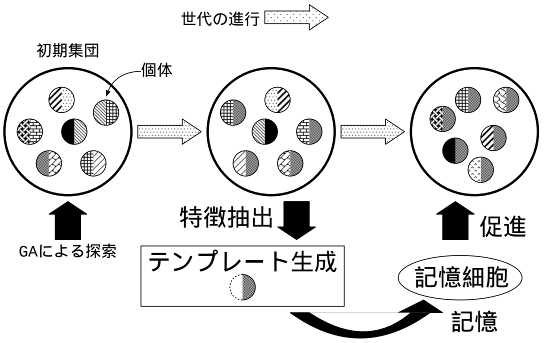

図 5: 一次記憶機構

3.4.3 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6）．

[Step1. 最大濃度の抗体をサ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．

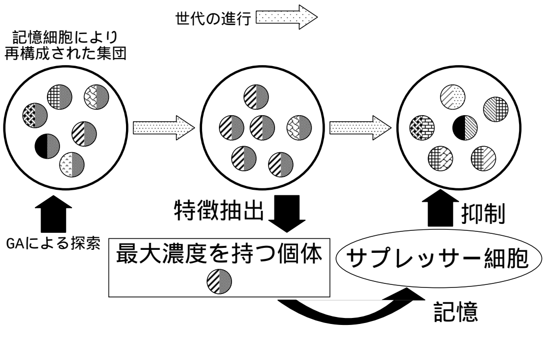

図 6: 二次記憶機構

4　計算機実験

4.1　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 [Goldberg92]．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 7 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（図 7 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 [Goldberg92] 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．

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

- 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

$$\psi'_i(u,\lambda) = \sum_{j=0}^{i} (-1)^j \begin{pmatrix} u \\ j \end{pmatrix} \begin{pmatrix} \lambda - u \\ i - j \end{pmatrix} \qquad (6)$$

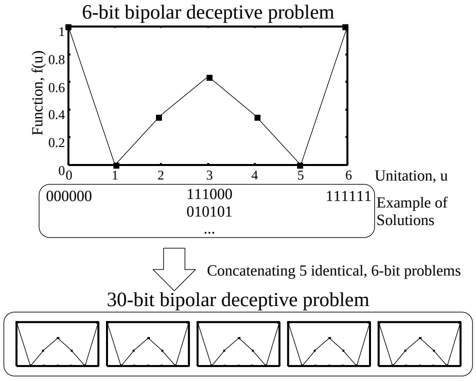

図 7: 30-bit 問題

4.1.1　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．

$$solution_i = \sum_{j=0}^{N} sub\_solution_{i_j} \qquad (7)$$

- $sub\_solution_{i_j} =$ 6-bit binary string
- N: 6-bit 問題の結合数

4.1.2　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

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

- u_{i_j}: $sub\_solution_{i_j}$ に含まれる 1 の数
- $f(u_{i_j})$: 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

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

- $H(v,w)$: 解 v と w のハミング距離

4.1.3　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 1 に示す．

4.1.4　実験 3：結果と考察

30-bit 問題は図 7 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，獲得したサプレッサー細胞（図 8 では Sup）の適応度と世代数を図 8 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プレッ

表 1: 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	300000

サー細胞は，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，それをサプレッサー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．

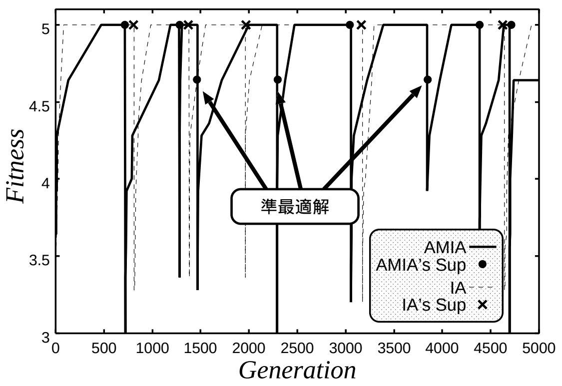

図 8: 獲得した記憶の適応度と世代数の推移

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

[Dasgupta99] D.Dasgupta (editor) : “Artificial Immune Systems and Their Applications” (1999).

[Goldberg92] Devid E. Goldberg, Kalyanmoy Deb, and Jeffrey Horn : “Massive Multimodality, Deception, and Genetic Algorithms”, PPSN 2 (1992).

[Holland92] John H. Holland : “Adaptation in Natural and Artificial Systems”, MIT Press (1992).

[Russell95] Stuart Russell and Peter Norvig : “Artificial Intelligence: A Modern Approach”, Prentice-Hall (1995).

[Endo98] Satoshi Endo, Naruaki Toma, Koji Yamada : “Immune Algorithm for n-TSP”, SMC’98 Conference Proceedings, pp.3844-3849.

[Thomas97] Thomas Back (editor) :“Proceedings of The Seventh International Conference on Genetic Algorithms, Morgan Kaufmann” (1997).

[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).

[藤原 97] 藤原 道夫 :“コア免疫学”，丸善株式会社 (1997).

[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).

[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).