

適応的免疫アルゴリズムを用いた
多峰性関数最適化に関する研究

平成11年度 修士論文

琉球大学大学院理工学研究科
情報工学専攻

當間 愛晃

目次

第1章	序論	1
第2章	免疫システム	4
2.1	緒言	4
2.2	免疫システムの概要	5
2.3	工学モデルとしての免疫システム	7
2.3.1	抗原と抗体	7
2.3.2	一次免疫応答と二次免疫応答	8
2.3.3	抑制機構	8
2.3.4	免疫システムを用いた探索アルゴリズム	9
2.4	結言	9
第3章	多峰性関数最適化	11
3.1	緒言	11
3.2	多峰性関数最適化	12
3.3	従来の複数最適解獲得手法	13
3.3.1	遺伝的アルゴリズム	13
3.3.2	シェアリング法	14
3.3.3	すみ分け型アルゴリズム	16
3.3.4	免疫的最適化	17
3.3.5	免疫アルゴリズム	18
3.4	多峰性関数における複数最適解獲得	20
3.5	結言	21
第4章	適応的免疫アルゴリズム	22
4.1	緒言	22
4.2	IAの特長と問題点	22
4.3	適応的免疫アルゴリズム (AMIA)	24
4.4	AMIAに導入した記憶機構	25
4.4.1	記憶機構の特徴と動作概念	25
4.4.2	一次記憶機構	28
4.4.3	二次記憶機構	29
4.5	結言	30

第 5 章	計算機実験	31
5.1	緒言	31
5.2	巡回セールスマン問題 (TSP)	31
5.2.1	コーディングと遺伝子操作オペレータ	32
5.2.2	適応度と類似度	33
5.2.3	実験設定	34
5.2.4	実験 1 : シミュレーション設定	34
5.2.5	実験 1 : 結果と考察	34
5.2.6	実験 2 : シミュレーション設定	37
5.2.7	実験 2 : 結果と考察	38
5.2.8	実験 1 と実験 2 のまとめ	39
5.2.9	Java を用いたシミュレータ作成	39
5.3	Bipolar Deceptive Function (BDF)	39
5.3.1	コーディングと遺伝子操作オペレータ	41
5.3.2	適応度と類似度	41
5.3.3	実験 3 : シミュレーション設定	42
5.3.4	実験 3 : 結果と考察	42
5.3.5	実験 3 のまとめ	43
5.4	結言	44
第 6 章	免疫システムのマルチエージェントシステムへの応用	45
6.1	緒言	45
6.2	マルチエージェントシステムと分業効率化	45
6.3	分業効率化システムとしての免疫システム	46
6.3.1	抗原と抗体	46
6.3.2	MHC	47
6.3.3	免疫ネットワーク	48
6.4	結言	49
第 7 章	免疫的分業効率化アルゴリズム	50
7.1	緒言	50
7.2	免疫的分業効率化	50
7.2.1	免疫的分業効率化アルゴリズム	50
7.2.2	競合処理	51
7.2.3	動作概念と特徴	52
7.3	結言	53
第 8 章	計算機実験 2	54
8.1	緒言	54
8.2	分業巡回セールスマン問題 (nTSP)	54
8.2.1	TSP と nTSP	54

8.2.2	分業と最適化	54
8.2.3	nTSP における免疫的分業効率化アルゴリズムの動作	55
8.2.4	適応度関数と類似解作成手法の設計	56
8.3	実験設定	57
8.3.1	問題設定	57
8.3.2	結果と考察	58
8.4	結言	62
第 9 章	結論	63
	謝辞	65
	参考文献	66
付録 A	研究業績	70
A.1	学術講演	70
A.2	紀要	71

第1章 序論

オペレーションズ・リサーチの研究分野の一つである最適化問題とは、与えられた問題を最良の手段で解決したいと考えた場合に必ず直面する課題であるため、あらゆる工学モデルの基礎となる重要な研究分野として認知されている [Goldberg 1989, Holland 1992, 北野 1993, 坂和 1995, 三宮 1998] .

初期の最適化問題で取り扱った問題は、主に線形性や連続性という性質を有する目的関数であり、このような関数における最適化手法としては、近傍における連続性を解法に応用したシンプレックス法に代表される線形計画法や、微分概念に基づいた山登り法 (Hill Climbing) などが有効であった。一方、目的関数が不連続集合であったり、また解空間が離散集合であった場合には、近傍における連続性を解法に利用することができないため、真の最適解を発見することは非常に困難である。このように、解空間が離散集合であり、多峰性を有する、典型的な問題は組合せ最適化問題と呼ばれている。その問題に対する解法は、得られる解の最適性に注目すると、最適解を求めるための厳密解法と、近似的な最適解 (局所解や準最適解) を高速に求める近似解法に大別される。本論文では、後者の近似解法により多峰性関数最適化を行う立場をとる。

多峰性関数における近似解法としては、生物の情報処理にヒントを得た情報システムが盛んに研究されている。ニューラルネットワーク (Neural Network, NN)、遺伝的アルゴリズム (Genetic Algorithm, 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 [Holland 1992, Russell 1995, Thomas 1997, 北野 1993] .

また、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 1999, 石黒 1997, 石田好輝 1998, 高橋 1998, 多田 1993-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 1993, 森 1997]、一個体による多機能型適応システム [和田 1992] など、様々な分野において適用され、工学モデルとしての応用可能性が論じられている。

このように、最適化問題は古くから研究されているが、一方では、経済の発展と共に対象とする問題がより複雑さを増し、それに追従するように要求される解の性質も変化してきた。特に、多目的の最適化問題では、目的関数に設計者の意図を反映させることが困難であり、厳密な最適解が得られたとしてもその解が設計者の意図しないものである可能性もある。すなわち、予め設計された問題の最適解を発見するだけではそれを利用する側にとって不十分であり、別の解法が強く求められている。このように、問題の変化にも対応できるような解 (ロバスト解) を獲得するための一つの答えが「一度の問題解決で複数の

最適解を獲得することである。これにより、複数の代替案から実行する解を選択する余地を残すことが可能となる。

従来の複数最適解を獲得する手法としては、シェアリング (Sharing) 法 [Goldberg 1987, Goldberg 1992] や、すみ分け型アルゴリズム [島 1995-a, 島 1995-b] , が提案されているが、どちらも個体数が最適解の数より多くなければならないという制約を持つ。その制約に依存せずに複数の最適解を探索できる手法として、免疫システムに学んだ免疫アルゴリズム (Immune Algorithm, IA) [森 1993, 森 1997] がある。

森らにより提案された 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 (1) 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 (2) 獲得した優位解は二度目以降の問題解決時にのみ活用するという優位解の利用形態についても検討の余地がある。

本論文では、前述の検討点を改善するため、二種類の記憶機構を導入した適応的免疫アルゴリズム (Adaptive Memorizing Immune Algorithm, AMIA) を提案する [Endo 1998, 遠藤 1999, 當間 1998, 當間 2000] 。前述の検討点 (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。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。

提案手法を実験的に評価するために、二つの多峰性のだまし問題、巡回セールスマン問題 (Traveling Salesman Problem, TSP) および、Bipolar Deceptive Function [Goldberg 1992] を採用し、計算機実験によってその有効性を検証した。実験結果から、AMIA がより少ない世代で複数の最適解を獲得可能であり、また、実行可能解として非常に優れた準最適解を探索する効率面においても優れた結果を示した。以上の結果より、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る。

さらに、本論文では、構築した基礎理論をもとに、免疫的手法の更なる工学応用可能性を検証するため、工学分野の一つであるマルチエージェントシステムへの適用を試みた。

分散人工知能の研究領域の一つであるマルチエージェントシステムとは、複数のエージェントと呼ばれる自律した計算主体がお互いに相互作用することにより問題解決を行う枠組であり、ロバスト性・適応性・即応性などの性質を期待されている [石田亨 1996, 生天目 1998, 沼岡 1998]。このような性質を実現する分散問題解決システムを構築するには、

1. 多数のエージェントにどのように仕事を割り振るのか、
2. どのような組織が環境の変化やトラブルに対して頑健か、
3. エージェント同士が如何に効率良くコミュニケーションするのか、

といったことを解明する必要がある。本論文では、上記の 1. に重点をおいた分業問題効率化システムを構築し、その基本性能を実験的に検証するため、マルチエージェントシステムの典型的な評価問題である分業巡回セールスマン問題 (N-th agent's TSP, nTSP) [中村 1994] へ適用した。実験により、複数のエージェント間の相互作用により、与えられた問題における最適な分業結果の獲得を示した。

本論文は以下のように構成される。

第 2 章では、提案手法の生体モデルである免疫システムの概要を述べ、それを工学モデルとして応用するための定義を行う。特に、免疫システムの抗体産生を調節する三大機構 (一次免疫応答, 二次免疫応答, 抑制機構) をモデル化し、探索手法として用いる点を詳細に述べる。

第 3 章では、多峰性関数最適化における研究課題として、従来の複数最適解を獲得する手法である、シェアリング法, すみ分け型アルゴリズム, 免疫アルゴリズム (IA) を概観し、残された課題を明らかにする。

第 4 章では、多峰性関数における複数最適解を獲得する手法として、二種類の記憶機構を導入した適応的免疫アルゴリズム (AMIA) を提案する。AMIA の新規性は、IA の問題点を解消し、さらに探索効率を向上させた点にある。

第 5 章では、提案手法の動作確認および有効性を実験的に検証するため、TSP におけるだまし問題と Bipolar Deceptive Function へ適用した。これらの確認実験や性能評価実験の結果について述べる。

第 6 章では、マルチエージェントシステムにおける分業問題解決システムを構築するためにモデル化した、MHC と免疫ネットワークについて述べる。これらを用いることにより、MHC による競合排除, および免疫ネットワークによる行動生成を基にしたシステムを構築できる。

第 7 章では、MHC と免疫ネットワークを応用した免疫的分業効率化アルゴリズムを提案する。提案手法は、エージェントの作業領域拡大と縮小という相反する適応手段を有し、これらの相互作用により、効率の良い分業を探索することが可能である。

第 8 章では、提案手法の動作確認および基本性能を検証するため、nTSP へ適用した。その実験結果を報告する。

第 9 章では、本論文の結論および成果をまとめ、今後の展望について述べる。

第2章 免疫システム

2.1 緒言

人工知能の分野において，人間の認知・推論を模倣した情報処理システムや，数理論理学を人間の推論に近づけるための研究が盛んに行われ，記号処理をベースにした知識ベースシステムなど，工学応用として結実しつつある [Russell 1995, 廣田 1996] . 近年では，それに加えて生物の情報処理にヒントを得た情報システムが盛んに研究されている (図 2.1) . 遺伝的アルゴリズム (Genetic Algorithm, GA) あるいは進化的計算 (Evolutionary Computation, EC) は，生物進化の原理に着想を得たアルゴリズムであり，新たな確率的探索・学習・最適化の一手法として多くの研究がなされている . また，ニューラルネットワーク (Neural Network, NN) は，脳神経系からヒントを得たものであり，パターン認識等での応用が検討されている [Holland 1992, Russell 1995, Thomas 1997, 北野 1993] .

一方，生体内のインテリジェント・システムである免疫システム (免疫系) が新たな生物型情報システムのパラダイムとして注目されつつある [Dasgupta 1999, 石田好輝 1998, 多田 1993-a] . 本章では，その免疫システムの概要を述べ，免疫システムの工学応用に関する定義を行う .

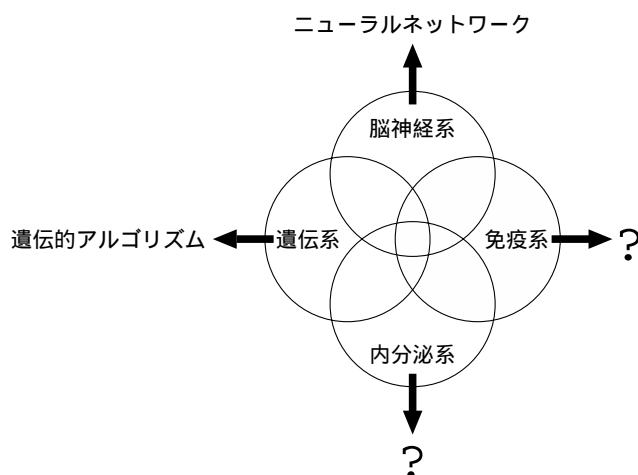


図 2.1: 生物の情報処理に学んだ情報システム

2.2 免疫システムの概要

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、抗体の再構築により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 2.2)[藤原 1997]。この抗原に対する一連の処理(下記 Step1. ~ Step5.)は免疫応答と呼ばれる。

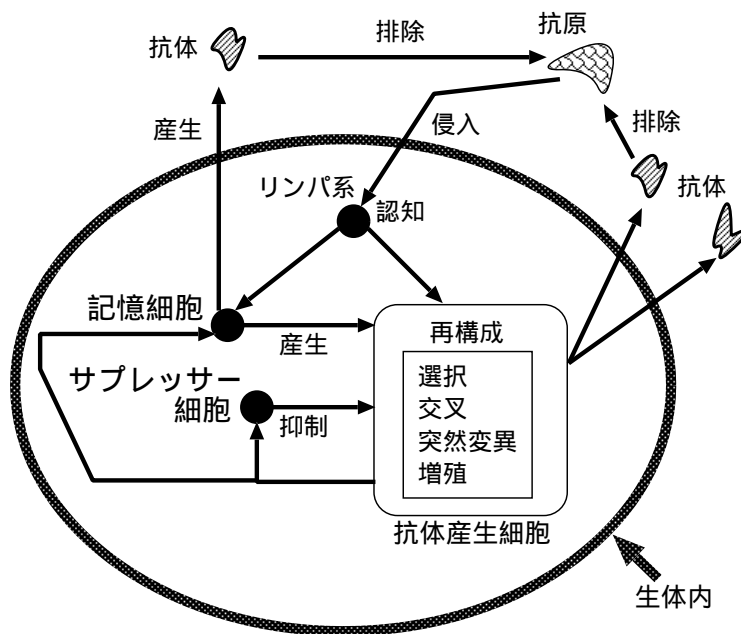


図 2.2: 免疫システム

Step1. 抗原の認識機構

生体内に侵入した抗原をリンパ系が認識し、免疫応答を開始する。

Step2. 抗体の再構成機構

抗体産生細胞により、その抗原を排除し得る抗体を構築するため再構築(選択・交叉・突然変異・増殖)を行い、適切な抗体を産生する。

Step3. 抗体による抗原の排除機構

侵入した抗原を分解・中和することで生体防御を行う。

Step4. 排除に利用された抗体の記憶機構

一度排除した抗原に対しては、記憶細胞に記憶された抗体の記憶を用いることで素早い抗原排除を行う。

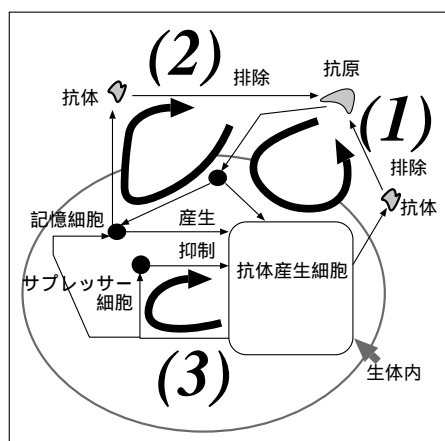
Step5. 抗体の抑制機構

抗原排除のために抗体が大量に産生された結果、生体内の抗体集団の多様性が損なわれてしまう。そこで、自己に対しても免疫性を示し、大量に発生した抗体の産生を抑えることで調節を図る。


免疫システムは複数の情報処理機構から構成されており、抗体の産生を調節する機構に注目すると、次の3つに大別される。

1. 一次免疫応答 (図 2.3 (1)):
未知の抗原に対し行う抗原排除。抗原排除時に使用された抗体などの免疫細胞は、免疫学的記憶として記憶細胞へ分化する。
2. 二次免疫応答 (同図 (2)):
一度排除した抗原に対し行う抗原排除。一次免疫応答時に獲得した記憶細胞を活用することにより、より素早い抗原排除を実現する。
3. 抑制機構 (同図 (3)):
増えすぎた抗体の産生を抑制することで多様性を保持し、未知の膨大な抗原の侵入に備える。

(1) 一次免疫応答, (2) 二次免疫応答, (3) 抑制機構



(a) 免疫システム



(b) 二種類の免疫応答の違い

図 2.3: 二種類の免疫応答と抑制機構

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ため、素早い抗原排除を可能とする (図 2.3(b))。免疫システムでは、このような二次免疫応答と抑制機構を実現するため、前述した免疫学的記憶と、厳密に抗原を識別するための特異性、の二つを用いる。

2.3 工学モデルとしての免疫システム

前節で述べたように，二種類の免疫応答は免疫学的記憶と特異性を用いることにより実現している．この両者をモデル化することが一般的なアプローチであるが，特異性を実装するためには，

- 解決すべき問題を認識し，
- その問題の持つ特徴を抽出し，
- 識別する

機構を構築する必要がある．この課題は，問題をどのように設計するかの指針を与えてくれるだろう．しかし，この特異性を含めたモデルは，設計者の好みや問題に依存した実装となるため，汎用性が大きく損なわれてしまう．そこで，本研究では，免疫学的記憶のみを用いた二次免疫応答と抑制機構についてモデル構築・実装を行う．

免疫システムと，探索アプローチとしての工学システムにおける各々の概念を対応付けたのが図 2.4 である．以下では，同図における関係を，順を追って説明する．

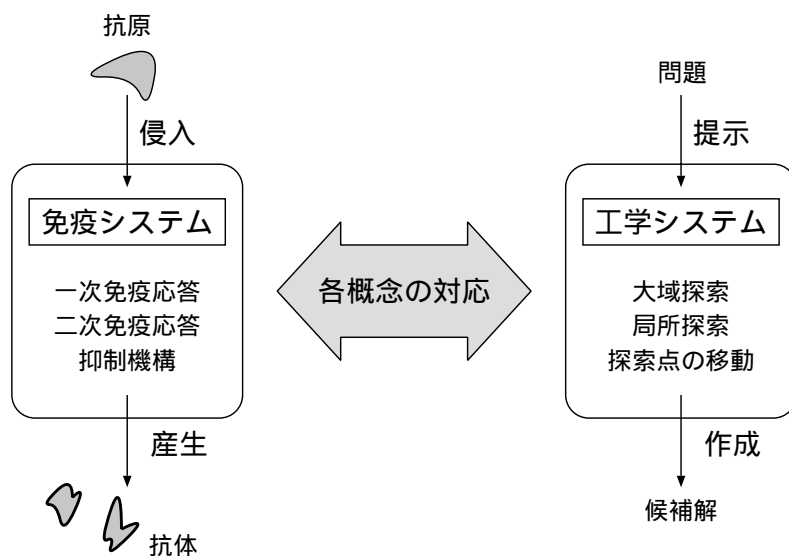


図 2.4: 免疫システムと工学システム

2.3.1 抗原と抗体

免疫システムを工学モデルとして応用する場合，最初に決定すべきことは (1) 免疫システムにとって何が抗原であり (2) 抗原を排除するための抗体とは何を意味するのか，の二つである．免疫システムにおける目的は，侵入した抗原を排除することで生体防御を行うことである．一方，問題解決 (最適化) を行う工学システムでは，与えられた問題に対

する最適な解を発見することが目的である．ここで免疫システムの目的を工学システムの観点から捉え直すと，次のように定義することが妥当なアプローチである．

- 侵入した抗原 = 与えられた問題
- 抗原を排除するために産生する抗体 = 問題に対する最適な解

以下では，一次免疫応答などの高次情報処理機構を用いて抗原を排除する抗体を産生するという免疫システムの枠組を，その情報処理機構を応用して最適解を発見する探索手法として定義する．

2.3.2 一次免疫応答と二次免疫応答

免疫システムでは，抗原排除という問題解決を効率良く実現できる二次免疫応答を二度目以降の問題解決時にしか利用していない．しかし，工学の観点からは，一度目の問題解決時にも二次免疫応答のような機能を有する方が，より優れたシステムと成り得る．本研究では，免疫システムの三大機構（一次記憶機構，二次記憶機構，抑制機構）に学んだ工学モデルを構築し，それを探索アプローチとして応用する．

まず，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．このような免疫応答を探索手法の観点から捉え直すと（１）一次免疫応答では，未知の抗原に対しては先験情報の無い状態から探索する必要があったが（２）二次免疫応答では，学習結果を先験情報として活用することにより探索空間を絞り込めるため，適切な抗体を素早く産生している，と考えられる．本研究では二種類の免疫応答を次のように定義し，探索手法として応用する．

- 一次免疫応答 = 先験情報無しの状態で行う大域探索
- 二次免疫応答 = 先験情報を活用した局所探索

この定義により，二次免疫応答を一度目の問題解決時に活用するためには，局所探索を問題解決の手法として組み入れた探索手法を構築することで実現可能である．

2.3.3 抑制機構

抑制機構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．

免疫システムにおいて，抑制機構により抑制される抗体とは，抗体集団中に占める割合が非常に高いものである．そのような抗体が集団中に数多く含まれる状態とは，抗体の多様度が減少しており，未知の抗原に対する適応度が低いことを意味する．この状態を改善するため，免疫システムでは，抗体産生の抑制などを行い抗体集団の多様度を調整してい

る．この抑制機構を探索手法として捉え直すと，探索集団の多様度を調整する機構となる．特に，探索集団に占める割合の高い解を抑制するため，

- 抑制機構 = 収束した探索集団の移動

を実現する機構として定義する．

2.3.4 免疫システムを用いた探索アルゴリズム

免疫システムを用いた探索アルゴリズムを構築するために，二種類の免疫応答と抑制機構を探索手法として定義した．これらの手法をまとめると，

1. 先験情報無しの状態では大域探索を行い，
2. その結果獲得した記憶を先験情報として活用した局所探索を行う．
3. 収束した探索集団を移動することにより，解集団の多様度を調節する．

という探索アルゴリズムが構築できる（図 2.5）．

第 3 章で紹介する免疫アルゴリズム（Immune Algorithm, IA）では，図 2.5 の一次免疫応答と抑制機構をモデル構築した手法であり，二次免疫応答は採用されていない．一方，本研究で提案する適応的免疫アルゴリズム（Adaptive Memorizing Immune Algorithm, AMIA）とは，図 2.5 をアルゴリズムとして構築を行っており，二次免疫応答を探索手法として導入している点が大きく異なる．二次免疫応答を実装した結果，AMIA は，大域探索と局所探索を使い分けることにより探索効率化を実現した．その詳細は，第 4 章で述べる．

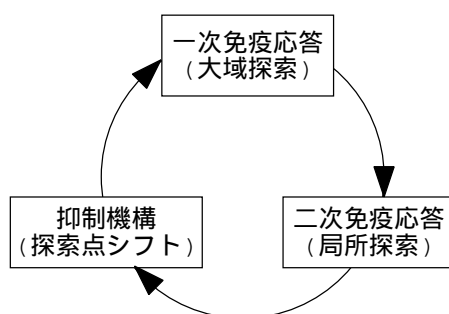


図 2.5: 免疫システムと探索アプローチ

2.4 結言

本章では，新たな生物型情報システムのパラダイムとして注目されている免疫システムの概要を述べ，さらに，工学システムとしての定義を行った．特に，免疫システムにおいて抗体産生を調節する二種類の免疫応答と抑制機構を探索アプローチとして用いることにより，

- 多様な抗体産生による大域探索，
- 記憶を先験情報として活用した局所探索，
- 収束した探索集団を移動することにより，解集団の多様度を調節，

という動作原理に基づいた最適化システムを構築可能であると述べた．

次章では，提案手法の有効性を検証するために扱う多峰性関数について述べる．

第3章 多峰性関数最適化

3.1 緒言

オペレーションズ・リサーチの研究分野の一つである最適化問題とは、与えられた問題を最良の手段で解決したいと考えた場合に必ず直面する課題であるため、あらゆる工学モデルの基礎となる重要な研究分野として認知されている [Goldberg 1989, Holland 1992, 北野 1993, 坂和 1995, 三宮 1998] .

その一般的な定義は、「ある解空間 X において制約条件 F を満足しつつ目的関数 $f(x)$ を最大化もしくは最小化する解 x を求める」課題として定式化される (式 (3.1) ~ 式 (3.3)) .
ここで、制約条件 F を満足する解を実行可能解と呼ぶ .

$$\text{opt}_x f(x) \tag{3.1}$$

$$\text{subject to } x \in F \tag{3.2}$$

$$F \subseteq X \tag{3.3}$$

最適化問題は古くから研究されており、経済の発展と共に対象とする問題がより複雑さを増し、それに追従するように要求される解の性質も変化してきた .

初期の最適化問題で取り扱った問題は、主に線形性や連続関数という性質を有する目的関数であり、このような関数における最適化手法としては、近傍における連続性を解法に応用したシンプレックス法に代表される線形計画法や、微分などが有効であった . 一方、目的関数が不連続集合であったり、また解空間が離散集合であった場合には、近傍における連続性を解法に利用することができないため、真の最適解を発見することは非常に困難である . このように (1) 解空間が離散集合であり (2) 多峰性を有する、典型的な問題は組合せ最適化問題と呼ばれている . その問題に対する解法は、得られる解の最適性に注目すると、最適解を求めるための厳密解法と、近似的な最適解 (局所解や準最適解) を高速に求める近似解法に大別される . 本論文では、後者の近似解法により多峰性関数最適化を行う立場をとる .

多峰性関数における近似解を発見する手法としては、

- 欲張り法 (Greedy Algorithm) や局所探索法に代表されるヒューリスティック法 (発見的手法) ,
- ニューラルネットワーク (Neural Network, NN) や遺伝的アルゴリズム (Genetic Algorithm, GA) に代表される生物の優れた情報処理機構を応用した手法 ,

がある．[北野 1993, 廣田 1996, 三宮 1998]．また，これらの手法を組み合わせたハイブリッド・アルゴリズムや，問題に特化したアルゴリズムも数多く提案され，近似解のみならず最適解を獲得できる状況も数多く見られる．しかしながら，一般に，実世界の問題では制約条件や目的関数が変化する状況が多々存在するため，厳密な大域的最適解だけが要求されることは少なく，複数の代替案の中から解を選択できるように複数の最適解が要求されることが多い[坂和 1995, 三宮 1998]．

本章では，多峰性関数の性質を述べ，従来の複数最適解獲得手法の特徴について概観する．特に，生体内に内在する免疫システムに基づいた新しい最適化手法である免疫アルゴリズムに関し，生体モデルとしての妥当性や，工学モデルとしての最適性の観点から研究課題を考察する．

3.2 多峰性関数最適化

典型的な組合せ最適化問題とは，図 3.1 に示すように (1) 解空間が離散集合であり (2) 多峰性を有する関数である．このような組合せ最適化問題の解法は，近傍における連続性を解法に利用することができないため，一般に解を数えあげるという列挙法的なアプローチとならざるを得ない．しかし，このような問題のほとんどは，多項式オーダーの計算量の厳密解法が存在しないとされる NP 困難となることが示されている．可能領域 F の要素 (実行可能解) の総数は有限であっても膨大な数にのぼることが多く，これらをすべて列挙することは現実的には不可能である．そこで，実際に列挙する範囲をいかに限定するかが重要となる [三宮 1998] ．

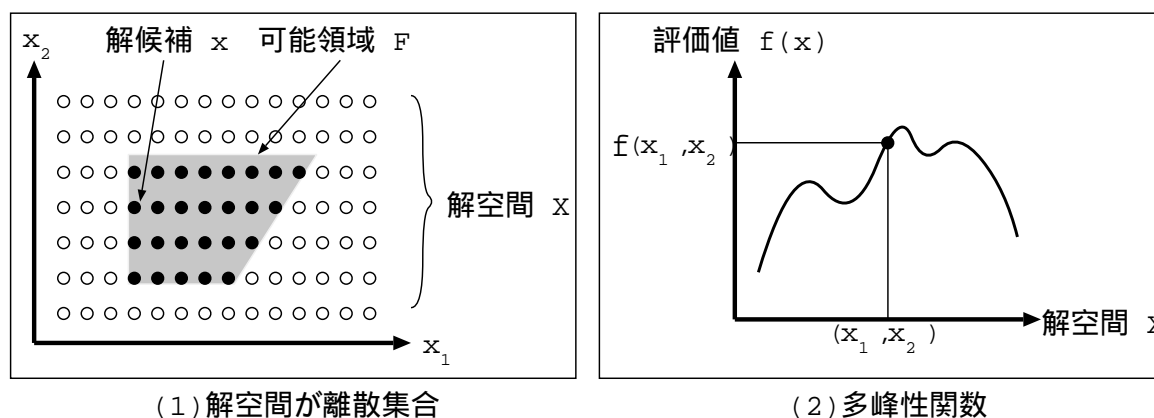


図 3.1: 組合せ最適化問題

従来の組合せ最適化手法は，得られる解の最適性に注目すると

- 厳密解法：最適解を求めるための方法，
- 近似解法：近似的な最適解 (局所最適解や準最適解) を高速に求める方法，

に大別される。厳密解法で用いられる手法は、いずれも可能領域の中で列挙する範囲を狭めているが、それでも限定された領域をくまなく探索するので、一般に膨大な計算量を必要とする。近似解法では、厳密解法のような厳密な手続きによらず、問題に関する先験情報を利用して探索領域を絞り込む。探索領域を絞り込む場合、次の相反する二つの要求をバランス良く実装することが重要である。

- 質の良い解を得るためには、できるだけ広い領域を探索する方（大域的探索）が望ましく、一方、
- 計算時間を短縮するためには、先験情報によってできるだけ探索領域を狭めること（局所的探索）が望ましい。

これらの相反する二つの要求うち、前者を重視するのがランダム探索法（モンテカルロ法）であり、後者に重きを置くのが逐次改善法（山登り法）や欲張り法である。

これまでの解法は、解空間内の一つの解を何らかのルールで移動させ、最適解を探索する手法（一点探索）である。最適化システムとして最も研究例の多い手法である遺伝的アルゴリズムは、生物の進化過程を模倣したアプローチであり、解空間内を多点で並列に探索することが可能である。そのため、強力な大域探索能力を有する手法として広く認知されているが、一方では局所探索を不得手とするため、必ずしも最適解を獲得することはできない近似解法である。

ここで、現実世界において最適化問題を解く一例として、スケジューリング問題における最適化を例題に、最適化問題に求められる要求の変化を述べる。

スケジューリング問題とは、「一つあるいは複数の機械を用いて、いくつかの仕事を処理するとき、各機械上での仕事の処理順序を決定すること」である。この場合、現実世界においては、機械の増減などにより制約条件が変化したり、処理すべき仕事の追加・削除などにより目的関数が増減する場面が多々存在し得る。また、多目的の最適化問題では、目的関数に設計者の意図を反映させることが困難であり、厳密な最適解が得られたとしてもその解が設計者の意図しないものである可能性もある。すなわち、予め設計された問題の最適解を発見するだけではそれを利用する側にとって不十分であり、別の解法が強く求められている。このように、問題の変化にも対応できるような解（ロバスト解）を獲得するための一つの答えが「一度の問題解決で複数の最適解を獲得する」ことである。これにより、複数の代替案から実行する解を選択する余地を残すことが可能となる。

次節では、複数最適解を獲得するための従来のアプローチについて概観し、その特徴と未解決のまま残されている課題を検討する。

3.3 従来の複数最適解獲得手法

3.3.1 遺伝的アルゴリズム

複数の最適解を獲得する手法の多くは、解空間を多点で並列に探索する手法である GA を拡張した枠組となっている。そこで、まずは GA の概略を紹介する。

GA は、個体集合がある環境に適応するために、固定の環境からの評価をもとに進化し、適応能力の高い個体を獲得する手法である [伊庭 1994, 北野 1993, 寺野 1999, 星野 1992, 米澤 1993] . 図 3.2 に、GA のアルゴリズムを示した . GA は、

- コーディング ,
- 適応度関数 ,
- 遺伝子操作オペレータ (選択・交叉・突然変異) ,
- パラメータ設定 ,

などを、試行錯誤的に適切に設計することにより優位解の発見を可能する . これらの設計指針の多くは環境に依存した課題であるため、ヒューリスティックや局所探索を組み込んだハイブリッド型アルゴリズムも数多く研究されている .

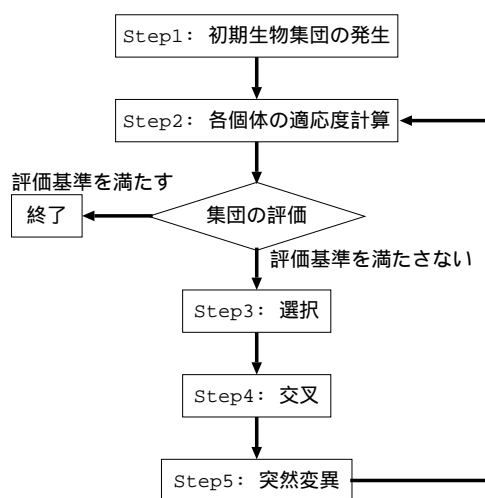


図 3.2: 遺伝的アルゴリズムの枠組み

3.3.2 シェアリング法

GA により最適化を行った場合、GA に特有の初期収束によって、複数の最適解があるにもかかわらず、一つの最適解しか得られない場合がある . 例えば、探索の初期段階において一つの大域的最適解を発見すると他の最適解はもはや得ることはできない . この問題に対して、Goldberg らはシェアリング (Sharing) 法によって集団を初期収束させることなく、個体を複数の空間に配置させ複数の最適解を得ることに成功している [Goldberg 1987, Goldberg 1992] .

シェアリングとは、多くの個体が集中している部分での関数値には比較的小さい重みをかけるのに対して、孤立している個体の関数値には相対的に大きい重みをかけることによ




図 3.3: シェアリング

り，関数値の分布の相対的な均一化を図る操作である（図 3.3）．数学的には，コード化された文字列 s_i, s_j 間の距離 $d(s_i, s_j)$ を考えることにより，

$$0 \leq sh(d) \leq 1, \forall d \in [0, \infty) \quad (3.4)$$

$$sh(0) = 1 \quad (3.5)$$

$$\lim_{d \rightarrow \infty} sh(d) = 0 \quad (3.6)$$

を満たす関数 $sh(\cdot)$ をシェアリング関数 (sharing function) と名付け，次のようなべき乗の関数が便利であると提案した．

$$sh(d) = \begin{cases} 1 - \left(\frac{d}{\sigma_{share}}\right)^\alpha & d < \sigma_{share} \text{ のとき} \\ 0 & \text{その他} \end{cases} \quad (3.7)$$

ここで， σ_{share} ， α は定数である．

いま，個体 s_i の適応度関数を $f(s_i)$ ，個体群サイズを N として，距離とシェアリング関数が選ばれると，シェアリングにより次のように適応度を修正する．

$$f(s_i) := \frac{f(s_i)}{m_i} \quad (3.8)$$

$$m_i = \sum_{j=1}^N sh(d(s_i, s_j)) \quad (3.9)$$

このようにして関数値分布の均一化を行うことにより，最適化問題における初期収束の防止を実現している．一方，

- 個体の数が最適解の数よりも多くなければならず，
- また，定数である σ_{share} ， α の設定は非常に困難，

という課題が残されたままである．

3.3.3 すみ分け型アルゴリズム

シェアリング法と類似した手法として、個体間の距離に対するペナルティを導入することで複数の最適解獲得に成功した、島のすみ分け型エポルーション・アルゴリズムがある [島 1995-a, 島 1995-b] .

説明のため、親の個体数を N 個とし、各親が 1 個の子を作り、 $2N$ 個の個体が存在すると仮定する。すみ分けを可能にするために、次に示す手続きを、これら $2N$ 個の個体間の距離に対するペナルティとして導入する。

- $2N$ 個の個体間の距離を 2 個ずつ比較する。
- もし決められた距離 L よりも二つの個体が接近していれば、その適応度を比較し、良い方の適応度はそのままにするが、悪い方にはペナルティを与える。

これによって、距離 L 内に接近している二つの個体の中で、悪い適応度を持つものはペナルティを課され、さらに悪い適応度を持つことになり、淘汰される確率が非常に高くなる (図 3.4) . その結果、各個体はそれぞれ距離を保ちつつ制約空間の中を分散し、すみ分けることになる。




図 3.4: すみ分け型アルゴリズム

すみ分けを可能にするために、個体間の距離に対するペナルティを導入したことが従来からの方法と異なる点である。計算機実験では、大域的最適解が 18 個も存在するような複雑な問題である Shubert 関数 (式 (3.10) ~ 式 (3.11)) を例題として扱い、シェアリング法よりも良好な結果を得たと報告されている。

$$\min f(x_1, x_2) = \left\{ \sum_{i=1}^5 \cos[(i+1)x_1 + i] \right\} \times \left\{ \sum_{i=1}^5 \cos[(i+1)x_2 + i] \right\}, \quad (3.10)$$

$$\text{subject to } -10 \leq x_i \leq 10 \quad (i = 1, 2). \quad (3.11)$$

このようにすみ分け型アルゴリズムは、複数最適解獲得の手法として優れているが、

- 個体の数が最適解の数よりも多くなければならず、
- また、定数である距離の設定も問題に依存しているため試行錯誤的に決定しなくてはならない

という、シェアリング法と類似の課題を抱えている。

3.3.4 免疫的最適化

森らの免疫アルゴリズムを紹介する前に、その基礎となる免疫的最適化を定義する。

一般的な組合せ問題の適応度地形は、図 3.5 のように多峰性関数となる。通常最適化では、その適応度地形の最大適応度となる解（大域的最適解）の発見を目的とする。しかしながら、実際に獲得した解を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。

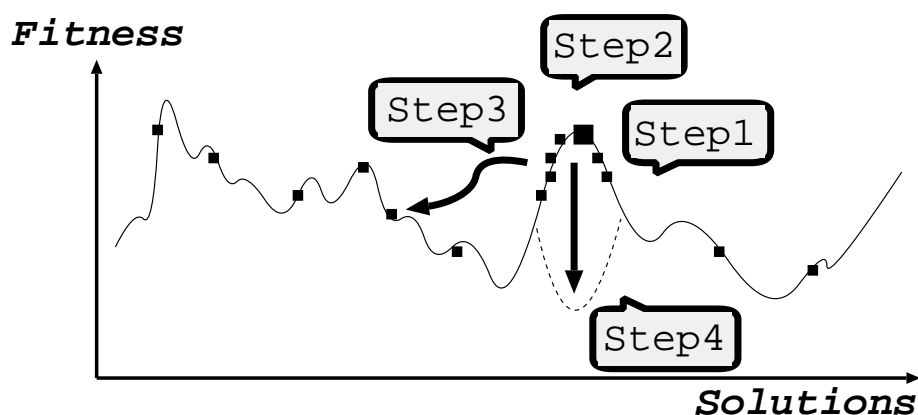


図 3.5: 多峰性関数における免疫的最適化の動作原理

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 3.5）。

- 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 Step2. 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

$$c_v = \left(\sum_{w=0}^{PopSize} ac_{v,w} \right) / PopSize \quad (3.12)$$

$$ac_{v,w} = \begin{cases} 1 & ay_{v,w} \geq TAC1 \\ 0 & otherwise \end{cases} \quad (3.13)$$

- $PopSize$: 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

$$e_v = fitness_v \times \prod_{s=1}^S (1 - as_{v,s}) \quad (3.14)$$

$$as_{v,s} = \begin{cases} ay_{v,s} & ay_{v,s} \geq TAC2 \\ 0 & otherwise \end{cases} \quad (3.15)$$

- 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)で用いる収束割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．

3.3.5 免疫アルゴリズム

シェアリング法やすみ分け型アルゴリズムは，個体数が最適解の数より多くなければならないという制約があった．森らにより提案された免疫アルゴリズム(Immune Algorithm, IA)は，免疫システムのもつ多様性のある抗体の産生機構とその自己調節機構を模倣した探索アルゴリズムであり，先の制約に依存せずに複数の最適解を探索することが可能である[森 1993, 森 1997]．

免疫アルゴリズムの特徴

初期の IA は一つの最適解の探索を目的として設計されたが，

- 探索過程で得た有効抗体の記憶細胞とサプレッサー細胞への分化機構 (Step4) と，
- サプレッサー細胞による抗体産生の抑制機構 (Step5)

を追加することにより，複数の最適解を探索する手法として発展させている．拡張された IA は，GA の強力な大域的探索能力に基づく解の再構成を行い，記憶細胞による優位解の獲得および，サプレッサー細胞による獲得した解の再探索抑制を行う探索アプローチとなっている (図 3.6) . 図 3.7 に IA のアルゴリズムを示す .

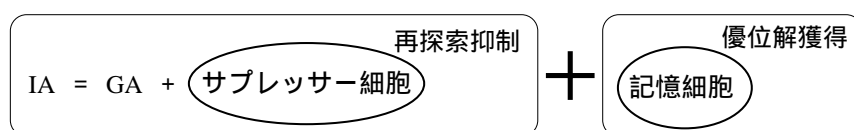


図 3.6: 免疫アルゴリズムの枠組み

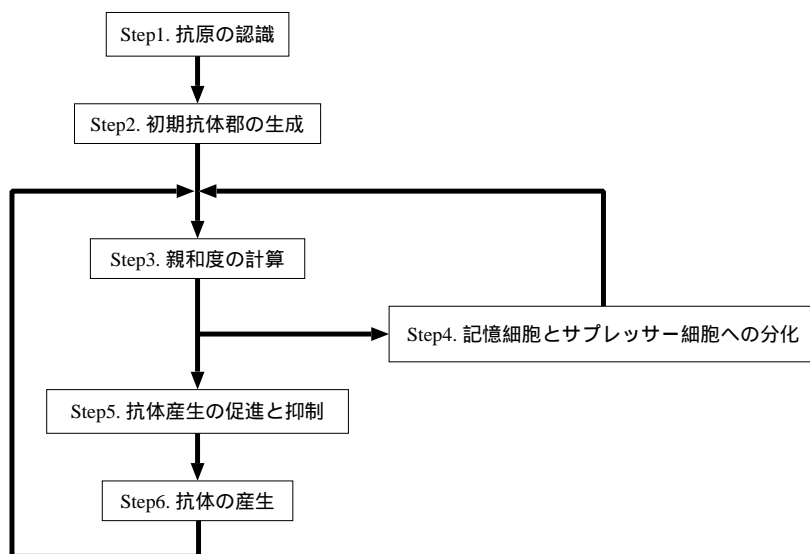


図 3.7: 免疫アルゴリズム

免疫アルゴリズムに残された課題

IA の探索アプローチの基礎となる免疫的最適化とは，生体の免疫システムを応用した探索アプローチであり，

1. 探索集団の収束度合を計算し、その収束度合がある閾値を越えた場合に以下の処理へ移行する。
2. 閾値を越えた解を記憶として獲得。
3. 解集団を別の探索点へと移動。
4. 記憶した解に類似する解群の再探索を抑制。

という4つの処理で構成される。この構成により、IAの基本的な探索動作は、探索点の収束度合がある閾値を越えた際に(1)候補解獲得と(2)再探索抑制を同時に実行するものとなる。この探索動作は、上記の1.で用いられる閾値が適切に設定されているならば複数の最適解を獲得可能であるが、そのパラメータ設定は次に示す理由から困難である。

- 閾値が低いと最適解に到達する前に記憶として獲得し、再探索を抑制するため最適解を獲得できない。
- 閾値が高すぎる場合には、最適解を獲得するのに要する計算コストが膨大となる。

本研究では、この課題を解決し、さらに探索能力の向上のため、二種類の記憶機構を導入した適応的免疫アルゴリズムを構築した。

3.4 多峰性関数における複数最適解獲得

多峰性関数最適化によって得られる最適解は、度々その対象問題の変化などによってその最適性を失ってしまう。その問題を解決する手法として、GAを拡張したシェアリング法やすみ分け型アルゴリズム、免疫アルゴリズムといった複数最適解を獲得する解法を概観した。特に、IAは個体数が最適解の数よりも多くなければならないという制約に依存しないため、シェアリング法やすみ分け型アルゴリズムよりも優れた手法といえる。しかしながら、IAが適切に動作するためにはパラメータ調整が必須であり、それは非常に困難であることを述べた。

この問題を解決するため、本研究では、二種類の記憶機構を導入することにより、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, AMIA)を提案する。AMIAでは、記憶獲得と再探索抑制を行う機構の独立性を、二種類の記憶機構として分離することによりパラメータ設定を用意に行える実装とした。また、生体のもつ免疫システムにおいては、記憶無し状態で抗原を排除する一次免疫応答よりも、獲得した記憶を活用することでより効率の良い二次免疫応答を実現している。IAでは、免疫システムと同様に、二度目以降の問題解決時に記憶細胞を活用しているが、提案手法では、この二次免疫応答を一度目の問題解決時にも応用することにより、探索効率化を図った。AMIAの詳細は次章で述べる。

3.5 結言

本章では，人工知能の研究領域の一つである多峰性関数最適化における研究課題として，実世界の問題では制約条件や目的関数が変化する状況が多々存在するため，厳密な大域的最適解だけが要求されることは少なく，複数の代替案の中から解を選択できるように複数の最適解を獲得することが強く求められていることについて述べた．また，複数最適解を獲得する従来法として，シェアリング法，すみ分け型アルゴリズム，免疫アルゴリズムといった手法について概観した．

次章では，より有効な複数最適解獲得の手法として，二種類の記憶機構を導入した適応的免疫アルゴリズムを提案する．

第4章 適応的免疫アルゴリズム

4.1 緒言

これまでに、

- 第2章では、免疫システムの工学システムとしての定義、
- 第3章では、多峰性関数における複数最適解を獲得する従来手法の特徴と問題点、

を述べた。本研究では、第2章で述べた免疫型モデルに基づいた探索手法を構築することにより、IAの問題点を改善し、さらに探索効率の向上を図る。

本章では、多峰性関数における複数最適解を獲得する手法として、二種類の記憶機構を導入した適応的免疫アルゴリズム (Adaptive Memorizing Immune Algorithm, AMIA) を提案する。まず、先行研究である IA [森 1993, 森 1997] の問題点を明確にする。そして、その問題点の改善を行った AMIA を示し、アルゴリズムの詳細を述べる。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。

4.2 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、サブ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 4.1)。

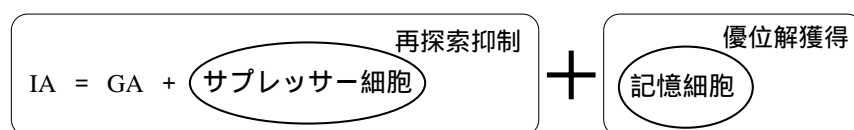


図 4.1: 免疫アルゴリズムの枠組み

この構成により、有効解の獲得および探索点の移動を実現しており、多峰性関数における複数最適解の獲得が可能となっている。しかし (1) 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 (2) 獲得した優位解は二度目以降の問題解決時にのみ活用するという優位解の利用形態につい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(図 4.2)．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基に，記憶に類似した探索点の局所探索を行なうことで局所最適解の探索可能性を高めることが可能である(図 4.3)．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最適解を探索するよりも，局所探索を行なうことにより，最適解の探索に要する世代数の減少が見込める．

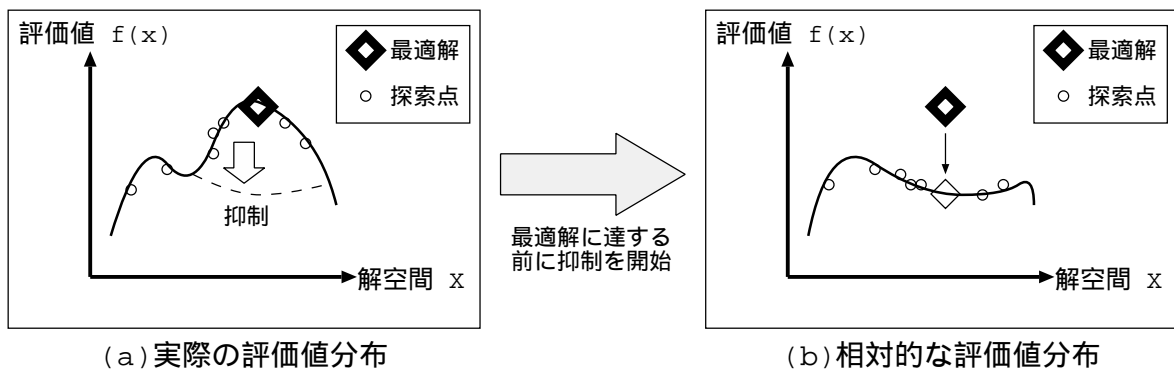


図 4.2: IA におけるパラメータ調整の困難性 (閾値が低い場合)

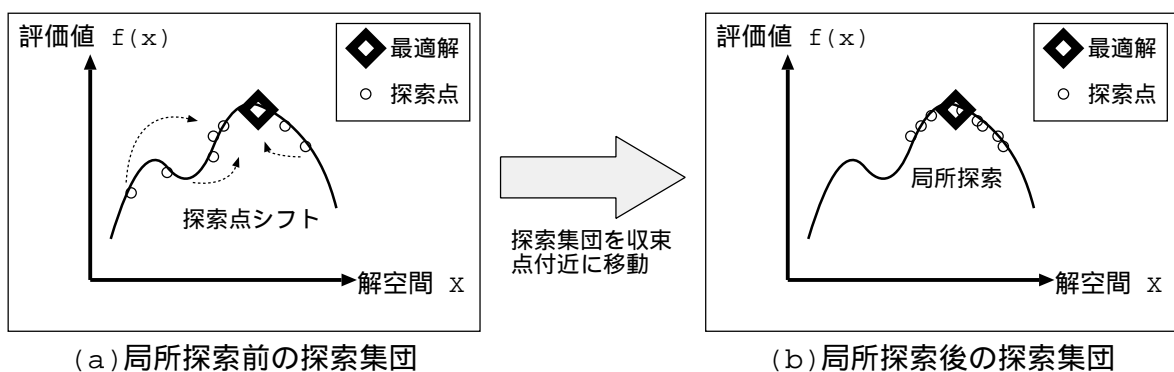


図 4.3: 記憶細胞を活用した探索能力の向上

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する．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，

パラメータ調整が容易になる。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、探索能力の向上を図る。

4.3 適応的免疫アルゴリズム (AMIA)

二種類の記憶機構を Step4 に導入した拡張アルゴリズム AMIA を図 4.4 に示す。

[Step1. 抗原の認識]

抗原を入力情報として認識する。具体的には、問題に対する解 v の評価値 $fitness_v$ を決定する。

[Step2. 初期抗体群の生成]

記憶細胞から過去に有効であった抗体群を生成する。記憶細胞が存在しない時は、抗体の遺伝子をランダムに決定することで抗体群を生成する。

[Step3. 適応度および類似度の計算]

抗体 v の抗原に対する結合度合である適応度 $fitness_v$ と、2つの抗体 v, w 同士の認識度合である類似度 $ay_{v,w}$ 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:
現抗体群が共通して持つ特徴をテンプレートとして作成し、記憶細胞に記憶する。そのテンプレートを用いて抗体群を再構築し、局所探索の促進を図る。
- 二次記憶機構:
現抗体群から、最大濃度を持つ抗体を計算し、サプレッサー細胞に記憶する。その後の探索においては、記憶解に類似する抗体の産生を抑制する。また、現抗体群をランダムに再構築することで、探索点を移動する。

[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、世代が予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。4つのパラメータの内、適応度と類似度は問題固有に固有の設計を行い、濃度と期待値は 3.3.4 節の式 (3.12) ~ 式 (3.15) により決定する。

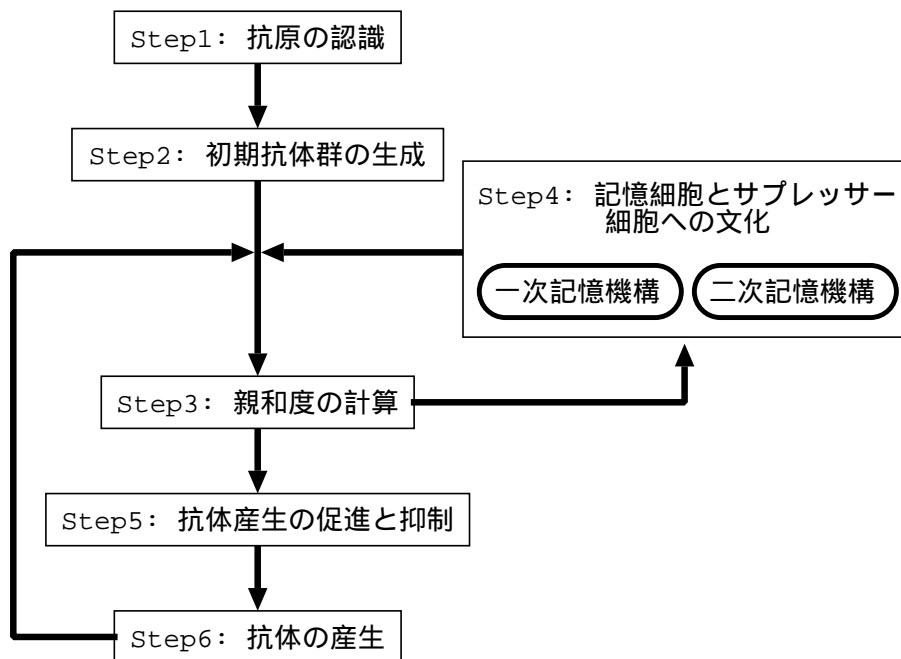


図 4.4: 二種類の記憶機構を導入した適応的免疫アルゴリズム

4.4 AMIA に導入した記憶機構

導入した記憶機構は、

- 記憶細胞を活用した局所探索を実行する一次記憶機構、
- サブレッサー細胞を活用した探索点のシフトを行う二次記憶機構、

の二つである。本節では、この記憶機構の詳細を述べる。

4.4.1 記憶機構の特徴と動作概念

記憶機構は (1) GA による大域探索 (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 4.7)。アルゴリズムの詳細を述べる前に、免疫システムと記憶機構の対応関係と、AMIA の動作概念、そして記憶機構の特徴を述べる。

免疫システムと記憶機構の関係

2.3.4 節では、免疫システムの二種類の免疫応答と抑制機構を探索手法として定義したが、これを導入した記憶機構と対応付けたのが図 4.5 である。

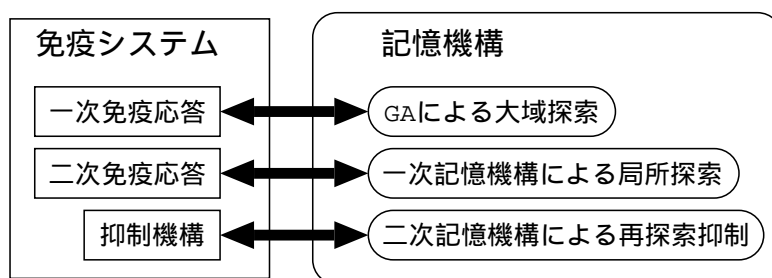


図 4.5: 免疫システムと記憶機構

AMIA の動作概念

また，導入した記憶機構では，どちらも探索集団を再構築することで局所探索や，探索点シフトを実現しており，実際の探索は GA により実行される．従って，図 2.5 では，大域探索，局所探索，探索点シフト，という順に処理が推移していたが，実装した記憶機構では図 4.6 に示したように，1) GA (大域探索)，2) 一次記憶機構による局所探索のための集団再構築，3) GA (局所探索)，4) 二次記憶機構による探索点を移動するための集団再構築，という順で実行される．また，処理が GA から記憶機構へ移行するのは，予め設定した閾値よりも探索集団が収束した場合にのみ実行される．

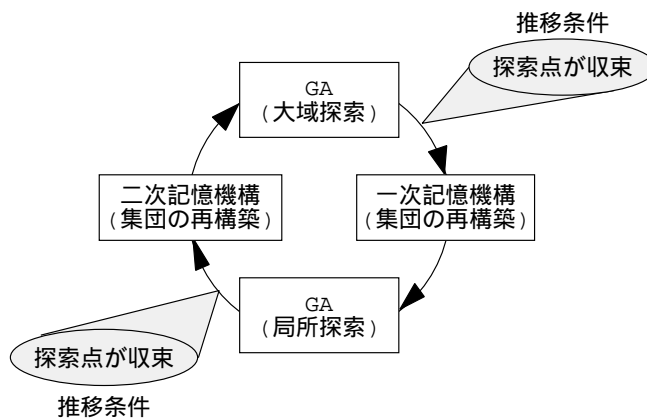


図 4.6: 導入した記憶機構による探索動作の概念図

以上が，基本的な動作原理である．以下では，図 4.7 に示した詳細なアルゴリズムに沿って説明を行う．

図 4.7 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し，探索点を移動するという探索動作を行なう．

記憶機構の特徴

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テンプレートの獲得および、獲得したテンプレート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優位解の獲得、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、という拡張を行う。

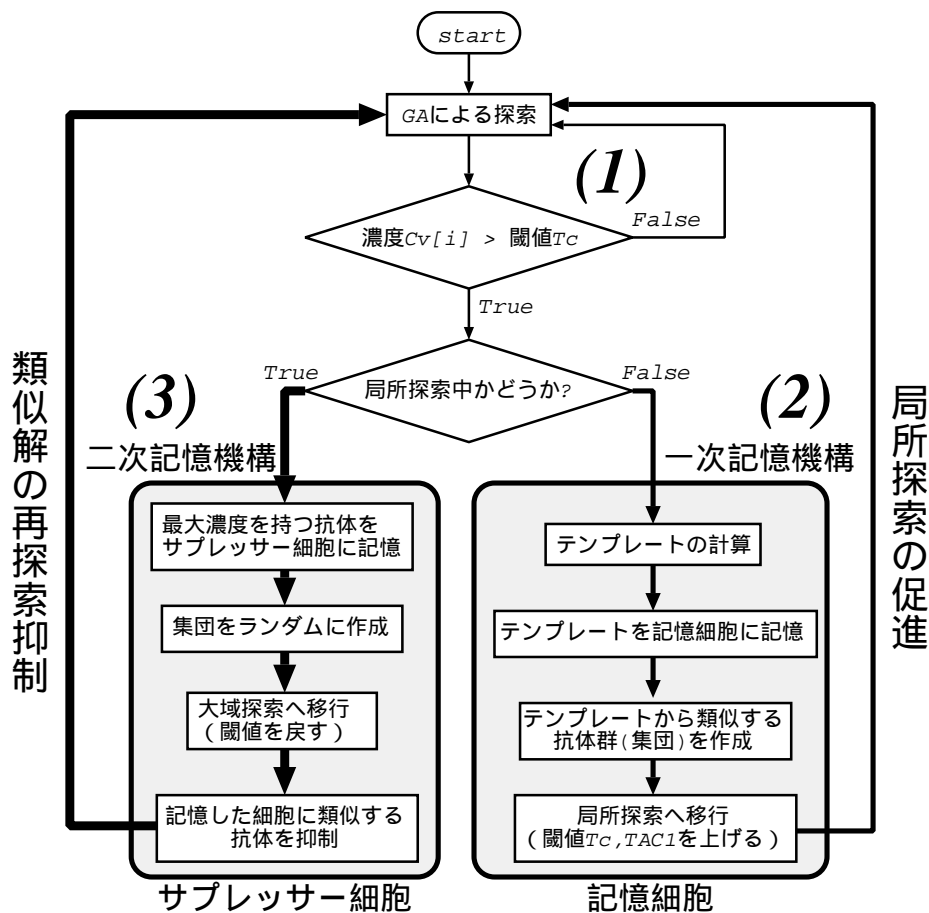


図 4.7: 記憶機構

また、IAで獲得した候補解は、記憶細胞とサプレッサー細胞へ同一の解が記憶されるが、AMIAで獲得する解は、

- 記憶細胞：探索集団に含まれる優位な部分解（テンプレート），
- サプレッサー細胞：収束した探索点の候補解，

であり，記憶細胞とサプレッサー細胞で獲得する解が異なる点に注意を要する．

4.4.2 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質の良い部分解（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4.8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．

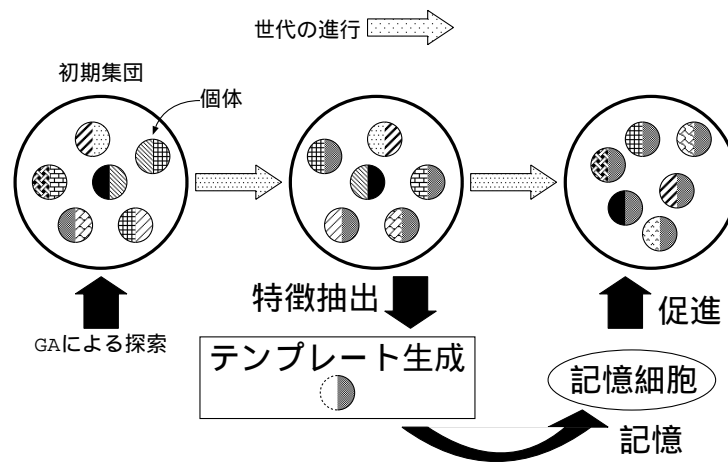


図 4.8: 一次記憶機構

[Step1. テンプレートの計算]

現集団で最大濃度を持つ抗体との類似度が閾値 $TAC1$ を越えるような抗体群（共通する部分解を持つ解群）において，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]

記憶可能な数には限界があるため，それを越える場合には最も共通するパターンを持つテンプレートと入れ換えることで，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]

Step3 で作成された抗体群に対し，閾値 (TC や $TAC1$) を上げることにより，より収束度合が高くなるまで探索を行う．

4.4.3 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 4.9）．

[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（3.14），式（3.15））ことで再探索を抑制する．

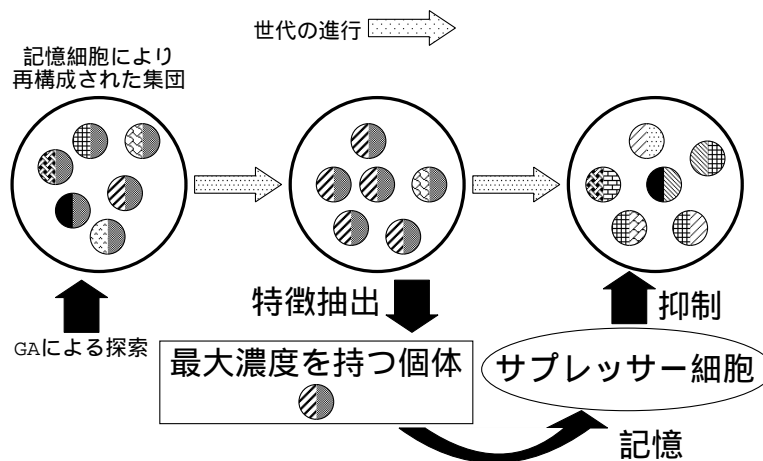


図 4.9: 二次記憶機構

4.5 結言

本章では，多峰性関数における複数最適解を獲得する手法として，二種類の記憶機構を導入した適応的免疫アルゴリズム（AMIA）を提案した．AMIAは，

- GAによる大域探索，
- 一次記憶機構による局所探索，
- 二次記憶機構による再探索抑制，

を動作原理とする．AMIAの新規性は，IAの問題点を解消し，さらに探索効率を向上させている点にある．また，IAでは獲得する候補解は，記憶細胞とサプレッサー細胞とで同一であるが，AMIAでは，

- 記憶細胞：探索集団に含まれる優位な部分解（テンプレート），
- サプレッサー細胞：収束した探索点の候補解，

であり，記憶細胞とサプレッサー細胞で獲得する解が異なる点に注意を要する．

次章では，AMIAの有効性を検証するため，多峰性関数を対象問題として行った計算機実験を示す．

第5章 計算機実験

5.1 緒言

これまでに，多峰性関数最適化問題に対して，免疫システムの二種類の免疫応答と抑制機構を用いた探索手法を定義し，本研究で提案する適応的免疫アルゴリズム (AMIA) の枠組を述べた．本章では，提案手法を実験的に評価するために，多峰性のだまし問題を採用し，計算機実験によってその有効性を検証する．

計算機実験では次の二つの問題を扱った．

対象問題 1 :

AMIA の探索動作を確認のため，巡回セールスマン問題におけるだまし問題へ適用．

対象問題 2 :

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．

以降では，これらの採用した問題の概略を述べ，AMIA を適用した結果を報告する．

5.2 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 (Travelling Salesman Problem, TSP) におけるだまし問題 [山村 1992] へ適用する．ここで，だまし問題とは二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 5.1 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 5.1 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 5.2 は，だまし問題における AMIA の動作原理を概念的に示している．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，
- 最適解探索に要する世代数の減少，

が可能である．

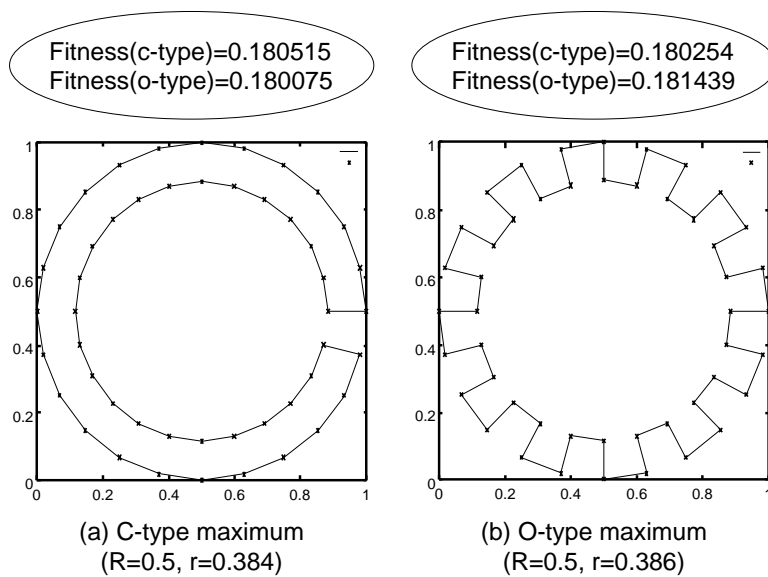


図 5.1: C-type と O-type

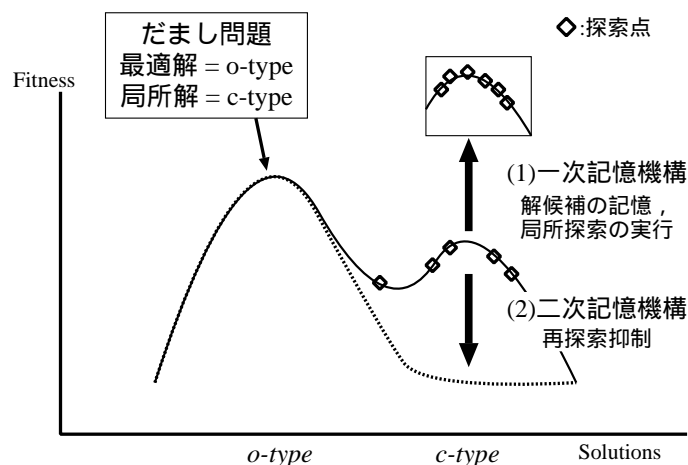


図 5.2: だまし問題における AMIA の探索動作

5.2.1 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．なお，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 1992] 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 5.3 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（Step1）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。

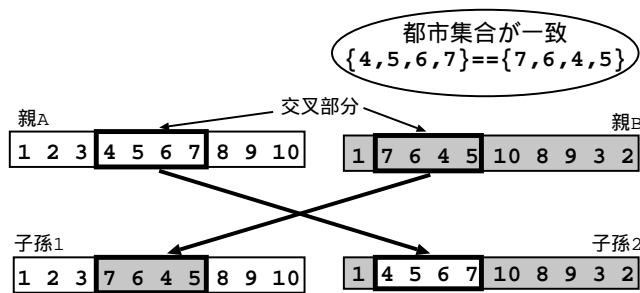


図 5.3: サブツアー交換交叉

5.2.2 適応度と類似度

先にも述べたように、免疫アルゴリズムを適用する場合、適応度、類似度、濃度、期待値の計算尺度を設計する必要がある。濃度と期待値については、3.3.4 節で定義した式 (3.12) ~ 式 (3.15) を用いる。適応度 $fitness_i$ は、解 i の巡回経路長の逆数とした (式 (5.1))。類似度 $ay_{v,w}$ は、2 つの解 v, w に共通する順路の都市数と設定した (式 (5.2))。

[適応度]：解 i の評価値

$$fitness_i = 1 / (Cost * Cost_w) \quad (5.1)$$

$Cost$ ：巡回経路長

$Cost_w$ ： $Cost$ の重み

[類似度]：2 つの解 v, w に共通する巡回経路の割合

$$ay_{v,w} = common_path / m \quad (5.2)$$

$common_path$ ：2 つの抗体に共通する順路の都市数

m ：都市数

5.2.3 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 1992]と同一(48都市TSP)とした。

5.2.4 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5.1、AMIAのパラメータを表5.2に示す。表5.2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。

表 5.1: 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
終了世代数	100000

5.2.5 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($Mem1 \sim Mem4$)およびサプレッサー細胞($Sup1 \sim Sup3$)へ記憶した世代を図5.4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プレッサー細胞を図5.5に示す。

図5.4より、探索集団に共通する部分解であるテンプレートを記憶細胞へ獲得し、その後の局所探索後により適応度の高い候補解をサプレッサー細胞として獲得するという、AMIAの探索動作が確認できる。以下、同図の結果より考察を行う。

図5.4に示した、最大適応度推移と記憶細胞やサプレッサー細胞との関係より、次の二点が考察できる。

考察1：

$Mem1$ 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が

表 5.2: 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
サプレッサー細胞総数	5
TC (記憶用閾値)	0.5 (0.695)
$TAC1$ (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}	1.39

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有効に機能していると考えられる．

考察 2 :

また，サプレッサー細胞 $Sup1$ 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．その後に得られたサプレッサー細胞 $Sup2$ 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おり，探索点の移動が実現したと考えられる．

次に，図 5.5 に示した，得られた記憶細胞およびサプレッサー細胞から記憶内容を検証し，前述した考察の妥当性を確認する．

[$Mem1$]

外円を連続して巡回するという最適解 C-type の特徴が確認できる．

[$Sup1$]

$Mem1$ 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-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．

ところで，最適解が得られるのに要した世代数（約 35000 世代）と比較し，局所解探索時の世代数（約 12000 世代）に減少しているのが確認できた．これは，探索の進行

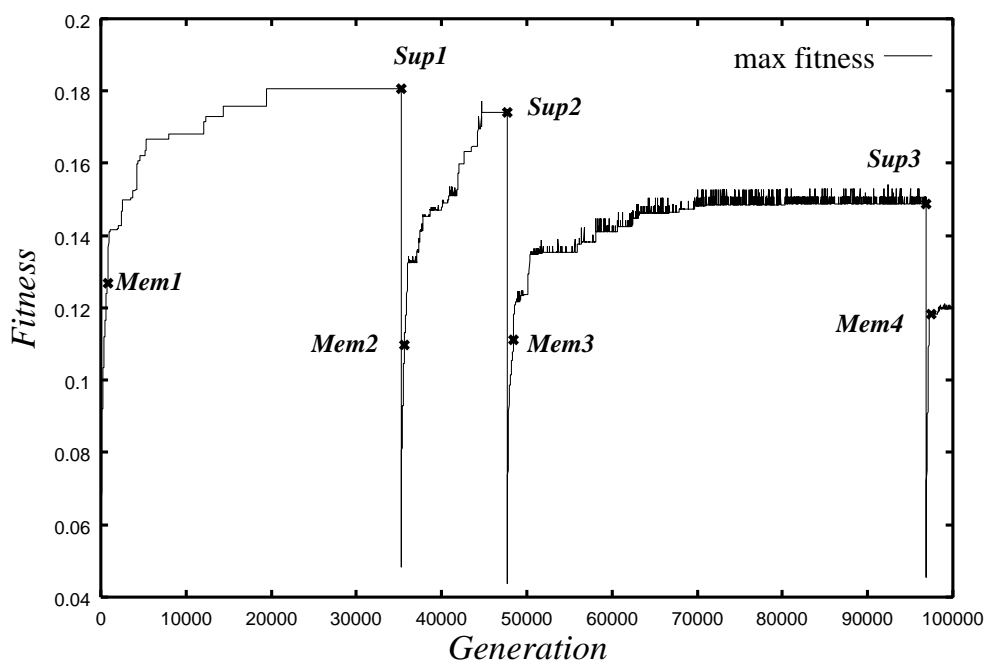


図 5.4: 最大適応度の推移と記憶した世代数

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はなく、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なわれた結果、*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。

また、*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確認できた。*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抑制すべき *Sup1* や *Sup2* 等が上書きされるまで続き、上書きされた後は再び C-type や O-type が高適応度となるようなフィットネス・ランドスケープを持つ問題に戻る。

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。

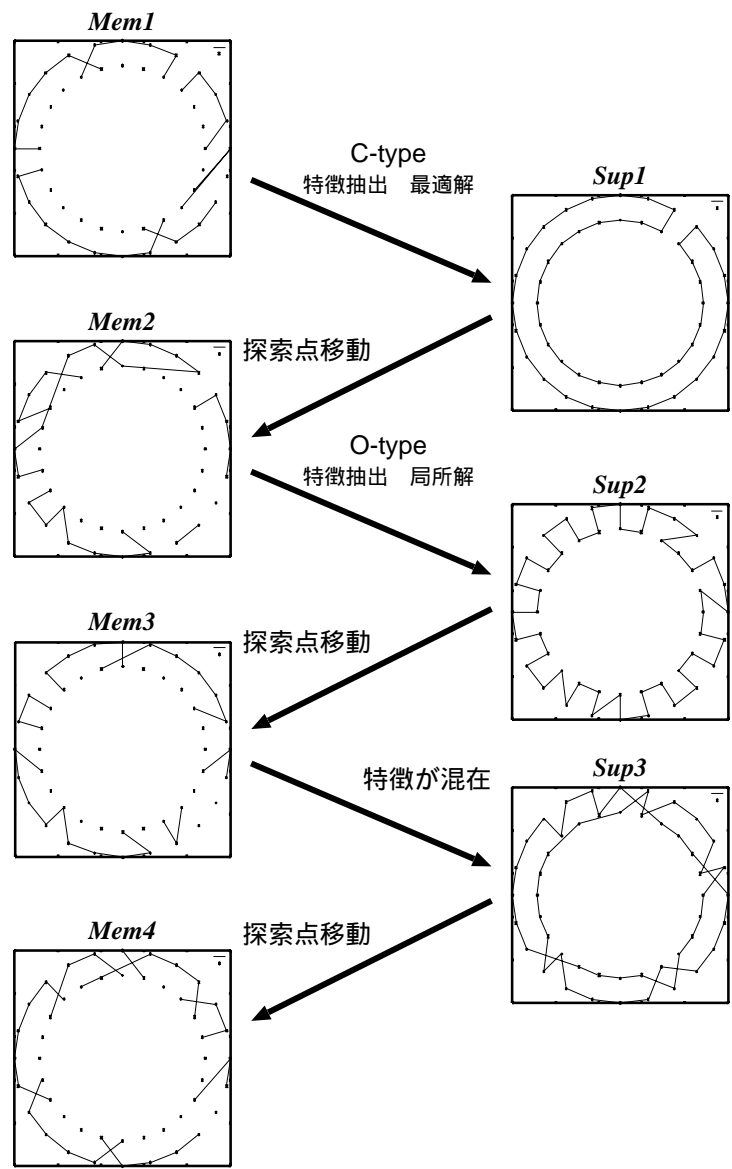


図 5.5: 記憶細胞とサプレッサー細胞

5.2.6 実験 2 : シミュレーション設定

表 5.1 に示した問題を, 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, 各々に適用し, その結果得られた適応度推移から優劣比較を行う. ここで用いた GA は, 5.2.1 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 (5.1) 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 5.2 と同じ設定とした.

5.2.7 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5.6に示す．なお，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た．

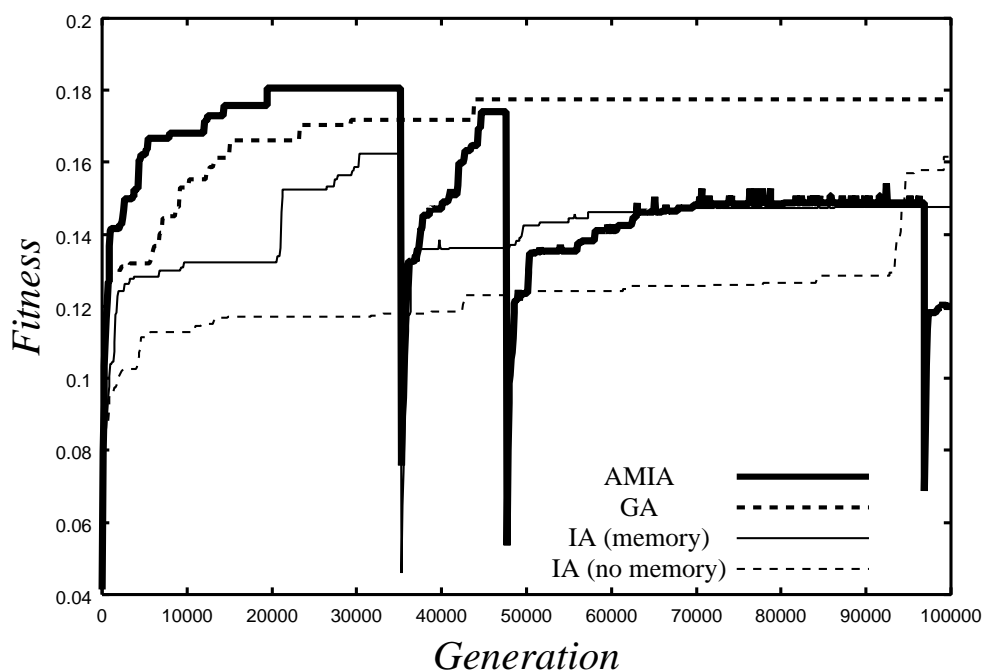


図 5.6: 最大適応度の推移の比較

図5.6に示した最大適応度の推移を，AMIAと各手法との比較から考察する．

考察3：AMIAとIA (memory)

IA (memory)は，記憶を約35200世代で獲得しており，その直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かかわらず，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る．よって，AMIAは高適応度の解を探索可能性がより高いことが確認できた．

考察4：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、記憶獲得と再探索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。

考察 5：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。

5.2.8 実験 1 と実験 2 のまとめ

実験 1 と実験 2 では、AMIA の基本性能および探索動作を確認するため、TSP におけるだまし問題へ適用した。実験結果から、AMIA の優位点をまとめる。

1. 局所探索の妥当性

探索中に獲得した記憶を活用した局所探索が、最適化の観点から妥当であることを示した。

2. 記憶獲得の安定性

記憶機構を二種類に分割することで、適切な記憶獲得のためのパラメータ調節が容易となった。

3. 高適応度の解探索可能性

記憶細胞に記憶後も探索を行なえるため、より高適応度の解探索が可能である。

5.3 節では、多峰性関数における複数最適解獲得の獲得効率の観点から提案手法の有効性を検証する。

5.2.9 Java を用いたシミュレータ作成

研究成果を報告する一貫として、AMIA のシミュレータを Java アプレットとして作成した (図 5.7)。将来的には、TSP や AMIA のパラメータ設定の変更などを行えるように改良する予定である。

5.3 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 1992]。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 5.8 上) は、低次 Walsh 係数を用いて作成した関数 (式 (5.3)) 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

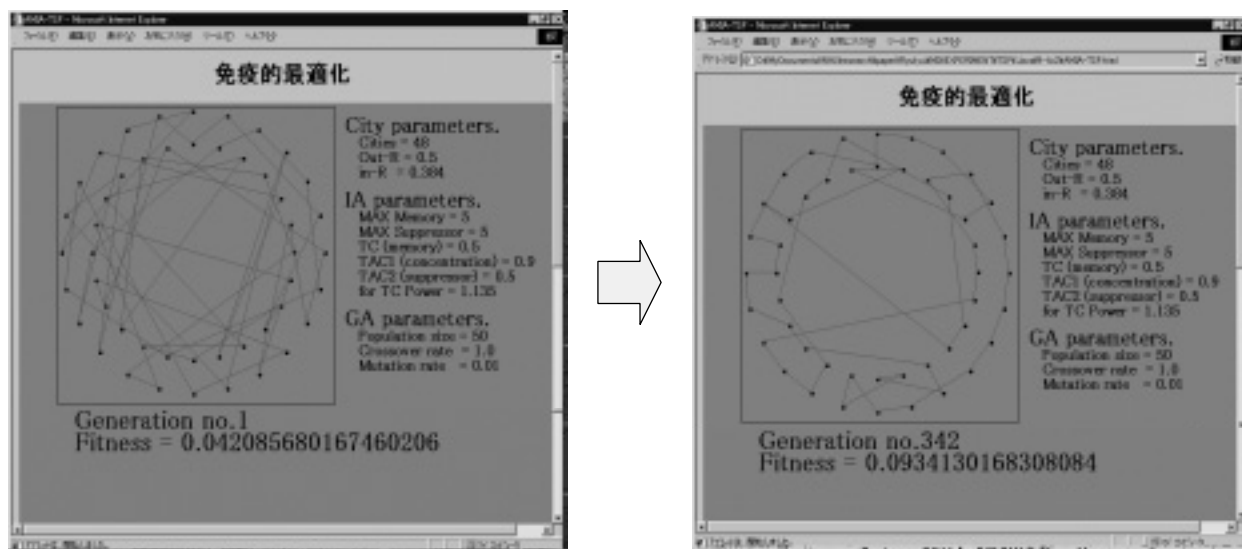


図 5.7: シミュレータ画面

て作成した 30-bit 問題 (図 5.8 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 (5.3) で用いた各パラメータ値は , 文献 [Goldberg 1992] 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 (5.3) 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 .

$$f(u, \lambda, 2l) = \sum_{i=0}^{\lambda} w_i \psi'_i(u, \lambda) \quad (5.3)$$

- 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

$$\psi'_i(u, \lambda) = \sum_{j=0}^i (-1)^j \binom{u}{j} \binom{\lambda - u}{i - j} \quad (5.4)$$

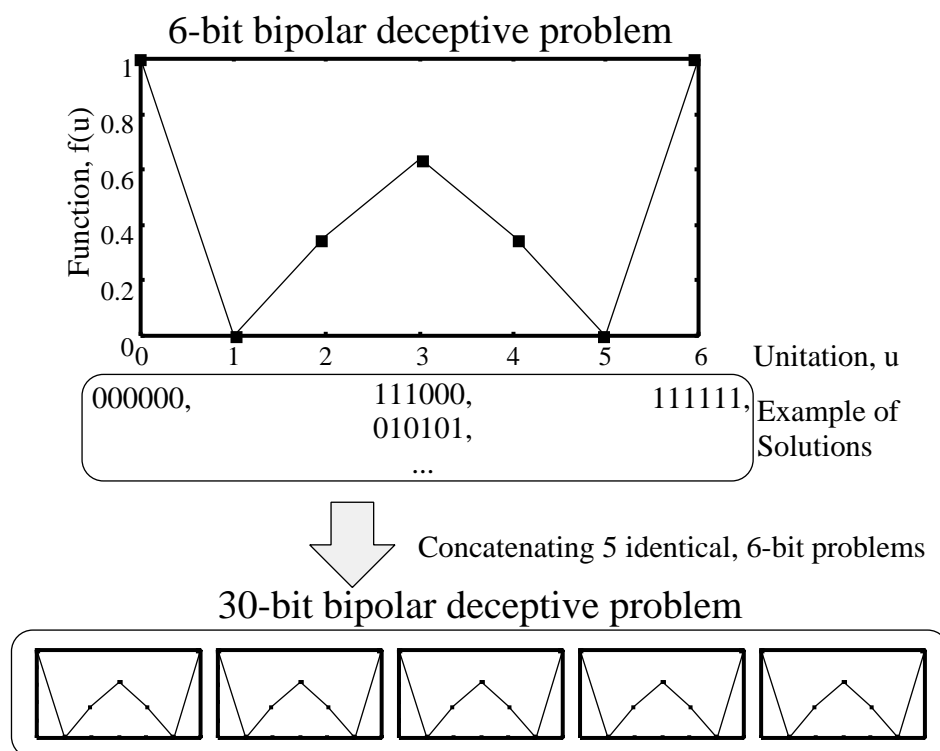


図 5.8: 30-bit 問題

5.3.1 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．

$$solution_i = \sum_{j=0}^N sub_solution_{ij} \quad (5.5)$$

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

5.3.2 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 (式 (5.5) の $sub_solution_{ij}$) 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 (5.6))．類似度はハミング距離を用いた (式 (5.7))．濃度と期待値については，3.3.4 節で定義した式 (3.12) ~ 式 (3.15) を用いる．

[適応度] : 解 i の評価値

$$fitness_i = \sum_{j=0}^N f(u_{ij}) \quad (5.6)$$

- u_{ij} : $sub_solution_{ij}$ に含まれる 1 の数
- $f(u_{ij})$: 式 (5.3) (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

$$ay_{v,w} = 1/(1 + H(v,w)) \quad (5.7)$$

- $H(v,w)$: 解 v と w のハミング距離

5.3.3 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 5.3 に示す. 表 5.3 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.

表 5.3: 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	30000

5.3.4 実験 3 : 結果と考察

30-bit 問題は, 図 5.8 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（表 5.4）．獲得した優位解は適応度の高い解から順に獲得していた．

表 5.4: 全最適解獲得に要した平均世代数と，獲得した優位解の平均個数

	AMIA	IA
平均世代数	14 万世代	21 万世代
平均個数	220 個	40 個

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，図 5.9 に示した，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 (*Sup*) の適応度から考察を行う．

考察 6：

図 5.9 に示した，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場面が確認された．特に，約 1400 世代目・2300 世代目・3800 世代目に獲得したサプレッサー細胞は，探索中に大域的最適解を発見しているにも関わらず，準最適解を獲得している．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．

5.3.5 実験 3 のまとめ

実験 3 では，多峰性関数における複数最適解獲得の性能評価を行うため，30-bit 問題へ適用した．実験結果から，AMIA の優位点をまとめる．

1. 探索効率の向上

全最適解を獲得するのに要する平均世代数の比較より，AMIA がより少ない世代で探索可能であることを示した．

2. 優位解獲得の効率化

最終世代までに獲得した優位解の平均個数の比較により，AMIA がより多くの優位解を獲得することを示した．

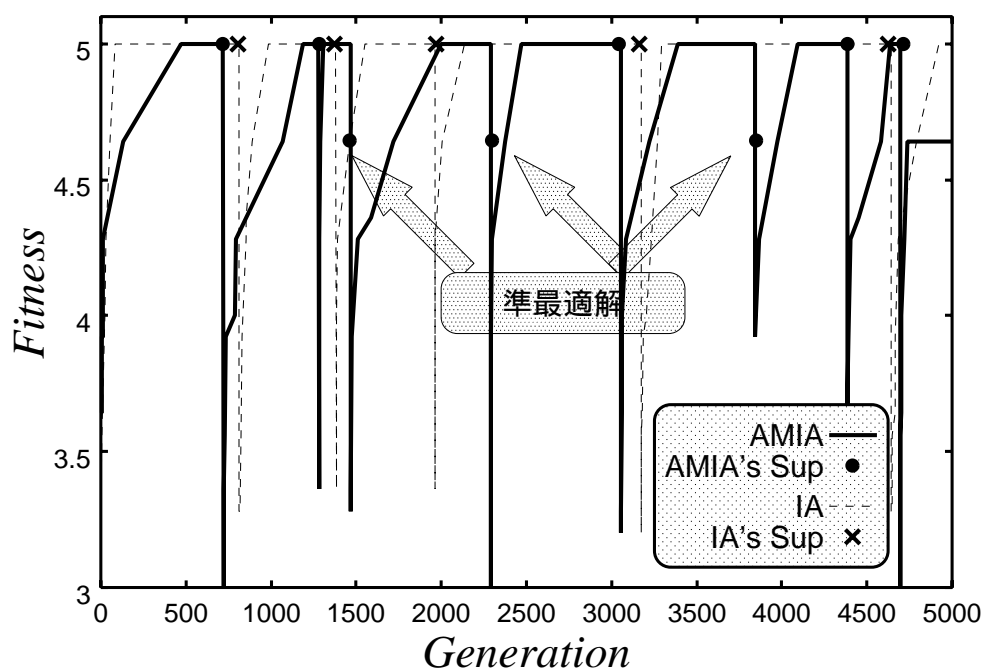


図 5.9: 獲得した記憶の適応度と世代数の推移

また，AMIA 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．

5.4 結言

提案手法の動作確認および有効性を検証するため，TSP におけるだまし問題と Bipolar Deceptive Function へ適用した．動作確認を行った実験 1 と実験 2 より，

1. 局所探索の妥当性
2. 記憶獲得の安定性
3. 高適応度の解探索可能性

を確認した．また，性能評価を行った実験 3 より，

1. 探索効率の向上
2. 優位解獲得の効率化

を確認した．これらの計算機実験により，提案手法 AMIA は，多峰性関数における探索手法として有効であることを示した．

第6章 免疫システムのマルチエージェントシステムへの応用

6.1 緒言

第2章で述べた免疫システムは、免疫学的記憶を活用した一次免疫応答や二次免疫応答、抑制機構に着眼点を置いたモデルであった。このモデルでは(1)既に抗原を認識したという前提のもとで免疫応答を行っており、また(2)抗体構築は抗体産生細胞により行われていた。しかし、免疫システムが本来行っている動作は、

生体(自己)内に侵入した抗原を非自己として認識し、非自己を排除すること

であることから、如何に自己・非自己を判別するかが重要な課題である。また、抗体の構築は、マクロファージやT細胞、B細胞と呼ばれる免疫細胞群の相互作用により行われる。非自己を認識し、免疫細胞群の相互作用により抗体を構築する機能は免疫ネットワークと呼ばれている[Janeway 1997, 垣内 1996, 多田 1996, 藤原 1997]。

本章では、自己・非自己を認識し、判別するために用いられているMHCと、上記の免疫ネットワークの概要を述べ、自律分散システム(マルチエージェントシステム)における作業領域の分業問題を解決するための定義を行う。

以下、マルチエージェントシステムにおける分業問題を述べ、次いで、免疫システムを応用した工学モデルを構築する。

6.2 マルチエージェントシステムと分業効率化

分散人工知能の研究領域の一つであるマルチエージェントシステムとは、複数のエージェントと呼ばれる自律した計算主体がお互いに相互作用することにより問題解決を行う情報処理技術である[石田亨 1996, 生天目 1998, 沼岡 1998]。分散問題解決システムを構築するには、

1. 多数のエージェントにどのように仕事を割り振るのか、
2. どのような組織が環境の変化やトラブルに対して頑健か、
3. エージェント同士が如何に効率良くコミュニケーションするのか、

といったことを解明する必要がある。本論文で扱う分業問題効率化とは、上記の1.に重点をおいた課題であり、以下のように定義する(図6.1)。

分業問題効率化：

エージェントに配分する対象問題を作業領域 WS ，全作業領域を問題領域 PS と定義する．このとき，

- (a) 問題領域 PS において，エージェント i の担当する作業領域 WS_i を平等に分割し，かつ，
- (b) 作業領域 WS_i を最適化することにより，効率的な分業を実現する．




図 6.1: 分業問題率化

以下では，マルチエージェントシステムにおける分業問題効率化のため，MHC および免疫ネットワークのモデル構築および，それを応用したシステム設計を行う．

6.3 分業効率化システムとしての免疫システム

本章で扱う免疫システムは (1) 抗原を認識するための MHC と (2) 免疫細胞群の相互作用により抗体産生を行う免疫ネットワークを用い，生体防御を行うモデルとなっている．免疫システムと，分業効率化システムにおける各々の概念を対応付けたのが図 6.2 である．以下では，同図における関係について述べる．

6.3.1 抗原と抗体

免疫システムをマルチエージェントシステムにおける適応モデルとして構築するため，抗原と抗体を次のように定義する．

- 抗原 = エージェントに与えられた問題，エージェントが存在する環境
- 抗体 = 課題に対する解，適応手段，

この時，分業問題を効率化するために (1) エージェントが環境や他のエージェントを知覚するための機構として MHC を応用したモデルを構築し，また (2) 環境に適合するための行動生成システムとして免疫ネットワークを実装する．

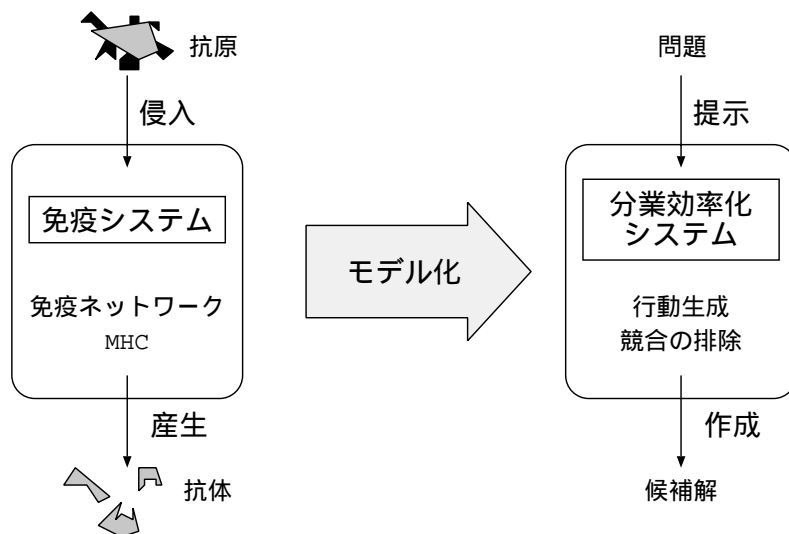


図 6.2: 免疫システムと分業効率化システム

6.3.2 MHC

免疫システムでは、自己を MHC (Major Histocompatibility Complex) と呼ばれるユニークな情報で定義している [Janeway 1997, 垣内 1996, 多田 1996, 藤原 1997]。非自己の認識は、非自己を取り込んだ免疫細胞上の MHC が非自己上の部分情報と結合 (MHC+peptide) し、変化することによって行われる (図 6.3)。免疫システムでは、この MHC の変化を非自己の侵入として認識し、その MHC が変化した細胞が無くなるまで非自己の排除を行う。

非自己の排除とは、図 6.3 の下部に示したように、自己システム内に存在する非自己システムをシステム外へ取り除くことである。この非自己システムを排除する機構を、マルチエージェントシステムにおける作業領域の分業タスクとして置き換えると、

1. エージェントの作業領域に、他のエージェントとの重なり合う競合が存在する状態 (図 6.3 (a)) から、
2. 重なり合う作業領域を排除した状態 (図 6.3 (b))、

へと状態を変化させるための処理と考えられる。本研究では、MHC による非自己排除を次のように定義し、分業問題を解決するシステムとして応用する。

- MHC = エージェント群の作業領域に存在する競合を取り除く機構、

このように、作業領域の分業問題を解決する手法の一つが、MHC を用いた競合排除である。競合が無い状態において、より良い分業を獲得するための手法としては、次に述べる免疫ネットワークを用いる。

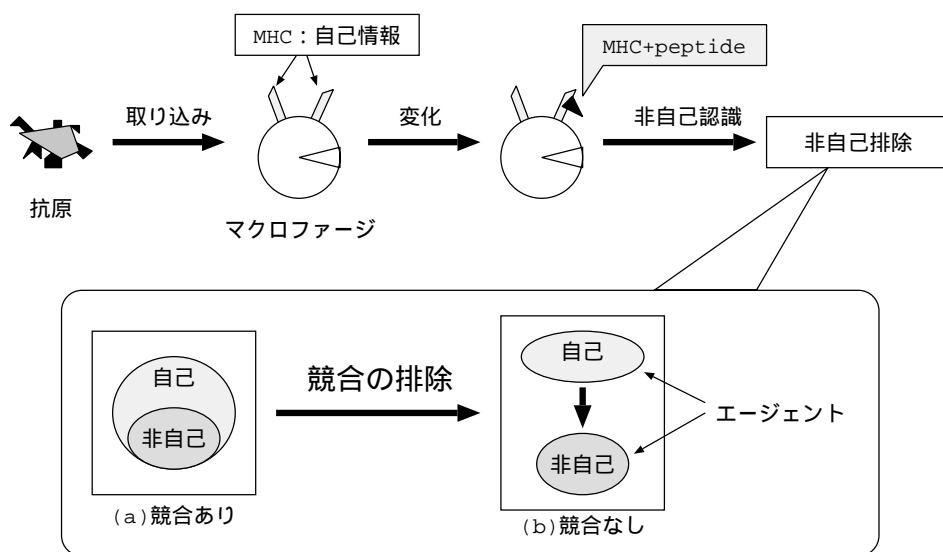


図 6.3: MHC によるエージェント間の競合排除

6.3.3 免疫ネットワーク

免疫システムにおいて、各種免疫細胞群とそれらの結合により構成されるネットワークを免疫ネットワークと呼び、その構成要素の再構築を繰り返すことで免疫応答を調節する(図 6.4 左)。具体的には、下記のような情報伝達と動作を行う。

マクロファージ：

ネットワーク上で伝達される情報の一つが先に述べた MHC であり、生体内に抗原が侵入したというシグナルや、抗原に関する情報がマクロファージにより伝達される。

T 細胞：

MHC を伝達された T 細胞は、感染細胞を排除し、さらに抗原自体を認識することが可能な B 細胞の活性化を促す。

B 細胞：

活性化された B 細胞は、その抗原に関する記憶を残すと共に、抗体を産生する。

抗体：

産生された抗体が抗原排除を行うことで、生体防御を果たす。

免疫ネットワークをエージェントの行動生成モデルとして用いるため、図 6.4 右に示したモデルを構築した。具体的には、次のように動作する。

環境情報取得：

エージェントが存在する外界情報やエージェント内部の情報である環境情報を取得する。

競合排除：

エージェントの内部状態に競合が存在するならば，その競合を排除する．

行動探索：

現在の内部状態の環境に対する適応度を高めるために行動探索を行う．

優良解抽出：

行動探索の結果から，最も適応度が高い解を抽出する．

抽出された解は，環境へ適用される．その後は，この行動生成モデルを繰り返し実行することで，適切な分業を実現するための行動獲得を行う．

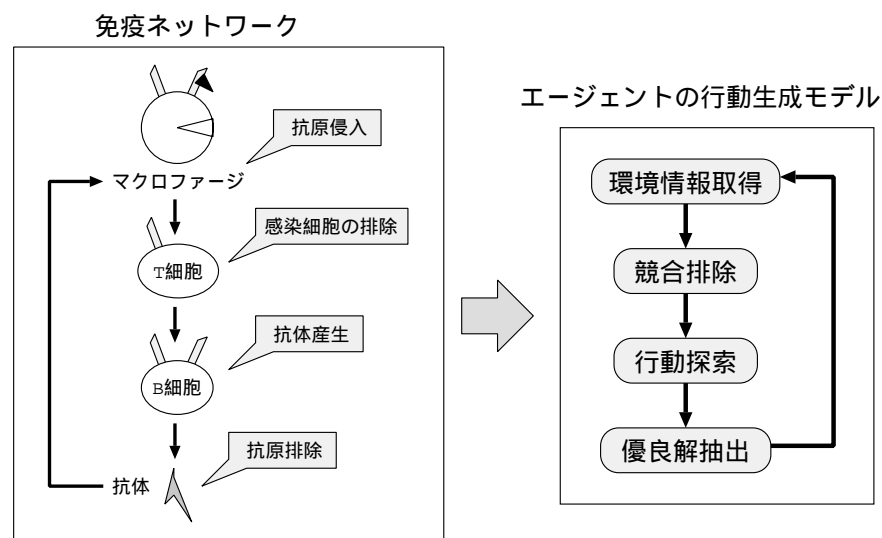


図 6.4: 免疫ネットワークによる行動生成

6.4 結言

本章では，生体（自己）内に侵入した抗原を非自己として認識し，非自己を排除するために用いられる MHC と，認知した非自己を排除するために用いられる免疫ネットワークの概要を述べ，さらに，マルチエージェントシステムにおける分業問題を解決するシステムとしてのモデル構築を行った．構築したモデルを応用することにより，

1. MHC による競合排除，
2. 免疫ネットワークによる行動生成，

という分業効率化システムが構築できる．

第7章 免疫的分業効率化アルゴリズム

7.1 緒言

第6章で述べた免疫システムは、自己と非自己を MHC により認識・識別し、非自己に対しては免疫ネットワークにより適切な抗体を産生し、排除するというモデルであった。また、マルチエージェントシステムにおける分業問題を解決するシステムとしてのモデル構築を行った。構築したモデルを応用することにより、

1. MHC による競合排除、
2. 免疫ネットワークによる行動生成、

という分業効率化システムが構築できる。

本章では、上記の免疫モデルを応用した、免疫的分業効率化アルゴリズムを示す。

7.2 免疫的分業効率化

構築したアルゴリズムでは、免疫ネットワーク上で MHC が伝達され、その構成要素を再構築することにより、適切な抗体を産生する。MHC とは、非自己が侵入してきた際に、MHC+peptide へと変化することで、自己情報と非自己情報を同時に保持することが可能な情報媒体である。MHC が非自己情報を含む状態を競合と呼ぶ。提案するアルゴリズムでは、競合排除や免疫ネットワークにより適切な分業を獲得する。

7.2.1 免疫的分業効率化アルゴリズム

以下に、構築したアルゴリズムを示す(図 7.1)。

[Step1. 抗原と MHC の定義]

エージェントの存在する問題領域を抗原、内部状態(解)を MHC として定義する。

[Step2. 初期 MHC の生成]

エージェントの初期行動を生成する。

[Step3. 環境情報の取得]

エージェントが存在する外界情報やエージェント内部の情報である環境情報を取得する。取得した環境情報は、内部状態と共に MHC として記述し、以下の処理へ伝達する。

[Step4. 競合処理]

伝達された MHC に競合が存在するならば，後述の競合処理により競合状態を排除する．

[Step5. 類似解群の作成]

環境情報と，競合の無い内部状態で構成される MHC を基に，それに類似する解を N 個作成する．類似度や類似解の作成方法は，問題に固有の設定である．

[Step6. 最大適応度を抽出]

作成した類似解の中から，最も適応度が高い解を抽出し，実行する．以下，Step3 ~ Step6 を繰り返すことで，環境や他のエージェントと相互作用し，分業に適した行動へと適応する．

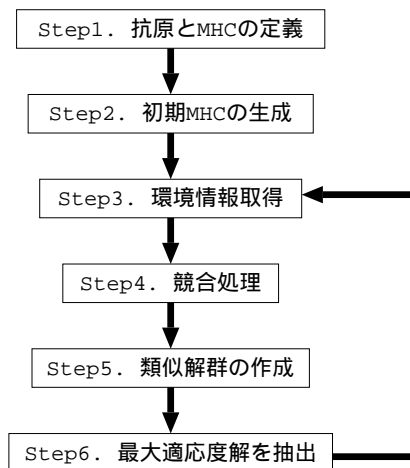


図 7.1: 免疫的分業効率化アルゴリズム

7.2.2 競合処理

免疫的分業効率化アルゴリズムの Step4 で行われる競合処理は，競合エージェント間における適応度比較により競合を排除する機構である．アルゴリズムを示す前に，ここで用いる記号を表 7.1 に定義する．表 7.1 において「競合を排除した」とは，各エージェントの作業領域から競合領域を排除したことを意味する．

以下では，自己エージェント A の作業領域 $MHC(A)$ 内に，非自己エージェント B が侵入した状況（式 7.1）を例に説明する（図 7.2）．

$$MHC(A) \cap MHC(B) \neq \emptyset \quad (7.1)$$

表 7.1: 緒定義

	自己エージェント A	非自己エージェント B
現在の作業領域	$MHC(A)$	$MHC(B)$
競合を排除した作業領域	$MHC(A')$	$MHC(B')$
現在の適応度	$fitness(A)$	$fitness(B)$
競合を排除した適応度	$fitness(A')$	$fitness(B')$

[Step1. 自己エージェント内の適応度比較]

競合領域を排除する前の適応度 $fitness(A)$ と、競合領域を排除した後の適応度 $fitness(A')$ を比較する。その結果、 $fitness(A')$ が高いならば自己の作業領域を $MHC(A')$ へ修正し、競合を排除する。逆に、 $fitness(A)$ が高いならば Step2. へ。

[Step2. 非自己エージェントとの適応度比較]

$fitness(A)$ と、競合相手である非自己エージェントの適応度 $fitness(B)$ を比較する。その結果、 $fitness(A)$ が高いならば非自己エージェントの作業領域を $MHC(B')$ へ修正し、逆に、 $fitness(B)$ が高いならば自己の作業領域を $MHC(A')$ へ修正する。

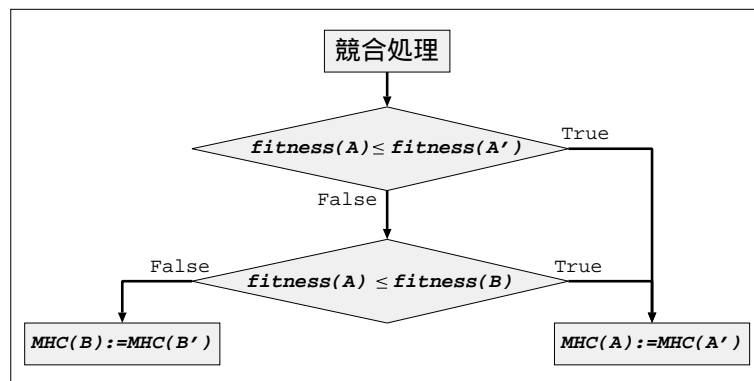


図 7.2: 競合処理例

7.2.3 動作概念と特徴

提案する免疫的分業効率化アルゴリズムは (1) MHC による競合排除と (2) 免疫ネットワークによる行動生成から構築される。この構成により、

1. 免疫ネットワークの行動生成により、各エージェントはエージェント内部の適応度を高める方向 (作業領域拡大) へ適応が進む。

2. MHC の競合排除により，各エージェントの作業領域における非効率な領域を排除する方向（作業領域縮小）へ適応が進む．

という，相反する二つの適応を内在している（図 7.3）．これらの相互作用により，効率の良い分業を探索することが可能となる．




図 7.3: nTSP に対する分業効率化システムの処理例

7.3 結言

本章では（1）MHC による競合排除（2）免疫ネットワークによる行動生成，を応用した免疫的分業効率化アルゴリズムについて述べた．提案アルゴリズムは，

1. 免疫ネットワークの行動生成により，各エージェントはエージェント内部の適応度を高める方向（作業領域拡大）へ適応が進む．
2. MHC の競合排除により，各エージェントの作業領域における非効率な領域を排除する方向（作業領域縮小）へ適応が進む．

という，二つの相反する適応を内在しており，これらの相互作用により，効率の良い分業を探索する手法である．

次章では，提案手法の有効性を検証するために行った計算機実験について述べる．

第8章 計算機実験2

8.1 緒言

第6章から第7章にかけて，マルチエージェントシステムにおける分業問題効率化手法として，免疫システムのMHCと免疫ネットワークを用いた枠組を構築し，それを応用した免疫的分業効率化アルゴリズムについて述べた．

本章では，提案手法を実験的に評価するために，マルチエージェントシステムの典型的な評価問題である分業巡回セールスマン問題を対象とし，計算機実験によってその基本性能を検証する．まず，対象問題である分業巡回セールスマン問題を定義し，その性質について述べる．

8.2 分業巡回セールスマン問題 (nTSP)

8.2.1 TSP と nTSP

巡回セールスマン問題 TSP は，NP 困難に分類される問題の複雑さとその応用範囲の広さから，さまざまな解法による検討がなされてきた．しかし，今日の大規模複雑な工学的諸問題への対応には，各エージェント間の協力による効率良く問題を解決を行なうマルチエージェントシステムなどの，より強力な問題解決法が求められている．そこで，TSP におけるエージェント数を n 人に拡張した問題 nTSP (図 8.1) を設定し，マルチエージェント型アルゴリズムの性能評価の基準問題として位置付ける [中村 1994] ．

なお，本論文では，

条件 1: 一つの問題におけるセールスマン数を固定．

条件 2: 全セールスマンの出発都市を一致．

という二つの条件を設定した．

8.2.2 分業と最適化

nTSP は，本質的に

(1) 各セールスマンに対する都市配分と，

(2) その最短経路探索，

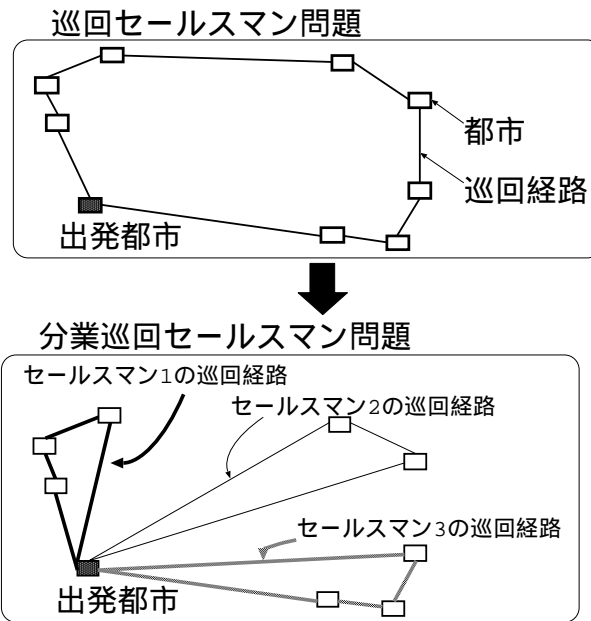


図 8.1: nTSP の概念図

という2面性を持つ。これらの2面性は、相互に関連しているため個別に逐次的に解くことが困難であるという特徴を持つ。つまり、都市の分担とTSPという2面性は、単純に分離できるものではなく、両方の問題を協調させて解く必要がある。

8.2.3 nTSPにおける免疫的分業効率化アルゴリズムの動作

実際に、免疫的分業効率化アルゴリズムを適用する前に、アルゴリズムの概念的な動作例を図8.2と図8.3に示す。以下、各図を説明する。

免疫ネットワーク

図8.2では、抗原情報とMHCを次のように定義した。

- 抗原情報 = nTSP の定義 (都市数, 都市配置, セールスマン数)。
- MHC = nTSP における解。

このように定義したMHCがネットワーク上で伝達され、適切な解へと再構築される。また、免疫ネットワーク上の処理は下記のように行われる。

1. マクロファージでは、抗原とMHCを認識し、nTSP情報と解情報をMHCとして結びつけ、それをT細胞へと伝達する。この時、自己エージェントの解に存在する競合状態もMHCとして伝達される。

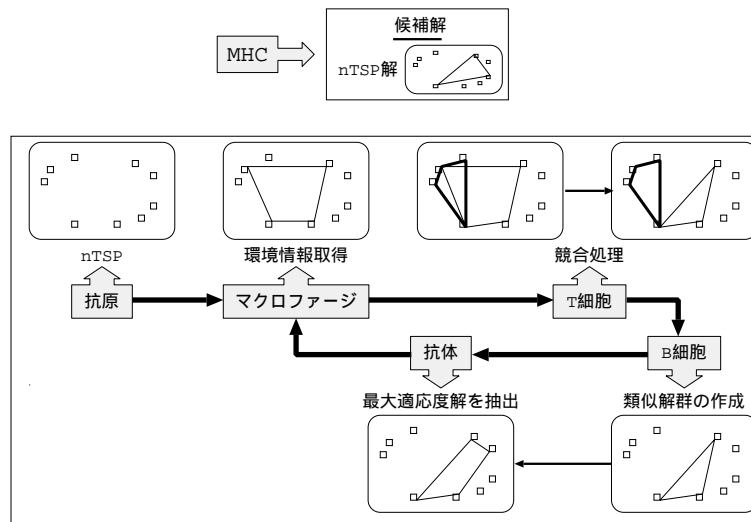


図 8.2: nTSP に対する分業効率化システムの処理例

2. T 細胞では，自分の作業領域である巡回経路に，他のエージェントの巡回経路に重複した都市があることを示している．この重複した都市を一方のセールスマンのみで巡回するように修正するため，競合処理を用いる．
3. B 細胞では，競合が排除された解が伝達され，その解に類似する解を N 個作成することで，適応度の高い解を探索する．
4. 最後に，作成された類似解の中から最も適応度が高い解を抽出し，次状態における候補解とする．

競合処理

図 8.3 は，*Salesman A, B* の巡回経路に競合状態が存在する一例を示している．

1. 最初の比較では，セールスマン A 自身の適応度を比較する．競合都市 T を含めた適応度 $f(A)$ が高いならば，セールスマン B との比較へと進む．逆に，競合都市 T を除いた適応度 $f(A')$ が高いならば，セールスマン A 自身の巡回経路から T を除き，終了する．
2. 第二の比較では，セールスマン B の適応度と比較する．もし， $f(A)$ が高いならば，競合相手であるセールスマン B の巡回経路から T を除き，終了する．逆に， $f(B)$ が高いならば，セールスマン A 自身の巡回経路から T を除き，終了する．

8.2.4 適応度関数と類似解作成手法の設計

提案手法を nTSP に適用するには (1) 適応度関数と (2) 類似解の作成手法を設計する必要がある．

式 (8.1) に示した適応度は，分業効率の最適化を目的とするため，

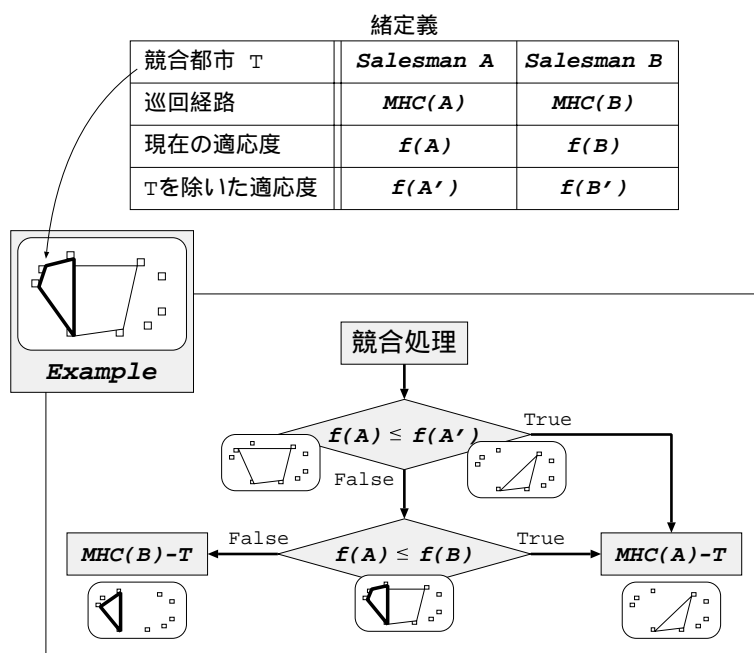


図 8.3: 競合処理例

- 初項では，巡回経路に含まれる都市数 $Cities$ を巡回経路長 $Cost$ で除し，多くの都市数を少ないコストで探索する解が高適応度となる．
- 第二項では，巡回に要するコストが高くなるほど適応度が低くなる．

の二点を含めた関数とした．また，類似解を作成する手法としては (a) 現在の巡回経路に未訪問の一都市を含めたもの，もしくは (b) 現在の巡回経路内の任意の二都市の巡回順番を入れ換えたもの，という二通りの手法を導入した．

[適応度]：エージェント i の評価値

$$fitness_i = Cities(MHC(i))/Cost(MHC(i)) + 1/Cost(MHC(i)) \quad (8.1)$$

- $MHC(i)$ ：エージェント i の巡回経路
- $Cities(MHC(i))$ ：エージェント i の巡回経路に含まれる都市数
- $Cost(MHC(i))$ ：エージェント i の巡回経路長

8.3 実験設定

8.3.1 問題設定

提案手法の基本性能を確認するため， $nTSP$ を対象問題とした計算機実験を行う．実験では，出発都市を円の中心とした円周上に他の 24 都市を配置した 25 都市 3TSP を扱う．問

題設定を表 8.1，提案手法で用いたパラメータを表 8.2 に示す．表 8.2 において，巡回都市増加確率と巡回順番スワップ確率とは，類似解作成時に用いる値である．

表 8.1: 問題設定

都市数	25
都市配置	円形
出発都市	円の中心
半径	0.4
セールスマン数	3
ステップ数	100

表 8.2: パラメータ

B 細胞総数	25
巡回都市増加確率	0.5
巡回順番スワップ確率	0.5

8.3.2 結果と考察

まず最初に，分業効率化アルゴリズムにより獲得した分業結果を図 8.4 に示す．
図 8.4 より，以下の二点を確認することができる．

1. 各セールスマンの訪問した都市数は（出発都市を含めないで）8 都市であり，平等な作業領域の分割が実現している．
2. 各セールスマンの分担領域における解は，明らかに最適解である．

よって，提案手法により，分業問題を適切に解けることを示した．以下，各セールスマンの適応度推移と，作業領域の分割がどのように推移しているかを示し，考察する．

各セールスマンの適応度推移

ステップ毎の適応度推移を図 8.5 に示す．図 8.5 の *System* とは，システム全体の分業効率を示す値であり，全セールスマンの適応度の総和により求めた．

図 8.5 より確認できることは，下記の通りである．

- 全セールスマンの適応度は，多少の減少は見られるものの，全体としては単調な右上がりの推移を示している．

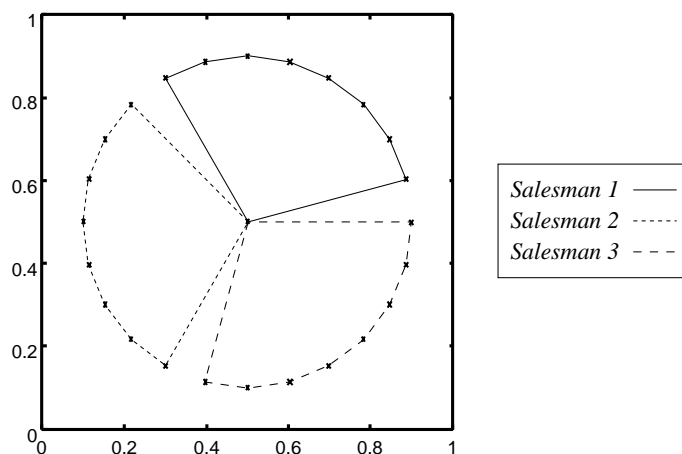


図 8.4: 獲得した分業

提案手法において、候補解が再構築されるのは (1) 競合状態を排除した (された) 場合、もしくは (2) 類似解作成により適応度が上昇した場合、のみである。従って (1) の競合排除や (2) の適応度上昇の結果が図の適応度上昇として現れる。同様に (1) の競合状態を排除された場合には、適応度低下が生じるはずであるが、図 8.5 からは殆んど確認することができない。そこで、競合が排除されているかを確認するために、各セールスマンの作業領域である巡回経路に含まれる都市数の推移を検証する。




図 8.5: システム全体と各エージェントの適応度推移

作業領域サイズの推移

図 8.6 に、各セールスマンの巡回経路に含まれる都市数（作業領域サイズ）の推移を世代毎に示した。

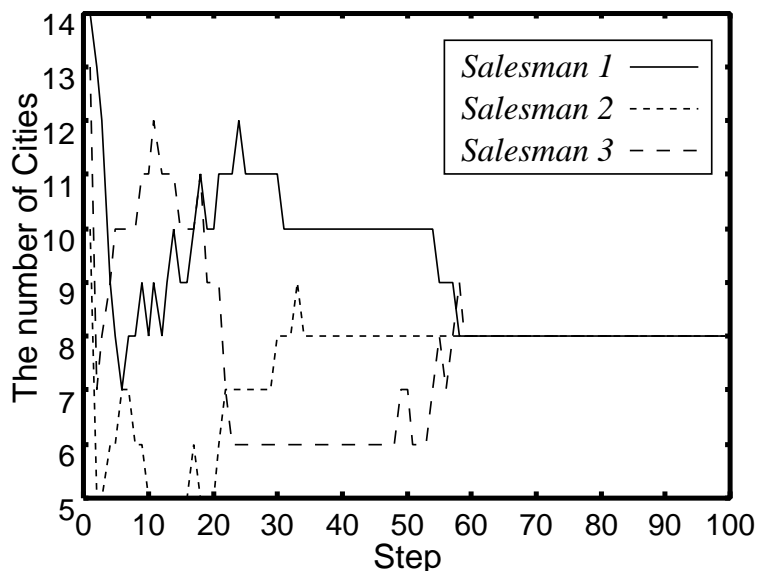


図 8.6: 各セールスマンの訪問都市数の推移

図 8.6 より、下記のことが確認できる。

- 先に示した適応度の単調な推移とは異なり、30 ステップ付近までは各セールスマンの作業領域が大きく変動している。
- 60 ステップ以降では、各セールスマンの作業領域が都市数 8 に収束した。

このように、作業領域サイズの変動は激しく行われているが、先に示した適応度は安定して上昇していることから、適応度を保持しつつ作業領域を移動していると考えられる。特に、作業領域の変動幅が非常に大きいステップに着目すると (1) 0~10 ステップ近辺 (2) 15~25 ステップ近辺 (3) 50~60 ステップ、の 3 箇所が確認できる。これらのステップにおける解の変化過程を図 8.7 に示し、考察する。

(1) 0~10 ステップ：

各セールスマンの初期作業領域は、環境情報や先験情報を用いず、ランダムに生成される。よって、作業領域の重なりや、未作業の領域が多く含まれており、競合排除等により解の再構築が頻繁に実行される。その影響が図 8.6 に示した作業領域の変動と、図 8.7 (1) に示した解の変化として現れた。

(2) 20 ステップ近辺：

図 8.5 において、20 ステップ近辺では、適応度の上昇度合が比較的高くなっているの

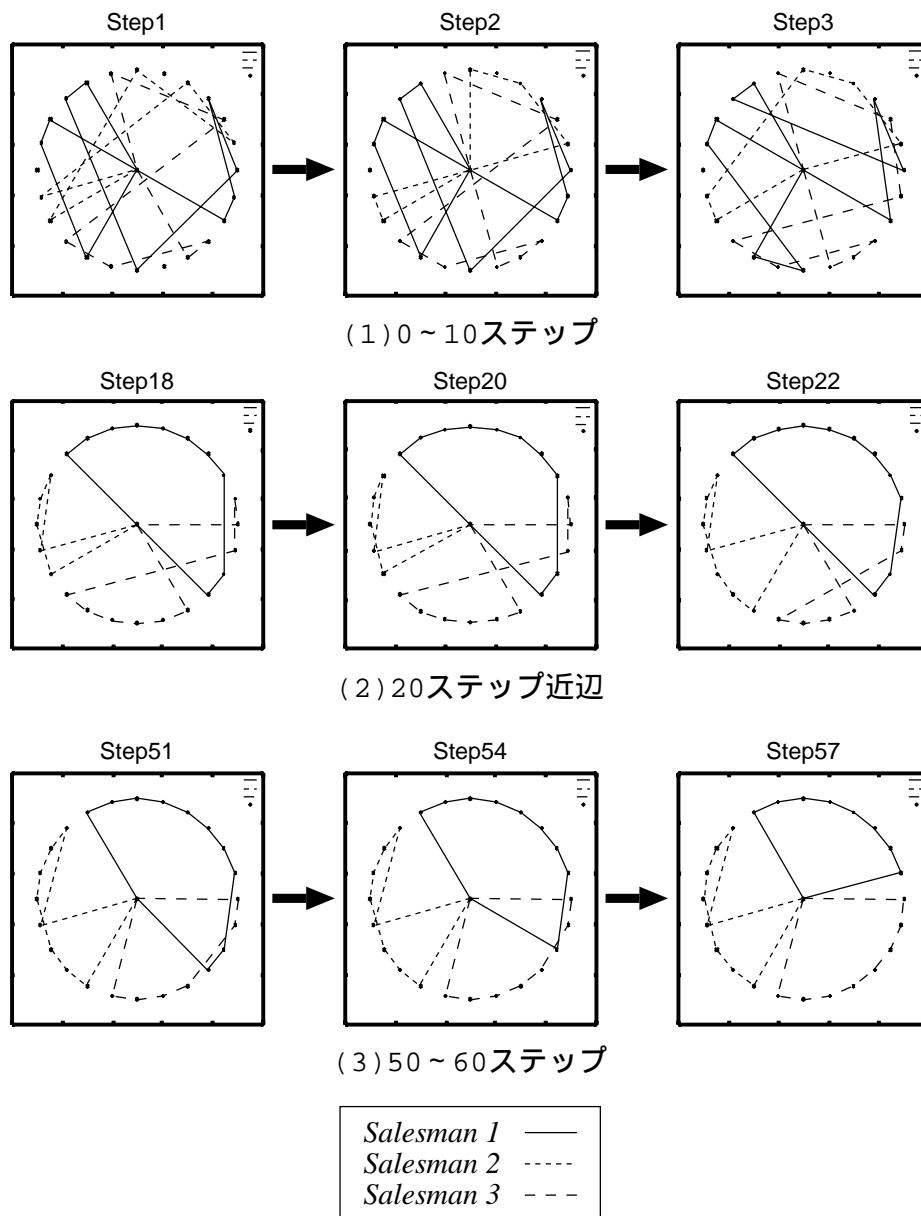


図 8.7: 各セールスマンの解の変化過程

が確認できる。また，図 8.6 に示した作業領域の大きな変動は，セールスマン 3 の減少により生じている。これらの結果から，セールスマン 3 はそれまで大きい作業領域において活動していたが，その作業領域の分割結果が効率の良い分割では無いため，一旦作業領域の縮小を図っていると考えられる。実際，図 8.7 (2) に示したように，セールスマン 3 の作業領域がセールスマン 1 と 2 の作業領域へ移り変わる様子が確認できた。

(3) 50~60 ステップ：

再び，図 8.5 の適応度推移を確認すると，先程と同様に適応度の上昇度合が良い。そ

して、図 8.6 では、セールスマン 1 の作業領域の減少と、セールスマン 3 の作業領域の増加が確認できる。この作業領域の変動結果が、セールスマン 2 は 40 ステップ目以降では収束しているが、セールスマン 1 とセールスマン 3 の作業領域に存在した競合の排除として現れている（図 8.7(3)）。

8.4 結言

マルチエージェントシステムにおける分業問題の解決を目的とした、免疫的分業効率化アルゴリズムの動作確認および基本性能の検証を行った。実験の結果、最適な分業結果の獲得を確認し、さらに以下のことについて考察した。

適応度推移における変動の小ささ：

提案手法では、競合状態の排除と類似解群の作成により解探索を行うため、適応度の増減が激しいと予想していたが、適応度の減少はほとんど確認できなかった。一方で、作業領域サイズの変動は激しく行われていることから、適応度を保持しつつ作業領域を移動していることが確認できた。

作業領域サイズにおける大きな変動：

作業領域サイズの推移は、非常に変動が激しいが、ステップの進行と共に適応度が上昇していることから、適応度を保持しつつ作業領域を変移している。特に、作業領域の変動が大きい箇所では、適応度の上昇度合が良好である箇所と同一であることを確認した。

第9章 結論

本論文では，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，多峰性関数へ適用することで提案手法の有効性を検証した．

多峰性関数において複数最適解を獲得する手法として，森らの免疫アルゴリズム(IA)が提案されたが(1)記憶獲得と探索抑制のためのパラメータ設定が非常に困難であり，また(2)獲得した優位解は二度目以降の問題解決時にのみ活用するという優位解の利用形態に関する検討の余地があった．

本論文では，前述の課題を解決するため，

- 免疫システムにおける抗体産生を調節する三大機構(一次免疫応答，二次免疫応答，探索抑制)を工学モデルとして定義．
- その工学モデルを応用した探索手法を構築．
- 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，効率の良い問題解決の実現．

という過程を経て，二種類の記憶機構を実現した．前述の検討点(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．

計算機実験では，巡回セールスマン問題におけるだまし問題と，Bipolar Deceptive Functionへ適用し，提案手法の有効性を検証した．AMIAの動作確認を行った実験1と実験2では，

- 局所探索の妥当性
- 記憶獲得の安定性
- 高適応度の解探索可能性

を確認した．また，AMIAの性能評価を行った実験3では，

- 探索効率の向上
- 優位解獲得の効率化

を示した。以上の結果より、本論文で提案した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有効性を確認することができた。

さらに、本論文では、構築した基礎理論をもとに、免疫的手法の更なる工学応用可能性を検証するため、工学分野の一つであるマルチエージェントシステムへの適用を試みた。

マルチエージェントシステムとは、分散人工知能の研究領域の一つであり、ロバスト性・適応性・即応性などの性質を期待されている。このような性質を実現する分散問題解決システムを構築するため、多数のエージェントにどのように仕事を割り振るのか、という課題に重点をおいた分業問題効率化システムを構築した。構築した免疫的分業効率化アルゴリズムは、

- 免疫ネットワークの行動生成により、各エージェントはエージェント内部の適応度を高める方向（作業領域拡大）へ適応が進む。
- MHCの競合排除により、各エージェントの作業領域における非効率な領域を排除する方向（作業領域縮小）へ適応が進む。

という、二つの相反する適応を内在しており、これらの相互作用により、効率の良い分業を探索する手法である。

提案手法の基本性能を実験的に検証するため、マルチエージェントシステムの典型的な評価問題である分業巡回セールスマン問題へ適用した。実験により、複数のエージェント間の相互作用により、与えられた問題における最適な分業結果の獲得を示した。

最後に、今後の課題として、免疫的最適化アルゴリズムにおいては（１）試行錯誤的に行うパラメータ調節の容易な設計手段の実現（２）問題に特化した最適化システムの構築、そして免疫的分業効率化アルゴリズムにおいては（３）他の手法との性能比較による有効性検証、等が考えられる。これらを実現するためには、記憶獲得と探索抑制のためのパラメータ調整を自動化するための検討や、免疫システムの特異性を実装するためのモデル構築などをする必要があるだろう。

謝辞

本論文は、著者が琉球大学在学中に、玉城史朗教授、遠藤聡志助教授、山田孝治助教授の御指導のもとに行った研究をまとめたものである。本研究をまとめるにあたり、多大なる御指導、御鞭撻を賜った琉球大学情報工学科玉城史朗教授、遠藤聡志助教授、山田孝治助教授に心より感謝の意を表します。

本論文を完成させるにあたり有意義な御指導と御鞭撻を賜った宮城隼夫教授に深く感謝いたします。

また、本論文を執筆するにあたり、免疫学における適切な御指摘を頂いた 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、並びに、人工免疫の設計・応用に関し貴重な御意見、御討論を頂いた、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にも深く感謝致します。

最後に、常日頃よりセミナーなどで貴重な意見と御支援頂きました、遠藤・山田研究室の博士二年根路銘もえ子女史、修士一年玉城清政君、および学部生の皆さんに深く感謝致します。

参考文献

- [Ballet 1998] P. Ballet, J. O. Pers, Y. Rodin, J. Tisseau : A Multi-agent System to Simulate an Apoptosis Model of B-CD5 Cells, IEEE International Conference on Systems, Man, and Cybernetics (SMC) '98 Conference Proceedings, pp.3799-3803 (1998).
- [Celada 1998] Franco Celada and Philip Seiden : Modeling Immune Cognition, IEEE International Conference on Systems, Man, and Cybernetics (SMC) '98 Conference Proceedings, pp.3787-3792 (1998).
- [Dasgupta 1998] Dipankar Dasgupta : An Artificial Immune Systems as a Multi-Agent Decision Support System, IEEE International Conference on Systems, Man, and Cybernetics (SMC) '98 Conference Proceedings, pp.3816-3820 (1998).
- [Dasgupta 1999] Dipankar Dasgupta (editor) : Artificial Immune Systems and Their Applications (1999).
- [Endo 1998] Satoshi Endo, Naruaki Toma, Koji Yamada : Immune Algorithm for n-TSP, IEEE International Conference on Systems, Man and Cybernetics (SMC) '98 Conference Proceedings, pp.3844-3849 (1998).
- [Forrest 1990] S. Forrest, A.A. Perelson. : Genetic algorithm and the Immune system, Proc. of 1st Workshop on Parrallel Problem Solving from Nature (PPSN), pp.320-325 (1990).
- [Goldberg 1987] D. E. Goldberg and J.Richardson : Genetic Algorithms with Sharing for Multimodal Function Optimization, Proc. of the Second Intern. Conf. on Genetic Algorithms, pp.41-49 (1987).
- [Goldberg 1989] D. E. Goldberg : Genetic Algorithms in Search, Optimization, and Machine Learning. Addison-Wesley (1989).
- [Goldberg 1992] Devid E. Goldberg, Kalyanmoy Deb, and Jeffrey Horn : Massive Multimodality, Deception, and Genetic Algorithms, PPSN 2 (1992).
- [Grefenstette 1985] J.Grefenstette, R.Gopal, B.J.Rosmaita and D.Van Gucht : Genetic Algorithms for the Traveling Salesman Problem, Proc. of ICGA '85, 16/168 (1985).

- [Holland 1992] John H. Holland : Adaptation in Natural and Artificial Systems, MIT Press (1992).
- [Ishiguro 1998] Akio Ishiguro, Shingo Ichikawa, Takanori Shibata, Yoshiki Uchikawa : “Moderationism in the Immune System: Gait Acquisition of a Legged Robot Using the Metadynamics Function”, IEEE International Conference on Systems, Man, and Cybernetics (SMC) '98 Conference Proceedings, pp.3827-3832 (1998).
- [Janeway 1997] Charles A. Janeway, Jr / Paul Travers / Simon Hunt / Mark Walport : “Immunobiology : The Immune System in Health And Disease” (1997).
- [Kennedy 1998] Catriona M. Kennedy : Evolution of Self-Definition, IEEE International Conference on Systems, Man, and Cybernetics (SMC) '98 Conference Proceedings, pp.3810-3815 (1998).
- [Mori 1998] Kazuyuki Mori, Makoto Tsukiyama and Toyoo Fukuda : Adaptive Scheduling System Inspired by Immune System : IEEE International Conference on Systems, Man, and Cybernetics (SMC) '98 Conference Proceedings, pp.3833-3837 (1998).
- [Russell 1995] Stuart Russell and Peter Norvig : Artificial Intelligence: A Modern Approach, Prentice-Hall (1995).
- [Thomas 1997] Thomas Back (editor) : Proceedings of The Seventh International Conference on Genetic Algorithms, Morgan Kaufmann (1997).
- [石黒 1997] 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).
- [石田好輝 1998] 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).
- [石田亨 1996] 石田 亨, 片桐 恭弘, 桑原 和宏 : 分散人工知能, コロナ社 (1996).
- [伊庭 1994] 伊庭 斉志 : 遺伝的アルゴリズムの基礎-GA の謎を解く-, オーム社 (1994).
- [遠藤 1999] 遠藤 聡志, 當間 愛晃, 山田 孝治 : 適応的免疫アルゴリズムの多峰性関数への適用, 第 9 回インテリジェント・システム・シンポジウム, 講演論文集, pp.608-611 (1999).
- [垣内 1996] 垣内 史堂 : 絵とき 免疫学の知識, オーム社 (1996).
- [北野 1993] 北野 宏明 : 遺伝的アルゴリズム, 産業出版 (1993).
- [廣田 1996] 廣田 薫 : 知能工学概論, 昭晃堂 (1996).

- [坂和 1995] 坂和 正敏, 田中 雅博 : 遺伝的アルゴリズム, 朝倉書店 (1995).
- [三宮 1998] 三宮 伸夫, 喜多 一, 玉置 久, 岩本 貴司 : 遺伝的アルゴリズムと最適化, 朝倉書店 (1998).
- [島 1995-a] 島 孝司 : すみ分け型エボリューション・アルゴリズムによる大域最適化, システム制御情報学会誌, Vol. 8, No. 2, pp.94-96 (1995).
- [島 1995-b] 島 孝司 : すみ分け型遺伝的アルゴリズムによる大域最適化, システム制御情報学会誌, Vol. 8, No. 5, pp.233-235 (1995).
- [白井 1997] 白井 靖浩, 渡邊 祐司, 石黒 章夫, 内川 嘉樹 : 免疫ネットワークを用いた自律移動ロボットの行動調停 ~ GA を用いたメタダイナミクス機能の実現 ~, 第 7 回 インテリジェント・システム・シンポジウム (1997).
- [高橋 1998] 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 1993-a] 多田 富雄 : 免疫の意味論, 青土社 (1993).
- [多田 1993-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).
- [多田 1996] 多田 富雄 : 免疫・「自己」と「非自己」の科学, 日本放送出版協会 (1996).
- [多田 1999] 多田 富雄 : 生命をめぐる対話, 大和書房 (1999).
- [寺野 1999] 寺野 隆雄 : 道しるべ : GA を使いこなすには, IPSJ Magazine, Vol.40, No.6, June (1999).
- [當間 1998] 當間 愛晃, 遠藤 聡志, 山田 孝治 : 免疫システムに基づく組合せ最適化アルゴリズムの検討, ヒューマンインフォメーション研究会, 映情学技報 VOL.22, NO.33, pp.49-54 (1998).
- [當間 2000] 當間 愛晃, 遠藤 聡志, 山田 孝治 : 適応的免疫アルゴリズムを用いた多峰性関数最適化, コンカレント工学研究会, 電子情報通信学会技術研究報告 信学技報, pp.71-76 (2000).
- [長尾 1990] 長尾 真・石田 晴久 他 : 岩波情報科学辞典, 岩波書店 (1990).
- [中村 1994] 中村 友洋, 角田 達彦, 田中 英彦 : 分業セールスマン問題のニューラルネットワークによる解法, 人工知能 94-2 (1994).
- [生天目 1998] 生天目 章 : マルチエージェントと複雑系, 森北出版株式会社 (1998).
- [西山 1995] 西山 賢一 : 免疫ネットワークの時代, NHK ブックス (1995).

- [沼岡 1998] 沼岡 千里, 大沢 英一, 長尾 確 : 分散協調メディアシリーズ 11 マルチエージェントシステム, 共立出版 (1998).
- [藤原 1997] 藤原 道夫 : コア免疫学, 丸善株式会社 (1997).
- [星野 1992] 星野 力 : 遺伝的アルゴリズム [2], bit(Vol.24, No.10, 1992).
- [森 1993] 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 1997] 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 1997] 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 1992] 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).
- [米澤 1993] 米澤 保雄 : 遺伝的アルゴリズム, 森北出版株式会社 (1993).
- [和田 1992] 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).

付録 A 研究業績

本研究を進めるにあたり客観的な評価を得るために、以下の学術講演等の学会活動を行った。

A.1 学術講演

国際学会

1. Satoshi Endo, Naruaki Toma, Koji Yamada : Immune Algorithm for n-TSP, The IEEE International Conferences on Systems, Man and Cybernetics, pp.3844-3849. San Diego, USA (October 5-7, 1998).
2. Naruaki Toma, Satoshi Endo, Koji Yamada : Immune algorithm with immune network and Major Histocompatibility Complex, IEEE International Symposium on Artificial Life and Robotics (AROB) 4th '99, pp.391-394, Vol2. Oita, Japan (January 19-22, 1999).
3. Naruaki Toma, Satoshi Endo, Koji Yamada : Immune algorithm with Immune Network and MHC for adaptive problem solving, The IEEE international Conference on Systems, Man and Cybernetics, (CD-ROM) pp.IV-271-276. Tokyo, Japan (October 12-15, 1999).

一般講演

1. 當間 愛晃, 遠藤 聡志, 山田 孝治 : 免疫アルゴリズムの nTSP への適用, 情報処理学会第 55 回全国体会講演論文集 (分冊 2), pp.453-454 (1997 年 9 月 24-26 日, 福岡工業大学)
2. 當間 愛晃, 遠藤 聡志, 山田 孝治 : 免疫アルゴリズムを用いた nTSP の解法に関する検討 : 第 50 回電気関係学会九州支部記念連合大会講演論文集, pp.606 (1997 年 10 月 3-4 日, 琉球大学)
3. 遠藤 聡志, 當間 愛晃, 山田 孝治 : 免疫アルゴリズムの nTSP に関する考察 : 第 7 回インテリジェント・システム・シンポジウム, 講演論文集, pp.505-508 (1997 年 11 月 22-27 日, 北海道大学)
4. 當間 愛晃, 遠藤 聡志, 山田 孝治 : 記憶機構を活用した免疫アルゴリズムによる nTSP の解法に関する検討, 情報処理学会第 56 回全国体会講演論文集 (分冊 2), pp.331-332 (1998 年 3 月 17-19 日, 中央大学)
5. 當間 愛晃, 遠藤 聡志, 山田 孝治 : 免疫システムに基づく組合せ最適化アルゴリズム

- の検討,映像情報メディア学会ヒューマンインフォメーション研究会,映像情報メディア学会技術報告(映像学技報 VOL.22, NO.33, ISSN1342-6893), pp.49-54 (1998年6月18-19日,琉球大学)
6. 當間 愛晃,遠藤 聡志,山田 孝治:免疫ネットワークを用いた分業巡回セールスマン問題の解法に関する考察,情報処理学会第57回全国大会講演論文集(分冊2), pp.335-336 (1998年10月5-7日,名古屋大学)
 7. 當間 愛晃,遠藤 聡志,山田 孝治:免疫ネットワークを用いた分業巡回セールスマン問題の解法に関する検討,第8回インテリジェント・システム・シンポジウム,講演論文集, pp.353-358 (1998年10月29-30日,パピヨン24会議室,福岡県)
 8. 當間 愛晃,遠藤 聡志,山田 孝治:免疫ネットワークを用いた免疫アルゴリズムに関する考察,平成10年度電気学会・電子情報通信学会合同講演会,講演論文集, pp.97-102 (1998年12月16日,琉球大学)
 9. 當間 愛晃,遠藤 聡志,山田 孝治:免疫ネットワークを用いた自律ロボットの行動制御に関する一考察,ニューロコンピューティング研究会'99,電子情報通信学会技報研究報告, Vol.99, No.131, pp.23-28 (1999年6月18日,琉球大学)
 10. 當間 愛晃,遠藤 聡志,山田 孝治:免疫ネットワークに基づく適応的最適化アルゴリズムの構築,情報処理学会第59回全国大会講演論文集(分冊2), pp.95-96 (1999年9月28-30日,岩手県)
 11. 遠藤 聡志,當間 愛晃,山田 孝治:適応的免疫アルゴリズムの多峰性関数への適用,第9回インテリジェント・システム・シンポジウム,講演論文集, pp.608-611 (1999年10月27-28日,フェニックスプラザ,福井)
 12. 當間 愛晃,遠藤 聡志,山田 孝治:適応的免疫アルゴリズムを用いた多峰性関数最適化,コンカレント工学研究会,電子情報通信学会技術研究報告 信学技報, pp.71-76 (2000年1月18日,沖縄エッカホテル)

A.2 紀要

1. 當間 愛晃,遠藤 聡志,山田孝治:免疫アルゴリズムの記憶機構を利用した nTSP の解法に関する考察,琉球大学工学部紀要,第55号, pp.77-82, 1998年3月
2. 當間 愛晃,前堂 卓也,遠藤 聡志,山田孝治:免疫ネットワークを用いた自律ロボットの行動制御,琉球大学工学部紀要,第59号, pp.129-134, 1999年9月