

免疫細胞間協同作用および抗原との共進化現象を用いた
免疫的分業問題最適化手法の提案と評価

An Immune Optimization Algorithm for the Division-of-labor Problems using an Immune Cell-cooperation and Co-evolutionary Phenomenon

第1 著者名： 當間 愛晃

所属： 琉球大学大学院理工学研究科 総合知能工学専攻

所在地： 〒 903-0213 沖縄県中城郡西原町字 1 番地 琉球大学

第2 著者名： 遠藤 聡志

所属： 琉球大学工学部情報工学科

所在地： 〒 903-0213 沖縄県中城郡西原町字 1 番地 琉球大学

第3 著者名： 山田 孝治

所属： 琉球大学工学部情報工学科

所在地： 〒 903-0213 沖縄県中城郡西原町字 1 番地 琉球大学

第4 著者名： 宮城 隼夫

所属： 琉球大学工学部情報工学科

所在地： 〒 903-0213 沖縄県中城郡西原町字 1 番地 琉球大学

第1 著者名： Naruaki Toma

所属： Graduate Student, Doctoral Course in Complex Intelligent Systems Engineering, Graduate School of Science and Engineering, University of the Ryukyus.

所在地： University of the Ryukyus, 1 Senbaru, Nishihara, Okinawa 903-0213 JAPAN.

第2 著者名： Satoshi Endo

所属： Faculty of Engineering, University of the Ryukyus.

所在地： University of the Ryukyus, 1 Senbaru, Nishihara, Okinawa 903-0213 JAPAN.

第3 著者名： Koji Yamada

所属： Faculty of Engineering, University of the Ryukyus.

所在地： University of the Ryukyus, 1 Senbaru, Nishihara, Okinawa 903-0213 JAPAN.

第4 著者名： Hayao Miyagi

所属： Faculty of Engineering, University of the Ryukyus.

所在地： University of the Ryukyus, 1 Senbaru, Nishihara, Okinawa 903-0213 JAPAN.

アブストラクト：

本論文では，マルチエージェントシステムにおける分業問題最適化を目的とした，免疫系と抗原との共進化現象を応用した免疫的最適化手法を提案する．先行研究 [7] において提案された競合型アルゴリズムでは，個々エージェントとエージェント全体における最適性とのバランス調整が困難であり，実問題への応用に当たりそれらを解消する必要があった．本手法は，免疫エージェントの細胞間協同作用による作業コスト最適化と抗原エージェントの逃避行動による平等な作業配分獲得に基づく探索を基本動作とする．抗原エージェントの逃避行動は，効率良く作業を行っている免疫系の最適化行動を妨害することで免疫エージェント全体の作業コストを平等に配分するように実装しており，免疫エージェントによる最適化との相互進化によって分業解を獲得することが可能である．計算機実験では，提案手法の基本性能および探索性能を評価するために典型的な分業問題の一つである分業巡回セールスマン問題へ適用し，考察する．

キーワード：マルチエージェントシステム，分業問題最適化，細胞間協同作用，共進化現象

ABSTRACT:

The purposes of this paper are to propose and evaluate an immune optimization algorithm using a biological immune co-evolutionary phenomenon and cell-cooperation. The co-evolutionary models searches the solution through the interactions between two kinds of agents, one of the agents is called immune agent which optimizes the cost of its own work. The other is called antigen agent which realizes the equal work assignment. This algorithm solves the division-of-labor problems in multi-agent system (MAS) through the three kinds of interactions: *division-and-integration processing* is used for optimization of the work-cost of immune agents and, *escape processing* is used to perform equal work assignment as a result of evolving the antigen agents.

The immune agent optimizes own cost using division as well as integration processing based on the immune cell-cooperation which is considered a kind of parallel-distributed system with role differentiation. The ‘splicing’ is one of the re-combination operator of genes, whose function is used for forming the role. The division as well as integration processing in our method is based on the splicing. And the antigen agent computes even division of work domain using escape processing based on a phenomenon that the antigen evolves to escape from the elimination of immune system.

In order to investigate the validity of the proposed method, this algorithm is applied to the “ N -th agent’s Travelling Salesmen Problem (called the n -TSP)” as a typical problem of MAS. The property that is believed to function as solution driver for MAS shall be clarified using several simulations.

Keywords: Multi-agent system, division-of-labor problems optimizatoin, immune cell-cooperation, co-evolutionary phenomenon.

1 はじめに

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, 3, 8, 9, 10]．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 [4] や，多峰性関数最適化 [12]，一個体による多機能型適応システム [15] など，様々な分野において研究がなされている．

生体の免疫システムにおいて抗原排除に関わる主要な機構として，細胞間協同作用と呼ばれる概念がある．免疫システムにおける抗原排除とは，本来自己体内に存在していない要素である非自己を認識することを切っ掛けに，各種の免疫細胞群が協同することでその非自己を消化・分解・中和する抗体を産生する一連の手続きをいう．細胞間協同作用は，主要組織適合遺伝子複合体 (major histocompatibility complex; MHC) と免疫ネットワーク二つの免疫機構を内包した高位の概念であり，役割分化を伴った一並列分散システムと考えられる．MHC とは，抗原排除における抗原認識に関わる細胞であり，自己と非自己を識別するために用いられる．免疫ネットワークとは，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の俗称であり，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 [5]．

一方，大規模化・複雑化の一途を辿る問題に対し，並列分散処理により実時間で実行可能な優良解を獲得する手法に関する研究が近年盛んに行われている．そのようなシステムの一つであるマルチエージェントシステム (Multi-agent system: MAS) 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，MAS における比較検証は工学的にも非常に有意義である．本論文では，エージェントにより問題を解決する際に (1) 個々エージェントの作業領域を平等に配分し，かつ (2) 各領域を担当するエージェントの作業コストを最適化することにより全体として最適な分業を獲得することを目的とした分業問題最適化を課題としており，その解決手法として免疫学に学んだ手法が有効に機能することを示す．

これまでの研究成果において提案してきた MAS を基本枠組みとする免疫的分散競合型アルゴリズムは，個々エージェントの最適性とエージェント全体での最適性とのバランス調整が非常に困難という課題が未解決の

まま残されていた [7]．分業問題の典型的な一例である分業巡回セールスマン問題 (N -th agent's Travelling Salesmen Problem: n -TSP) へ適用した [7] における評価実験では，円周上に均等に都市を配置したシングル円の問題においては最適な分業を獲得したが，円周を二重にした二重同心円型の都市配置においては平等な分業結果を獲得できておらず，計算機実験からも調整が困難であることが示されている．

エージェント間における競合型アプローチでは前述したバランス調整の問題点が生じ，その調整は解くべき問題毎に行う必要があるため，実応用の面からは適用が困難である．本論文ではより適用性の高いシステムとして，抗原を排除しようと進化する免疫系とそれから逃れるように進化する抗原に見られる共進化現象 [5] をモデルとした，次に示す二種類のエージェントが共進化的に解探索を行う分業最適化手法を提案する．

1. 作業 (免疫) エージェント: 作業エージェントとは解探索および分業解を保持する計算主体であり，役割分化を実現する細胞間協同作用を応用した分割・統合処理により動作する．分割処理とは保持する解の一部分を他の作業エージェントへ依託する探索オペレータであり，統合処理とは他の作業エージェントの解を吸収するオペレータである．分業問題において特定の作業領域を担当することが役割であり，その役割形成を通して作業領域の特定および作業コスト最適化を行う．
2. 要素 (抗原) エージェント: 要素エージェントとは，与えられた問題を実装する際に環境上に現れる要素 (例えば，巡回セールスマン問題における都市，人工蟻の捕食問題における餌など) を指す．このような要素は計算主体として設計されることは多くの場合見られない．本手法では，作業エージェントによって作業される立場である要素自体が主体となり，抗原の逃避行動をモチーフとした他の作業エージェントの最適化行動を妨害するような行動を採る．逃避行動と言っても実際に都市が移動するのではなく，効率良く作業を行っている作業エージェントの作業領域へ含まれるように作業領域を変化させるという間接的な行動で逃避を実現する．結果として，作業エージェントの保持する解の効率度は一次的に減少するが，全ての作業エージェントの効率度が均一になれば抗原はそれ以上逃げ回ることができなくなる．効率度が均一な状態とは平等な配分がなされていることを示しており，このような抗原の逃避行動により平等な作業配分獲得を目指す．

本論文では、免疫エージェントによる作業コスト最適化と、作業配分平等化という進化を採る抗原エージェントによる免疫的共進化現象に基づいた最適化手法を提案する。提案手法の探索動作を解析するため、本実験では分業問題の一例である分業巡回セールスマン問題 (N -th agent's Travelling Salesmen Problem: n -TSP) へ適用し、その探索動作を考察する。

、配送経路問題やそれに時間制約等の制約条件を設けたスケジューリング問題等のより実問題へ近づけた課題への応用が期待できる。




図 1: 分業問題率化

2 問題設計

本章では、提案手法の動作概念の理解を助けるために、まず対象とする分業問題を定式化し、その一例として計算機実験にて採用した n -TSP を紹介する。

2.1 分業問題

MAS は、分散人工知能の研究領域の一つであり、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 [6]。分散問題解決システムを構築するには、その通信手段の設計やタスク配分をどのように実現するか等の様々な課題を対象問題毎に解決する必要がある。本節で扱う分業問題最適化とは、タスク配分に重点をおいた課題であり、以下のように定義する (図 1)。

分業問題最適化：

エージェントに配分する対象問題を作業領域 WD 、全作業領域を問題領域 PD と定義する。このとき、

- (a) 作業配分平等化：問題領域 PD において、エージェント i の担当する作業領域 WD_i を平等に分割し、かつ、
- (b) 各作業コストの最適化：作業領域 WD_i におけるエージェント i の作業を最適化 (作業に要するコスト最小化) する。
- (c) 全作業コストの最適化：(a) と (b) を満足しつつ、個々エージェントの作業コスト総和、すなわち全エージェントの作業コストを最小化する。

すなわち、分業問題最適化とは予め固定された作業エージェント全てに平等に作業を配分しつつ並列分散処理する際のコストを最小に抑えることが求められる課題であり、スケジューリング問題やネットワークで接続された並列計算機におけるジョブスケジューリング [1]、巡回セールスマン問題に種々の制約を設けた課題¹

2.2 分業巡回セールスマン問題

分業問題の典型的な評価問題として分業巡回セールスマン問題 (n -TSP) を扱う。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 n -TSP (図 2) 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 [11]。

なお、計算機実験においては、「全セールスマンの出発都市を一致とする」という条件を設定した。

3 提案手法

3.1 免疫系からの知見

免疫系は、様々なウイルスや細菌にさらされている苛酷な環境の中で、如何に自己を存続させていくかと

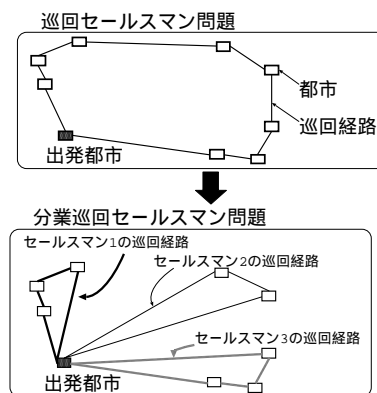


図 2: n TSP の概念図

¹ <http://www.iwr.uni-heidelberg.de/groups/comopt/software/TSPLIB95/>

いう重要な機能を担っている．生体内に侵入したウイルス等は抗原と呼ばれ，免疫系はその抗原を排除することで自己存続を実現している．免疫系における抗原排除とは，大別して (a) 免疫細胞により抗原を認識し，(b) 認識した細胞群による反応により抗原との親和度 (GA における適応度) を高め (c) その結果として産生された抗体により排除，という 3 系統の処理により行われる．これらの細胞群の反応による抗原処理は細胞間協同作用と呼ばれている (3.1.1 節)．

一方，抗原の中には免疫系の排除から逃れることで生体内に存在し続けようと抗うタイプ (病原体，ウイルス等) が存在する．排除から逃れるための抗原側の手段は多種多様であるが，先に述べた免疫系の機能，(a) の認識機構 (b) の細胞反応 (c) の抗体産生，の何れかまたは複数を妨害するものとして考えられる (図 3)．

本論文では，細胞間協同作用により抗原排除を行う免疫系と，その排除から逃れようとする抗原間に見られる共進化現象をモデルとした分業最適化手法を提案する．提案手法では，抗原を与えられた問題，免疫系を問題を解くためのエージェント群と定義しており，それらの持つ機能と最適化手法における諸定義をまとめたものが表 1 である．その抗原の逃避行動として，本稿では (b) の細胞反応を妨害する行動を実装した (3.1.2 節)．

表 1: 免疫系の持つ情報処理機構の最適化手法への適用

免疫系	工学系における定義 (論文中での呼称)
抗原	問題 (抗原エージェント)
免疫細胞	問題を解くためのエージェント (免疫エージェント)
抗体	エージェントの対象としている部分問題への解 (部分解)
新和度	部分解の部分問題に対する評価値 (コスト)
細胞反応	免疫エージェントがコストを下げるための手段 (分割・統合処理，突然変異)
抗原の逃避	抗原エージェントが，他の免疫エージェントのコストを上げるための手段 (逃避処理)

分化を伴った並列分散システムとして考えられる (図 4)．そのシステムにおける役割とは (a) 抗原の細分化及び提示 (b) 特異的に反応可能な抗体を産生する免疫細胞の活性化 (c) 特異的抗体の産生による抗原排除 (d) それらの動作制御，の 4 機能から構成される．機能としての役割だけではなく，図 5 の左に示すように一つの抗原に対し，「抗原の性質を決定する複数の抗原決定基各々に対し特定の免疫細胞が反応する」という作業分担における役割分化も含まれている．同図は役割が確定した作業分担後の概念図を示しており，実際の抗体産生の過程においてはスプライシングと呼ばれる遺伝子操作が働いている．スプライシングにより，DNA・RNA が酵素的にその一部が切り取られ，切断端部が再結合され，一つの遺伝子としての機能を持つようになる [5]．

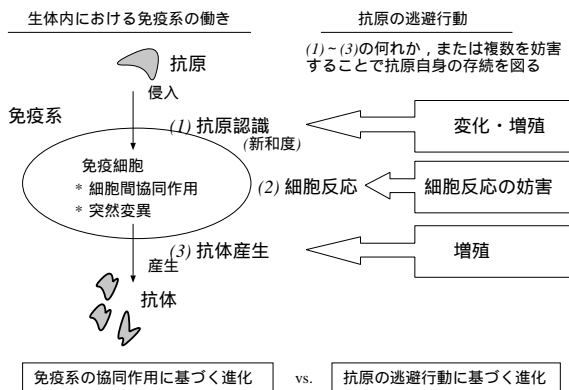


図 3: 免疫的共進化現象

3.1.1.1 細胞間協同作用による役割分化を用いた作業コスト最適化

生物の免疫系は，複数の高度情報処理機構の連携により抗原を排除している．その細胞間の連携に関わる重要な機構が MHC と免疫ネットワークであり，これらの二つの機構を含めた高位の概念を細胞間協同作用と呼ぶ．

細胞間協同作用とは，工学の視点から捉えると役割

このような作業分担における役割分化を実現している細胞間協同作用を探索アルゴリズムとして応用するにあたり，問題解決機として機能するための必要最小限の機能である (a) ~ (c) のモデル化を行った．提案手法においては，分割・統合処理と呼ばれる機能がそれに相当し，スプライシングを応用して構築した．免疫エージェントはこのような分割・統合処理を用い，抗原を問題，抗体を解として対応づけることにより (A) 問題の細分化 (B) 特異的な優位性を示す部分解により細分化された部分問題を解く (C) そのような部分解の組合せにより問題全体を解決する (図 5 右)．

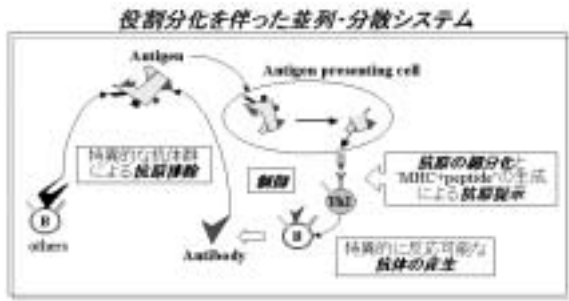


図 4: 細胞間協同作用

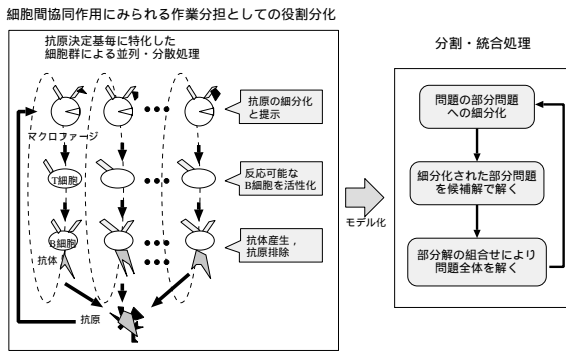


図 5: 細胞間協同作用の探索システムへの応用

3.1.2 抗原の逃避行動による共進化現象を用いた作業配分平等化

免疫系の抗原排除から逃げるように進化する抗原に対して免疫系そのものが進化するという共進化現象の概念を導入した。導入した共進化現象の目的は、逃げ回る抗原を対象問題における環境を形成する要素の変化として捉え、その抗原による逃避行動と免疫系による適応行動の共進化（図 6）により互いの妥協点となる収束解を導くことであり、[7]における個々エージェントの最適性とエージェント全体における最適性のバランス調整問題を解消することが期待できる。

このような逃避行動を実装するにあたり、本手法では抗原エージェントが作業領域 WD を変更（移動）するという間接的な行動で逃避を実現した。すなわち、環境内の要素そのものが変化するのではなく、その要素を含む作業領域 WD_i を WD_j へと変化させることで免疫エージェント i から j へ逃避することを表現した。この逃避行動は、後述のアルゴリズムに記載したように、作業コストの優れた免疫エージェントの作業領域へ変更するように行われる。結果として、免疫エージェントの保持する解の作業コストは一次的に悪化するが、全ての免疫エージェントの作業コストが均一になれば抗原はそれ以上逃げ回ることができなくなる。作業コストが均一な状態とは平等な配分がなされていること

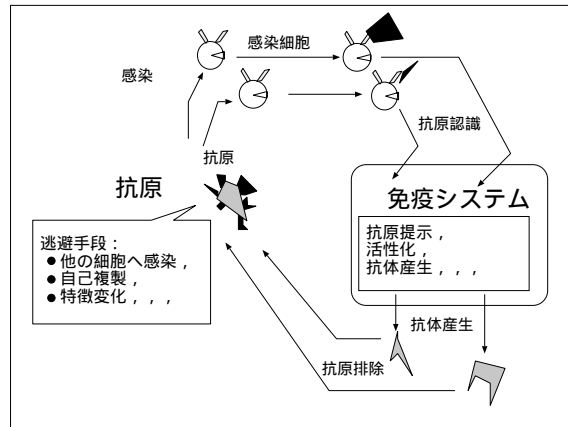


図 6: 免疫系と抗原との共進化モデル

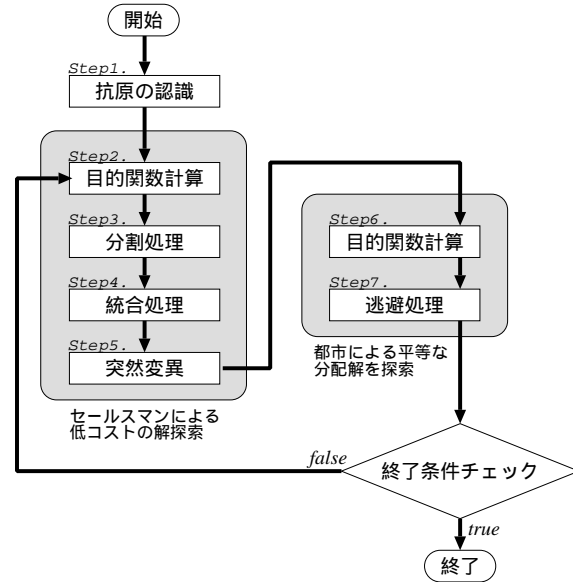


図 7: フローチャート

を示しており、このような抗原の逃避行動により作業配分平等化を目指す。

3.2 アルゴリズム

図 7 に、提案手法のフローチャートを示す。本手法は、(1) 免疫エージェント間の相互作用を基本動作とする分割・統合処理と、(2) 抗原エージェントが免疫エージェントと相互作用を行う逃避処理、という二種類のエージェントによる共進化現象に基づく探索を動作原理とする。

アルゴリズムを n -TSP に適用する際の設計を示す。以下の手続きにおいて、Step1 はエージェントの初期化のために一度だけ実行され、各エージェントは Step2 ~ Step6 を繰り返すことで問題の最適化を行う。

[Step1. 抗原の認識] 問題の定式化（都市数，都市

配置), およびセールスマンの定義(セールスマン数, MHC)を行う. また, 初期セールスマン数や都市の MHC 情報はランダムに初期値を決定する. MHC とは各セールスマンの ID であり, 各都市がその都市を巡回するセールスマン ID を情報として有する. MHC は, 他のセールスマンを認識し, 分割・統合する際に参照するために使用される.

セールスマンの巡回経路はパス表現(巡回する都市の番号をシーケンスに並べた一次元配列)でコード化し, 初期巡回経路は重複都市, 未訪問都市が存在しないようにランダムに生成される.

[Step2. 目的関数計算] 各セールスマンの巡回経路の評価値として巡回経路長を計算する.

$$Cost(S_i) = \sum distance(tour_{S_i}) \quad (1)$$

- S_i : セールスマン i .
- $tour_{S_i}$: セールスマン i の巡回経路.

[Step3. 分割処理] 各セールスマンは, 現在の自らの順路のコストを下げるためにコストの少ない2つのサブツアー(順路)へと分割処理を行う(図8-(A)).

1. セールスマン S_i は現在の巡回経路から任意の二点間により決定されるサブツアー $subtour_i$ を生成する.
2. セールスマン i から $subtour_i$ を除いた順路 $subtour_j$ を, まだ一つの都市も訪問していない新たに生成したエージェントの順路として設定する.
3. 分割により生じた二つの順路 $subtour_i$, $subtour_j$ のコストを計算する. もし, 分割後の二順路のコスト総和が分割前よりも減少しているならば, その分割処理を実行する. 逆にコストが増加しているならば元の順路へと戻す.

従って, 分割処理が実行されるならば, 効率の良い分業解を生成するために新たなセールスマンを生成することになる.

[Step4. 統合処理] 任意の2セールスマンは, 各々の順路を統合することにより総和コストの減少を図る(図8-(B)).

1. 二つの順路 $tour_i, tour_j$ の結合ポイントを任意に決定する.




図 8: 分割・統合処理の例

2. 決定した結合ポイントに, 一方の巡回経路を結合し, 新たな順路 $new\ tour_i$ を作成.
3. 新たに生成された順路のコストを計算する. もし, 結合後のコストが減少しているならばその結合処理を実行する. 逆に, コストが増加しているならば元の順路へと戻す.

従って, 結合処理が実行されるならば, 分割処理とは逆に, 効率の良い分業解を生成するために既存のセールスマンを削除することになる.

[Step5. 突然変異] 各セールスマンは, 任意の二都市の巡回順序を入れ換える突然変異操作を実行し, 新たな順路を生成する. 突然変異後の順路が元のコストよりも減少するならばその順路を次ステップにおける巡回経路として設定する.

[Step6. 目的関数計算] 抗原エージェントである都市の進化に必要となる目的関数を計算する. ここでは, その都市を訪問しているセールスマンのコストをそのまま採用する.

[Step7. 逃避処理] 各都市が近傍都市を訪問するセールスマンのコストを比較し, コストの低いセールスマンの ID へ変更する.

1. 予め設定された近傍都市数によって規定される近傍都市群に対し, それらの都市を訪問しているセールスマンのコストを確認する.
2. 自都市のセールスマン S_i のコストを下回るセールスマン S_j が存在するならば, 自都市の ID を S_j へと変更する.

図9の例では, 対象都市の ID を S_2 へと変更することで順路を修正した様子を示している.

以下, 終了条件(処理ステップ数)に達するまで Step2~7 を繰り返す.

このような手順に基づき, セールスマンエージェントは突然変異処理による作業領域における経路探索と,



図 9: 逃避処理

分割・統合処理によるエージェント間での作業領域の探索を行い、都市エージェントは分業の平等化を実行している。なお、本節で行った計算機実験においては、分割処理において実際に分割を実行する回数が非常に低いため、初期ステップではアニーリング法を導入することで実行回数の調整を行った。アニーリング法における温度パラメータ T を分割処理において二順路のコスト総和が増加している場合にも実行させる確率（単位は%）、温度調整パラメータを α としたとき、本実験では式 2 に基づき実行確率を変移させた。なお、同式における n はステップ数であり、初期値 T_0 および α は問題毎に試行錯誤的に調整している。

$$T_n = \alpha \times T_{n-1} \quad (2)$$

4 計算機実験

計算機実験では、二重円環型 n -TSP および応用例題として TSPLIB で提供されるテストベッド問題へ適用し、本手法の有効性を検証する。

4.1 実験 1: 基本性能確認

4.1.1 実験設計

実験 1 では、表 2 で定義される二重円環型 n -TSP へ本手法を適用し、基本性能を確認するとともに、その探索動作を検証する。なお、本手法で用いたパラメータは表 3 のように設定した。表 2 における最小セールスマン数とは、何人のセールスマンによる分業解を求めたいのかを指定するパラメータであり、システム利用者の欲するエージェント数での分業解を求めることが可能である（探索中、現在の分業解が最小エージェント数で構成されているならば分割処理は実行されない）。

表 2: 問題設定

都市数	25
最小セールスマン数	3
都市配置	二重円
出発都市	円の中心
半径	out=0.5, in=0.384
終了ステップ数	1000

表 3: パラメータ

近傍都市数	4
初期エージェント数	under 24
終了ステップ数	2000
初期温度 T_0	50
温度調整パラメータ α	0.99

4.1.2 結果

図 10-(A) は獲得した解を示しており、作業配分の平等化および各エージェントの作業コスト最適化が実現している。表 4 は、本手法における各処理の試行回数および実行回数を例示している。括弧内の回数は焼きなまし法を導入する前の実行回数である。分業処理の実行回数の増加に比例して統合処理回数も増えており、それらの処理が十分に機能するだけの回数が実行されていることが分かる。図 10-(B) はステップ毎のコスト推移を示しており、コストの増減を繰り返しながらステップ 400 過ぎには収束している。




図 10: 分業結果と作業コスト推移

次に、本手法の探索動作を検証するため、各エージェントの巡回都市数の推移を図 11, 12 に図示した。同図より、初期ステップでは小数の都市を多くのエージェントにより訪問する解（図 11）で構成されているが、50 ステップ目以降の解は約 8 都市を 3 人のエージェントで全都市の訪問を行う解（図 12）へと変更されており、またその変更にともない 50 ステップまでにおけるコストの大幅な減少が実現している。この平等な分業

表 4: 各処理の試行回数と実行回数の内訳例 (括弧内の数値はアニーリング法未導入時の例)

	試行回数	実行回数
分割処理	6,242	221 (6)
統合処理	546	225 (16)
突然変異	6,037	50
逃避処理	47,876	47,876
総計	60,701	48,372




図 11: 各エージェントの巡回都市数の推移 (ステップ 1~10)

は、提案手法における逃避処理により実現されている。その後のステップにおいては、ほぼ平等な分業を保持したまま、各作業領域における解の最適化が行われており、500 ステップ目以降はコストと巡回都市数が収束した。最終的に獲得した解は、図 10 に示したように、8 都市を 3 エージェントで訪問する解である。




図 12: 各エージェントの巡回都市数の推移 (ステップ 396~405)

4.2 実験 2: テストベッド問題による検証

応用例題として TSPLIB² で提供されるテストベッド問題 (*eil51.tsp*, *gr202.tsp*) に適用する。実験 1 で適用した二重円環型 n -TSP は、内外円の半径比を調整することで二種類の特徴的な最適解と局所解が入れ替わるだまし問題であり、非常に規則性の高い特殊な問題と言える。実験 2 では、TSPLIB で提供されるテストベッド問題へ適用することで、より具体的な事例においても本手法が有効に機能することを示す。

4.2.1 例題 1: *eil51.tsp*

実験 2 では、TSPLIB で提供される *eil51.tsp* へ適用する。*eil51.tsp* は 51 都市 TSP であり、その最適解は図 13 に示す通りである。




図 13: *eil51.tsp* の最適解

eil51.tsp に適用するに当たり、中心座標に近い都市を出発都市として設定し、最小セールスマン数を 3~5 人と三通りの設定で適用した。その結果を図 14 に、また各々の巡回に要するコストを表 5 に示す。セールスマン数の増加に伴いコストが上昇するのは最低限出発都市に戻る分の巡回コストを要するためである。セールスマン数が 4~5 人の場合には若干巡回経路に重なっている箇所が見られるものの (1) 図 13 に示した最適解と類似した部分解が見られ、また (2) 1 セールスマン当たりのコスト増加分は約 0.3 であり、片道 0.15 程度の出発都市への往復分程度の増加でしかないことから質の優れた準最適解であると考えられる。

図 15 は、最小セールスマン数 5 における、各セールスマンのステップ毎のコスト推移を示している。約 600 ステップ目までに縦線が頻りに描かれているが、これは分割・統合処理によりセールスマンが生成・削除されていることを意味する。また、縦線の無い、他のステップにおけるコストの増減は突然変異・逃避処理

² <http://www.iwr.uni-heidelberg.de/groups/comopt/software/TSPLIB95/>

により行われている．この結果，次第に各セールスマンのコストがほぼ均一となるように解が改善されており，2.1節で述べた (a) (b) を満足するように全作業コストの最適化が図られていることが確認できる．




図 14: *eil51.tsp* の最適解

表 5: コスト比較

	セールスマン数			
	1人	3人	4人	5人
コスト	6.1471	6.7937	7.2458	7.8205
増加率	100%	約 111%	約 118%	約 127%
1人当たりの増分コスト		0.215	0.274	0.334




図 15: *eil51.tsp* (最小セールスマン数 5) における各セールスマンのコスト推移

4.2.2 例題 2: *gr202.tsp*

テストベッド問題として都市配置に偏りのある問題 *gr202.tsp* を対象とし，本手法の有効性を検証する．*gr202.tsp* は 202 都市 TSP であり，1 セールスマンによる最適解は図 16-(A) に示す通りである．

gr202.tsp に最小セールスマン数 3，近傍都市数 10，終了ステップ数 2000 として適用した結果を図 16-(B) に示す．コストは 1 セールスマンと比較して約 7% 増加している程度であり，先程の *eil51.tsp* よりも増加コストが少ない．また，各セールスマンの平均コストは

1.597939，各エージェントの平均コストからの絶対誤差総和は 0.008215 であり，コスト誤差が総コストの 2% も無いことから獲得した解は良質な分業解であると考えられる．




図 16: *gr202.tsp* へ適用した結果

4.3 実験 3: GA との性能比較

実験 3 では，実験 1 で扱った問題 (表 2) を計算対象とし，遺伝的アルゴリズム (Genetic Algorithm: GA) との比較により，本手法の有効性を確認する．

4.3.1 GA の設計

使用した GA は，都市番号をそのまま遺伝型として用いるパス表現によるコーディングを行った．なお，コーディングにおいては，図 17-(A) および (B) に示す通り，出発都市の都市番号を各セールスマンの作業領域を切り分けるためのセパレータとして利用している．また，交叉オペレータとして，山村らによって提案されたサブツアー交換交叉 [13] を実装している．サブツアー交換交叉では，任意の二点間で決定されるサブツアーに含まれる都市集合が同一であるときのみ交叉により入れ換えるため，形質を保存した解を生成し，かつ，実行不能解を生成しないという特徴を持つ．

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 18 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。

また、適応度関数は式3として設定しており、平等な分業を獲得するために *Penalty* を設けた。

表 6: GA のパラメータ

集団数	100
交叉確率	1.0
突然変異確率	0.01
終了世代数	5000

$$fitness_i = 1 / (Cost + Penalty) \quad (3)$$

- *Cost*: 巡回経路長。
- *Penalty*: 平均コストと各エージェントのコストとの差分。




図 17: コーディング例




図 18: サブツアー交換交叉の例

4.3.2 比較結果

提案手法と GA について、シード値を変えた 20 試行を行った。その結果を表 7 に示す。表は (1) 最適解を獲得した回数 (2) 20 試行における最小・平均・最大コスト (3) 最適解を獲得するまでに探索した解の個数 (探索点数) (4) 実行時間、を示している。なお、(3) における比較対象となる探索点数は、解を更新した回数を意味しており、各々下記の方法で算出した。

表 7: 20 試行におけるシミュレーション結果

		GA	提案手法
最適解獲得回数		3	15
コスト	最小 (best)	5.845231	5.845231
	平均	6.403267	5.858212
	最大 (worst)	6.949701	5.897158
探索した解の数	最小 (best)	74,100	1,616
	平均	167,100	8,488
	最大 (worst)	227,100	16,580
実行時間		50sec	10sec

- 提案手法：分割・統合・突然変異・逃避の各オペレータを実行した回数の総和 (表 4 における「実行回数」の総計と同意)。
- GA：集団数 × 最適解を獲得した世代数。

同表より、実行時間を含めた全ての項目において提案手法が優れた結果を示している。特に、GA と比較して非常に短時間で優れた解を探索しており、本手法が分業問題最適化に有効に機能することが分かった。また、探索に要した解の個数においても GA と比較してオーダーが一桁少ないことから、適切な探索空間の絞り込が間接的に実現していると思われる。結論として、本手法は、局所的相互作用のみにより分業問題を最適化する能力を有することから、MAS における最適化システムとして有効に機能する能力を有すると考えられる。

4.4 実験 4：性能比較実験 2

実験 4 では、配送経路問題に対する古典的な近似解法であるセービング法および、セービング法により獲得した解を GA における初期の実行可能解として用いる Saving-GA[14] との性能比較を行う。

4.4.1 セービング法

出発都市から都市 $i (i = 1, 2, \dots, n)$ へ a_i の量の荷物を積載容量 b のエージェントを用いて配送するものと想定した際のアルゴリズムを以下に示す。

1. 初期配送経路の設定

初期の配送経路は、1 都市のみを配送する経路を設定。

2. セーピング値の計算

任意の2経路を統合した際のセーピング値(統合による節約できる距離)を下記の式で算出する.

$$s_{i,j} = d_{i,0} + d_{0,j} - d_{i,j} \quad (4)$$

なお, $d_{i,j}$ は, 都市 i, j 間の距離とする.

3. 統合を行う経路対の選択

最もセーピング値の高い組合せを求め, 結合対象とする.

4. 集積所 i, j それぞれを含む経路の統合

3. にて選択した2経路を結合し, 3. に戻る. ただし, 結合する際, 選択した組合せのセーピング値が負である場合, または結合により積載容量 b を越える場合には処理を終了する.

なお, 計算機実験においては $a_i = 1$, $b = (\text{都市数} / \text{セールスマン数})$ と設定した.

4.4.2 Saving-GA

Saving-GA は, セーピング法の解を GA における初期の実行可能解として用い, 巡回路の改善を行う方法である. [14] の横山らの手法においては更に SA (アニーリング法) による解の改善を導入しているが, 著者らが論文中に指摘している通り SA の実行には「計算時間が多大」にかかっているため, SA を省いた Saving-GA を比較対象とした. なお, 初期集団は, セーピング法により求めた解 A そのものを1個体含め, 解 A を突然変異処理により変移させた個体を集団数の半分個体生成し, 残りをランダムに作成した個体により初期集団を生成することで作成した.

4.4.3 問題設計

各手法を内外円の半径比が異なる二つの49都市二重円環型 n -TSP (表8)へ適用し, 探索性能を比較した. 二重円環型 n -TSP は, 半径比を調節することで二種類の特徴的な最適解・局所解が入れ替わるだまし問題であり, 同表において, Case1 は O 型(二つの円を交互に巡回する解)が最適解, Case2 は C 型(一方の円を巡回し終えた後にもう一方の円を巡回する解)が最適解となる.

4.4.4 実験結果

(1) サブツアー交換交叉を採用した GA (集団数400, 終了世代数10000, その他は表6と同一), (2)

表 8: 問題設定

都市数	49
セールスマン数	3
都市配置	二重円
出発都市	円の中心
半径	Case1(out=0.5, in=0.384) Case2(out=0.5, in=0.386)

セーピング法単体 (3) Saving-GA (集団数100, 終了世代数5000, その他は表6と同一) (4) 提案手法(近傍都市数4, 初期エージェント数200, 終了ステップ数1000), 各々を表8に適用し, 得られた解, 解獲得に要した実時間, 分業度合(平均コストからの絶対誤差総和(式5))を図19に示す.

$$sum\ error = \sum_i^N |\overline{cost} - x_i| \quad (5)$$

$$\overline{cost} = (\sum_i^N x_i) / N \quad (6)$$

サブツアー交換交叉 GA およびセーピング法単体では, 最適解より5~10%程度コストが劣化した解しか得られず, 分業問題最適化の第三項目である全作業コストの最適化の面でやや満足の行かない結果となった. また, 分業度合に関しては各セールスマンのコストに20%以上の差異が見られており, 分業問題最適化の第一項目である作業配分平等化の観点からは不十分である. 一方, セーピング法においては極めて短時間で良質な解を求めることが可能であるが, 二重円環型 n -TSP のようなだまし問題においては図19に見られるように, 問題が異なっているにも関わらず一方の特徴的な解しか獲得できない場合がある. そのため, セーピング法で獲得した解を初期集団に含めた Saving-GA においては, Case2 においては最適解に類似した近似解を獲得できているが, Case1 ではその局所解から脱出できずにいる. 分業度合についても各セールスマン間のコストの差異が大きい.

これらの手法に対し, 提案手法ではセーピング法単体よりも実行時間は要するものの, GA や Saving-GA と比較して極めて短時間で優良解を獲得可能であり, さらに獲得した解はコストも低く, 分業度合も1%程度の誤差であることから分業問題最適化のための手法として有効に機能するものと考えられる.

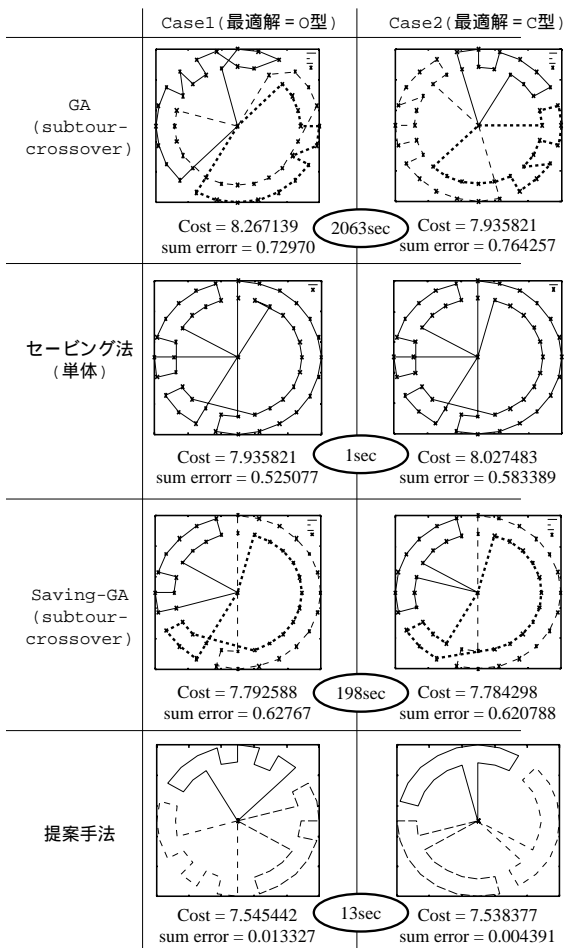


図 19: 三手法により獲得した分業解とコスト比較

4.5 総論

提案手法の Step3 の分割処理では、新たな作業エージェントを追加投入し、作業領域 WD のサブ領域を割り当てることで全体の作業コスト最適化を図っている。しかしながら、一般に計算資源である作業エージェントを追加することは作業エージェントの運用自体に要するコスト（主として金銭的な費用）の増加を招くため、実世界において得られた分業解を実行するには作業エージェント費用と作業時間コストとのトレードオフを考慮する必要がある。本論文においては最小作業エージェント数を固定としているが、そのような作業エージェント費用を考慮した目的関数を設計することでトレードオフを考慮した最適な分業解を獲得するように拡張することが可能である。

解探索の観点からは、分割処理におけるエージェント数の増加に伴う探索空間の複雑化もマイナスの要因となり得るだろう。 n -TSP へと適用した計算機実験では、作業エージェントは出発都市へと戻る必要があるためその往復分のコスト増加が作業エージェント費用

とみなせる。アニーリング法を導入することで分割処理実行回数を意図的に増加、すなわち作業エージェントを探索中に追加させた実験 1~3 では、探索空間の複雑化に反比例して低コストとなる優れた分業解を獲得しやすくなる傾向が見られており、初期作業エージェント数が多い場合にも同様であった。

反対に、アニーリング法を導入しなかった場合は、平等な分業解は獲得できるものの全作業エージェントの総コストは最適にはならなかった。図 20 は未導入時に獲得した分業解、図 21 は各エージェントのコスト推移を示しており、徐々にコストの平等化が図られているが、明らかに最適な分業解ではない。アニーリング法を導入しない場合、分割処理実行回数は表 4 に示したように 1000 ステップ中 6 回実行と殆ど実行されていない。さらに、最小作業エージェント数を問題設定として規定しているため、分割処理の実行回数減少に伴い Step4 の統合処理自体の実行回数も比例して減少する。結果として、逃避処理による平等な作業配分がメインオペレータとして機能するため、最適な分業解を獲得できていない。




図 20: 分業結果（アニーリング法未導入時）

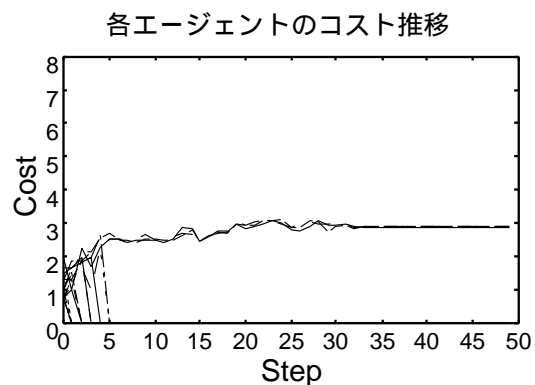


図 21: 作業コスト推移（アニーリング法未導入時）

探索中に作業エージェントを追加した方が良い結果を得ている理由として、セールスマン数と都市数との相関により探索空間サイズが大きく変化するためと考えられる。極端な例として、セールスマン数が都市数

と等しい状況においては、各セールスマンが1都市ずつ巡回する解のみが候補解であり、そのまま最適解となる。このことから、本手法は候補解数の少ない状況においてまず優位解を獲得し、獲得した候補解を組み合わせつつ修正することでセールスマン数の減った探索空間における優位解を生成しているものと考えられる。初期作業エージェント数が多く、作業エージェントを増加させた際の探索結果が良好であることから、最初から候補回数が多い探索空間を解くのではなく、一旦候補解の少ない問題を解いた上でそこで獲得した候補解を有効利用する解法が適しているといえる。

一方、このような一種の山登り法的なアプローチは局所解に陥りやすいように思われるが、実際のところ二種類の特徴的な最適解・局所解を有する騙し問題である二重円環型 n -TSP においても局所解に陥ること無く最適解または近似解を獲得している(図19)。この理由としては、エージェント数の増減に伴う探索空間サイズの変化が適応度地形そのものの変化として現れるため、結果として単一の問題空間のみに囚われない適応性の高い解法になっているものと考えられる。

5 おわりに

本論文では、MAS における分業問題最適化を目的とした免疫系と抗原間に見られる共進化現象をモデルとした免疫的分業最適化アルゴリズムを提案した。同アルゴリズムは、免疫エージェント間の局所的な相互作用により作業領域における解の最適化を行う分割・統合処理と、抗原エージェントの作業領域分担の平等化を行う逃避処理に基づいて探索を行う。計算機実験では、訪問都市の分配最適化と巡回経路最適化という二つの最適化を含む n -TSP を評価問題とした GA との比較実験により、シード値による探索能力への影響が低く、平均的に優れた解を極めて短時間で獲得可能であることを示した。また、具体的な事例を対象とした実験を通すことで、作為的に作成された二重円環型 n -TSP のような特殊な問題だけでなく、一般的な問題においても適切に分割できることを検証した。MAS においては、全てのエージェントや環境を構成する他の要素を考慮した目的関数を設計することは非常に困難であることから、局所的な相互作用により全体の最適化を図ることが望ましい。本手法は、局所的相互作用のみにより分業問題を最適化する能力を有する。すなわち、先行研究である免疫的分散競合型アルゴリズムの問題点(個エージェントとエージェント全体における最適性のミスマッチ)を解消していることから、MAS

における最適化システムとして有効に機能する能力を有すると期待できる。

本研究は、平成13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。

参考文献

- [1] E. G. Coffman : “Computer and Job-shop Scheduling Theory”, John Wiley & Sons (1976).
- [2] D.Dasgupta (editor) : “Artificial Immune Systems and Their Applications”, Springer (1999).
- [3] S. Forrest, A.A. Perelson : “Genetic algorithm and the Immune system”, Proc. of 1st Workshop on Parallel Problem Solving from Nature, Dortmund, Federal Republic of Germany, 1-3, October, 1990.
- [4] Y.Ishida : “Fully Distributed Diagnosis by PDP Learning Algorithm : Towards Immune Network PDP Model”, Proc. of IJCNN 90, pp.777-782 (1990).
- [5] Charles A. Janeway, Jr., Paul Travers ; with assistance of Simon Hunt, Mark Walport : “Immunobiology : The Immune System in Health And Disease”, Garland Pub (1997).
- [6] S.Russell and P.Norvig : “Artificial Intelligence: A Modern Approach”, Prentice-Hall (1995).
- [7] Naruaki Toma, Satoshi Endo, Koji Yamada, Hayao Miyagi : “The Immune Distributed Competitive Problem Solver with MHC and Immune Network”, Intelligent Engineering Systems through Artificial Neural Networks, vol.10 (editor C.H. Dagli et al.), ASME PRESS SERIES (ISBN 0-7918-0161-6), pp.317-322 (2000).
- [8] 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).
- [9] 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).
- [10] 當間 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, Vol.15, No.6, 2000. pp.1097-1106 (2000).

- [11] 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).
- [12] 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).
- [13] 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).
- [14] 横山 裕之, 白井 裕, 松本 直文, 川中子 敬至: “配送・集荷経路問題に対するセービング法 / GA / SA の組合せ解法”, 第 11 回インテリジェントシステムシンポジウム予稿集, pp55-60 (2001).
- [15] 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).

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．

問い合わせ先

氏名: 當間愛晃

住所: 〒 903-0213 沖縄県中城郡西原町字 1 番地 琉球大学 工学部 1 号館 601 号室

TEL : 098-895-8714

FAX : 098-895-8727

e-mail : tnal@eva.ie.u-ryukyu.ac.jp

著者略歴

- 當間 愛晃

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．また，PC クラスタ技術の修得のため米国立フェルミ研究所にて研修中．情報処理学会，人工知能学会各学生会員．

- 遠藤 聡志

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

1995 年 3 月，北海道大学大学院工学研究科博士後