

## 局所的培養型マスタースレーブモデルの多目的最適化への応用

渡邊 真也<sup>†</sup>, 廣安 知之<sup>††</sup>, 三木 光範<sup>††</sup>,

<sup>†</sup> 同志社大学大学院    <sup>††</sup> 同志社大学工学部

本論文では、遺伝的アルゴリズム (Genetic Algorithms :GA) を用いた多目的最適化における新たな並列モデルとして局所的培養型マスタースレーブモデル (Master-Slave model with Local Cultivation model :MSLC) の提案を行う。本モデルは、マスタースレーブモデルの一種であり、多様性の保持、ロードバランスに優れるという特徴を持っている。また、提案するこれらのモデルの有効性を検証するために、携帯電話のアンテナ配置問題への適用を試みた。この問題への適用結果より、従来の並列モデルに対する提案手法の優位性、特徴について考察を行った。

## The New Model of Parallel Genetic Algorithm in Multi-Objective Optimization Problems -Master Slave model with Local Cultivation model-

Shinya Watanabe<sup>†</sup>, Tomoyuki HIROYASU<sup>††</sup>, and Mitsunori MIKI<sup>††</sup>

<sup>†</sup> Graduate School of Engineering, Doshisha University

<sup>††</sup> Knowledge Engineering Dept., Doshisha University

In this paper, we propose a new parallel genetic algorithm model for multi objective optimization problems. That is "Master-Slave model with Local Cultivation model (MSLC)". The proposed model is one of a master slave model, and has some characters for multi objective optimization. To clarify the characters and effectiveness of this model, the proposed model are applied to antenna arrangement problem of mobile telecommunication. Thorough this problem, advantages and disadvantages of this model is made clarified.

### 1 はじめに

近年、GA の持つ「集団による探索 (多点探索)」という特徴に注目し、GA を多目的最適化問題へ適用する試みが行われその有効性が検証されている<sup>1, 2, 3)</sup>。これらの研究は一般に多目的 GA と呼ばれ、Schaffer らの VEGA<sup>3)</sup> に始まり、パレート最適解集合のフロンティアを陽に取り扱う Goldberg のランキング法<sup>2)</sup> や Fonseca らの MOGA<sup>1)</sup> などが代表的な研究としてあげられる。

このように、GA の多目的最適化問題に対する有効性が検証される一方で、複数の目的関数および制約条件の値を繰り返し評価する必要があり、膨大な計算時間が必要となるという問題点も指摘されている。このため、並列処理により計算時間を短縮することは重要な課題となる。

単一目的における GA の並列化に関する研究は近年活発に行われている<sup>4, 5)</sup>。その中でも、適合度関数の値を求める部分の並列化を行うモデルであるマスタースレーブ型モデルや母集団を幾つかのサブ母集団に分割し、それぞれのサブ母集団内

で GA を行い、数世代に 1 度の割合で解交換を行う分割母集団モデル (Distributed GA:DGA) が代表的である。

対して、多目的 GA の並列化に関する研究は幾つか行われているがその数は多くない<sup>6, 7, 8)</sup>。また、そこで使用されている計算モデルは GA の並列化手法として最も一般的な島モデル並列 GA を基にしているものがほとんどである。

その点に関して、我々は多目的 GA の特徴を活かした分割母集団モデルの一種である領域分割型多目的遺伝的アルゴリズム (Divided Range Multi-Objective Genetic Algorithm: DRMOGA) を提案し、幾つかのテスト関数を通じて従来の島モデル並列 GA に対する優位性を証明した<sup>9)</sup>。

しかし、個体数および探索世代数が限定される評価計算負荷の高い問題に対して、探索母集団をサブ母集団に分割して並列処理を行うという分割母集団モデル (島モデル) では必ずしも良好な解を得ることはできない。また、分割母集団モデルでは基本的に全ての個体を各サブ母集団で等分に分割し探索を行うため、分割するサブ母集団の数に

よって解が大きく影響を受けるという問題点も存在する。

そこで、本研究では用いるプロセス数による影響のないマスタースレーブモデルに基づく新たな並列モデルの提案を行い、その有効性の検証を試みる。新たに提案するモデルは、マスタースレーブモデルの一種である、局所的培養型マスタースレーブ型モデル (Master-Slave model with Local Cultivation: MSLC) である。提案手法は、従来のマスタースレーブモデルの問題点であったマスターノードに対する負荷集中の問題点を緩和する仕組みになっているだけでなく、多目的最適化の持つ特性にも配慮したものとなっている。

一方、近年の爆発的な普及に伴い携帯電話におけるアンテナ配置はますますその必要性が増加している。アンテナ配置は、アンテナを設置するための候補サイト群より実際に設置するサイト群を決定することにより行われる。その際、考慮すべき目的は電波の届くエリアの最大化、アンテナ設置に伴うコストの最小化、通話の断絶を最小化するため各アンテナの提供するエリア間の重なり最大化など多岐にわたる。また、この問題は離散的であり、かつ候補サイトおよび考慮すべき範囲がある一定以上となると問題が非常に複雑になる上、計算負荷が膨大になることが知られている。

近年、この分野の問題に対して多目的進化的計算を適用する研究が行われ、その成果が報告されている<sup>10)</sup>。

そこで、本研究では提案手法である MSLC とともに幾つかの分割母集団モデルをアンテナ配置問題に適用した。数値実験を通して、提案手法の有効性を検証するとともに分割母集団モデルにおけるサブ母集団の数による解への影響について検討を行った。

## 2 GA による多目的最適化への応用

### 2.1 多目的最適化問題

多目的最適化問題は、複数個の目的関数を同時に最適化する問題のことであり、一般に次のように定義される<sup>6, 11)</sup>。

$$\min_x \{f_1(x), \dots, f_p(x)\} (x \in R^n) \quad (1)$$

$$\text{subject to } x \in F \equiv \{x | g_i(x) \leq 0, \forall i, \dots, m\} \quad (2)$$

$x$  は  $n$  次元のベクトルで、各要素は問題の決定変数である。 $g_i(x)$  は制約条件を与えるための関数、そして  $F$  は制約条件を満たす  $x$  の集合で「可能領域」と呼ばれる。

目的関数が互いに競合し合っているため、与えられた複数の目的関数に対して完全最適化を求めることはできない。そのため、多目的最適化では「ある目的関数の値を改善するためには、少なくとも他の 1 つ目的関数の値を改悪せざるを得ないような解」を求めていく。多目的最適化では、このような解集合をパレート最適解 (Pareto optimal solution) と呼んでいる。ゆえに、多目的最適化の 1 つの目標は、このパレート最適解 (集合) を導出することである。

### 2.2 多目的遺伝的アルゴリズム

GA は自然界における生物の遺伝と進化をモデル化した最適化手法である<sup>1, 2)</sup>。従来までの一点探索による手法と異なり、GA は多点探索であるため多峰性のある問題においても最適解を探索でき、かつ離散的な問題にも対応できる非常に強力な最適化ツールの 1 つである。

このように、GA では個体群を用いて探索が進められるので、一度の探索において図 ?? に示されるような複数存在するのパレート解集合を探索することができる。

### 2.3 得られた解候補の評価方法

得られたパレート解に対する評価方法は、適用したモデルの定量的な評価を行う上で必要不可欠である。これまでに、進化的多目的最適化の分野においても幾つかの手法が提案されている<sup>6, 12)</sup>。

本研究では、優越個体割合と、被覆率の 2 つの評価方法を用いた。

#### 2.3.1 優越個体割合

優越個体割合 (The Ratio of Non-dominated Individuals:  $RNI$ ) この手法は、2 つの比較手法により得られた解を以下の手順に従い、その優越度合いの比較を行い、2 つの手法の優越を決定する方法である。

まず、比較対照とする 2 つの手法で得られたパレート解 ( $X'$ ,  $X''$ ) を足し合わせ、その中よりパレート解を選び出す。その上で、選び出されたパレート解の各手法の割合を  $RNI(X', X'')$  として導き出しというものである。

そのため、この割合は最大値の 100 % に近ければ近いほど、もう一方の手法を優越している、すなわちより真の解に近い解が得られているものと判断することができる。

#### 2.3.2 被覆率

パレート解を探索する場合、解個体群が 1 点に集中しては良い解集合とは言えない。そのため、何らかの解の幅広さに関する指標が必要となる。その指標が被覆率 (Cover Rate) である。

まず、各目的関数の最大値および最小値を検索し、その間をあらかじめ決めておいた分割数で分割する。それぞれの分割された領域の中に解が存在する場合は1、存在しない場合には0とする。これらの数値を合計し、領域の数で除したものを被覆率とする。よってこの被覆率が1に近い方がすべての領域に解が存在していることになり、解が集中することなく全体に行きわたっていることがわかる。本研究の数値計算例では分割された領域の数を50としている。

### 3 局所的培養型マスタースレーブモデル

多目的最適化 GA の並列化に関する研究は単一目的に比べその数は多くない。また、そこで使用されている計算モデルの多くは単一目的における GA の並列化と大差はなく、例としてマスタースレーブ型モデルや<sup>7)</sup>、分割母集団モデル<sup>8)</sup>などが挙げられる。

しかし、単一目的の場合における探索と多目的における探索では GA の探索方法において幾つか異なる。これは、求める解候補が一点でなく複数であることに起因している。

そこで、我々は多目的 GA の特徴を活かした分割母集団モデルの一種である領域分割型多目的遺伝的アルゴリズム (Divided Range Multi-Objective Genetic Algorithm: DRMOGA) を提案した<sup>9)</sup>。このモデルは、得られているパレート最適個体群を目的関数に沿って領域で分割し、その領域ごとに多目的最適化 GA を行うという分割母集団モデルの一種である。このように各個体の分割を個体の持つ目的関数値を基準に行うことにより、各分割島ごとの探索の重複を防ぐとともに近傍交叉を実現することができる。

しかし、分割母集団モデルでは用いる島数(サブ母集団の数)によって島内における個体数が変化するため、島数によって解が大きく影響を受けてしまうという欠点がある。その点に関して、マスタースレーブモデルでは基本的に何プロセス用いても総仕事量およびその内容に変化は無い。

そこで、本研究では一般的なマスタースレーブモデルにおける欠点を取り除き、より多目的の特性を取り入れた新たなモデル、局所的培養型マスタースレーブモデル (Master-Slave model with Local Cultivation model: MSLC) を提案する。

#### 3.1 局所的培養型マスタースレーブモデルの概要

DRMOGA は分割母集団モデルの多目的に特化したモデルであるのに対して、MSLC は大域的並列モデルを多目的に特化させたモデルであるといえる。

MSLC では、2 個体のペア個体をサブ母集団として扱い、マスターノードとスレーブノード間において 2 個体のサブ母集団を受け渡すことによって探索を進めるという仕組みを用いている。マスターノードでは、個体の管理のみを行い各種 GA オペレータを行わない。この点が従来のマスタースレーブモデルとの大きな違いである。一方、スレーブノードではマスターノードから受け取った 2 個体を元に各種 GA 操作を行い、次世代個体として選択された 2 個体をマスターに送るという操作を行う。

具体的なアルゴリズムをマスターノードとスレーブノードの場合に分けて以下に示す。

#### • マスターノード

##### – ステップ 1

$N$  個の個体をランダムに生成する。

##### – ステップ 2

生成した個体を全て評価した上で、各スレーブごとに生成、評価した染色体を全スレーブノードから受信して集める。そして、全個体よりランク 1 の個体を抜き出しランク 1 個体群を作成する。

##### – ステップ 3

ランク 1 個体群の目的関数値の情報を各ノードに分配する。

##### – ステップ 4

個体を 2 個体ずつペアで、非復元抽出し各ノードに配る。

##### – ステップ 5

各ノードから 2 個体のペアを受け取り、ステップ 4 で選んだ 2 個体のペアと入れ替える。全ての個体が配り終えるまでステップ 4、ステップ 5 を繰り返す。

##### – ステップ 6

終了条件を満たすかどうか判定を行う。終了条件を満たせば終了。満たさない場合には、ステップ 7 へ進む。

##### – ステップ 7

前世代までに得られたランク 1 個体群と新規個体群の比較を行い、両個体群から新たなランク 1 の個体群を作成、新規個体群の一部にその個体群を反映する。ステップ 3 へ戻る。

#### • スレーブノード

- ステップ 1  
N 個の個体をランダムに生成する .
- ステップ 2  
生成した個体を全て評価した上で全ての染色体をマスターノードへ送る .
- ステップ 3  
全個体の内, ランク 1 個体群の目的関数値の情報をマスターより受け取る .
- ステップ 4  
2 個体の個体ペアを受け取る .
- ステップ 5  
受け取った 2 個体を用いて交叉, 突然変異, 選択などの各種 GA 操作を行う .
- ステップ 6  
選択によって選ばれた 2 個体のペアをマスターへ送り返す . マスターから送信終了のメッセージが届くまでステップ 4, ステップ 5 を繰り返す .
- ステップ 7  
終了条件を満たすかどうか判定を行う . 終了条件を満たさなければステップ 3 へ戻る .

このように提案する MSLC は, 従来のマスタースレーブ型とその仕組みが大きく異なっている . MSLC の特徴を以下に示す .

- 全ての GA 操作は, スレーブノードが行うため, マスターノードの負荷が軽い .
- 探索個体群とは別の優良解を保存するパレート保存個体群を備えている . そのため, 探索途中で得られた優良解の損失が無い .
- GA 操作の一部に佐藤ら<sup>13)</sup>により提案された MGG モデル (Minimal Generation Gap model) の考えを取り入れ個体集団の多様性を保持している .

MSLC は, 基本的にマスタースレーブモデルに基づいているため, DGA や DRMOGA と違い, プロセス数による解への影響がない . 本モデルの概念図を図 1 に示す .

#### 4 アンテナ配置問題

本研究では, 対象問題として携帯電話用サイトにおけるアンテナの配置問題を用いた . アンテナの位置決定のためには, 決められたアンテナの数やアンテナの持つパラメータなども決定する必要がある . また, 求められる目的も, 電波の分布領域の広域化だけでなく, 設計コストの最小化, 電




図 1: Master-Slave model with Local Cultivation model

波が途切れないための電波ごとの十分な重なり具合など複数に及ぶため多目的最適化問題として定式化することができる .

本章では, ネットワーク設計問題の扱う設計空間, および問題の目的と制約について説明する .

#### 4.1 設計空間

ネットワーク設計問題は, 与えられた領域内における候補サイトの中から, 実際にアンテナを設置するサイトの決定とアンテナの構成を決定する . 本来, サイトに設置するアンテナは, 無指向性, 有指向性の 2 種類存在するが, 本研究では単純化のため無指向性アンテナのみを対象として扱った . 無指向性アンテナに付随するパラメータを以下に示す .

- 2 次元の位置座標  $(x, y)$
- 電波の強さ  $r$

上記の内, 電波の強さ  $r$  は, アンテナが最低限の電波の質的しきい値を保ったまま, どの程度の範囲まで電波を発信しているかに関するパラメータである . 本研究では, このパラメータを, アンテナが発信できる半径の距離と設定した .

表 1: The kind of antenna power

Power(m)	Cost
10	100
15	250
20	500

本研究では対象とする領域, すなわち各アンテナの電波によりカバーされる領域として, 50(m) × 50(m) の正方形の架空エリアを用いた . さらに, アンテナを配置できる候補サイトを, 縦横ともに 5(m) 間隔と設定した . また, 用いたアンテナの強さおよび付随するコストを表 1 に示す .

### 4.2 問題の定式化

本研究では、対象とするアンテナ配置問題を以下のように定式化した。

#### Objectives

$$\max f_1 = \text{Cover} \quad (3)$$

$$\min f_2 = \sum_{i=1}^n \text{Cost}_i \quad (4)$$

#### subject to

$$\text{Handover} > 50\% \quad (5)$$

$$\text{Cover} > 60\% \quad (6)$$

$$\text{The number of antennas} \leq 10 \quad (7)$$

関数式の (3) における Cover は、全領域に対してどれだけの領域をカバーしているかを示す割合値である。また、式 (4) における Cost<sub>i</sub> は、i 番目のアンテナにおけるコストを意味している。

制約式 (5) における Handover は、各アンテナが発信する電波エリアの他の電波エリアとの重なり具合を示しており、この値が 100% であった場合には、全ての電波エリア上の境界は、他の電波エリアと重なっていることになる。また、式 (5) はカバー領域に関する制約であり、式 (5) アンテナの本数に関する制約である。これらは、満足すべき目的関数の範囲を限定するために用いている。

## 5 数値実験

本章では、提案した手法を実際に幾つかの対象問題へ適用し、従来手法との比較を通じて提案手法の有効性の検証を行う。

本実験で用いた 4 つの手法を以下に示す。

- 単一母集団 GA (SGA)
- 分割母集団モデル (DGA)
- 領域分散型 GA (DRMOGA)
- 局所的培養型マスタースレーブモデル (MSLC)

提案する手法のうち領域分散型 GA を DRMOGA モデル、局所的培養型マスタースレーブモデルを MSLC モデル、また、単一母集団モデルを SGA モデル、島モデルを DGA モデルとそれぞれ略記する。

### 5.1 GA の構成

#### 5.1.1 コーディング

ネットワーク設計をするために必要な個体情報は、候補サイトから選ばれた実際にアンテナを建てるサイトの情報である。

アンテナには、方位、パワーといった情報が付随している。本研究では、アンテナの持つ方位として 2 次元の座標を想定した。個体コーディングの例を図 2 に示す。

Antenna number		1	2	3	4	.....	n
Position	x-coordinate	10	25	15	40	.....	10
	y-coordinate	75	40	25	85	.....	15
Power		15	20	10	20	.....	10

図 2: Coding of network design problem

#### 5.1.2 交叉方法

アンテナ問題においては、従来の交叉方法はあまり効果的でないと思われる。これは、従来の交叉方法では、アンテナの地理的な情報が考慮されていないからである。

それで本研究では、Herve の用いた遺伝的地理データ交叉を用いた<sup>10)</sup>。この交叉方法では、確率的に与えられた任意の半径内におけるサイトを交換する。この交叉方法は、形質遺伝性に優れているため、破壊的な交叉は行われない。図 3 に交叉方法の例を示す。

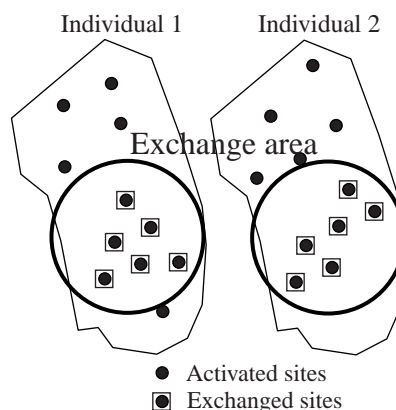


図 3: Geographical crossover

#### 5.1.3 突然変異

突然変異の手法として、我々は 2 種類の方法を用いた。1 つは、アンテナサイトの削減であり、もう一方はアンテナサイトの増加である。しかし、ランダムにこれを行ってもあまり意味がないため、アンテナを削減する場合には、最も距離的に近いアンテナサイトのペアの一方を、アンテナを増加する場合には、最も距離的に遠いアンテナサイトのペアの間にアンテナを設置するようにした。

### 5.2 シミュレーション環境と設定するパラメータ

数値計算例で使用した並列計算機は表 2 に示すような PC クラスタである。ネットワークは一般

表 2: Cluster system

CPU	Pentium III 600MHz
Memory	256 Mb
OS	Debian GNU/Linux 2.4
Network	FastEthernet TCP/IP
Communication library	MPICH1.2.1

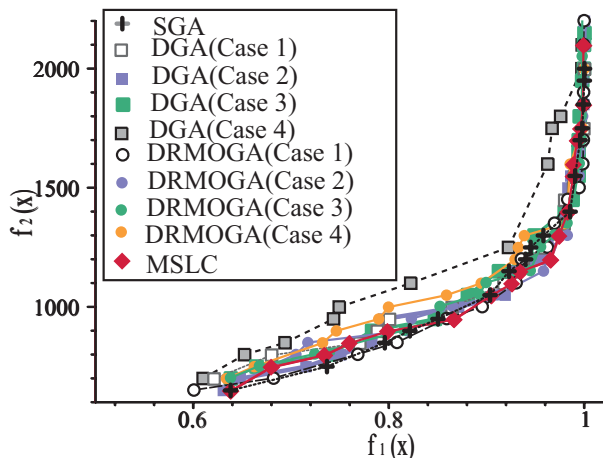


図 4: Pareto optimum individuals

的な FastEthernet および安価な Switching Hub を使用している。

表 3 に本研究で提案する DRMOGA, MSLC およびそれと比較する SGA と DGA において使用したパラメータをまとめて示す。

これまでの研究において、分割母集団モデルにおいて、用いるサブ母集団の数(島数)が探索に大きく影響することが分かっている<sup>4)</sup>。そこで、本実験では分割母集団モデルである DGA と DRMOGA に対して、サブ母集団の数が 2,4,8,16 の場合分けを行い、それぞれを Case1, Case2, Case3, Case4 として実験を行う。

これは、DGA 及び DRMOGA における用いるサブ母集団の数と最終的に得られる解の関係について考察を行うためである。

### 5.3 結果

実験結果について、各手法のパレートプロット図を図 4 に示す。この図における横軸は電波のカバー領域を表しており、縦軸はコストを表している。そのため、より右下の解が良好な解であるといえる。

図 4 から分かるように、どの手法にも大きな差は無い。ただし、DGA の Case4 のみが際だって探索が遅れている様子が見られる。

ここで、分割母集団モデルである DGA および

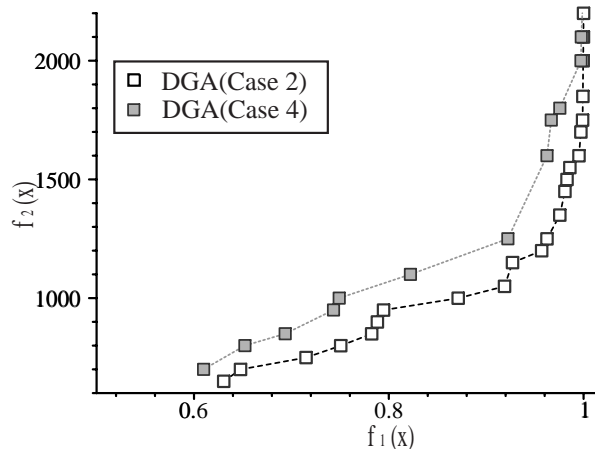


図 5: DGA pareto optimum individuals




図 6: DRMOGA pareto optimum individuals

DRMOGA におけるサブ母集団の解へ与える影響について検討する。DGA におけるサブ母集団の比較の少ない場合の Case2 と最も多い場合の Case1 について解をプロットした図を図 5 に、DRMOGA における同様の Case のプロット図を図 6 に示す。

図 5,6 より両手法ともサブ母集団のパラメータにより解の探索能力が異なっていることが分かる。特に、DGA では 2つのパレート解に大きく探索の異なりが生じている。比較的サブ母集団の数の少ない Case2 に比べ、サブ母集団の数の多い Case4 では探索が進んでいない。

一方、図 6 より DRMOGA でもやはりサブ母集団のパラメータによる影響を受けている様子が見られる。DGA 同様、よりサブ母集団の数の多い Case4 では Case2 に比べあまり良好な解が得られていない。しかし、2つのパレート解集合における探索能力の差はあまり大きなものではなく、DGA に比べその影響がかなり小さい。このことより、DRMOGA では DGA に比べサブ母集団のパラメータによる影響が少ないといえる。

各手法により得られたパレート解をより厳密に比較するため優越個体割合と被覆率の結果について考



表 3: Used parameters

	SGA	DGA	DRMOGA	MSLC
Population size			80	
Generations			100	
Crossover rate			1.0	
Mutation rate			0.0	
Migration interval (sort interval)	-		10	-
Migration rate	-	0.1	-	-

表 4: RNI of DGA

	SGA	DGA	MSLC	DGA
Case1	59%	41%	64%	36%
Case2	43%	57%	47%	53%
Case3	75%	25%	81%	19%
Case4	96%	4%	99%	1%

察する。優越個体割合の結果を表 4、表 5 に、被覆率の結果を図 7 に示す。これらの各評価手法による結果は、全て 10 試行平均の値である。SGA, DGA, MSLC を比較した優越個体割合表 4 より DGA では、Case2 の場合を除いてあまり良好な解が得られていない。サブ母集団の数が 4 島である Case2 では、SGA, MSLC の両手法を僅かながらも勝っているのに対して、比較的分割数の多い Case3, Case4 において圧倒的に劣っている。このことより、SGA, MSLC は最適なパラメータ設定を行った DGA には僅かながら劣るものの相対的に DGA よりも良好な結果を示していることが分かる。また、図 7 におけるパレート解の幅広さに関する被覆率の値にも同様の傾向を確認することができる。

一方、SGA, DRMOGA, MSLC を比較した表 4 と表 5 を比較することにより、DRMOGA は DGA に比べて相対的に良好な結果を示しているのが分かる。特に、母集団数のパラメータによる探索のばらつきも少なく、探索が安定している。また、SGA と DRMOGA を比べた結果より、DRMOGA では母集団数の最も多い Case4 を除き、ほぼ同等、それ以上の良好な結果を示している。MSLC との比較においても、SGA ほど良好な結果は得られていないが、Case4 を除いて MSLC に大きく優越されているということは無い。

また、SGA と MSLC を比較すると圧倒的では

表 5: RNI of DRMOGA

	SGA	DRMOGA	MSLC	DRMOGA
Case1	43%	57%	47%	53%
Case2	48%	52%	52%	48%
Case3	53%	47%	58%	42%
Case4	80%	20%	84%	16%

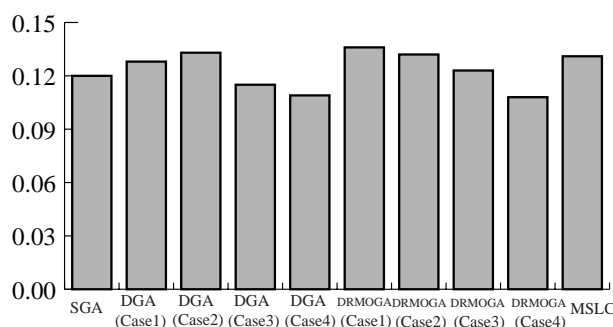


図 7: Cover rate

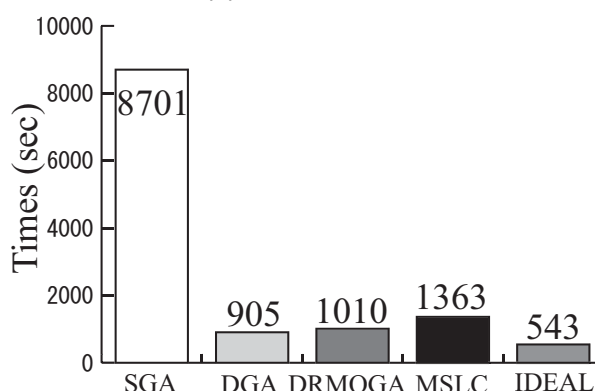


図 8: Calculation time

無いものの MSLC の方が良好な結果を示していることが分かる。本論文では省略したが、実際に優越個体割合によって SGA と MSLC を比較した場合、MSLC の方が優位な値を示すという結果も得られた。

最後に、各手法の計算時間および並列化効率について図 8 に示す。この結果は、16 プロセスを用いた場合の結果について示してある(ただし SGA は 1 プロセス)。

図 8 より、MSLC は DGA, DRMOGA に劣っているものの 16 プロセスを用いて約 6.4 倍の並列化効率を得られていることが分かる。MSLC は、DGA や DRMOGA に比べ通信量が多く通信負荷が高い。しかし、今実験で用いたアンテナ配置問題のような評価計算負荷の高い問題では十分な並列化効率を得ることができる。

## 6 結論

本研究では、アンテナ配置問題に対して新たな進化的並列アルゴリズムとして MSLC を提案し、その有効性について検討を行った。提案手法の比較手法として、単一プロセスによる SGA, 分割母集団モデルの DGA, DRMOGA を用いて数値実験を行った。また、本研究では提案手法の有効性検証だけでなく分割母集団モデルである DGA, DRMOGA に対してサブ母集団の数というパラメータの解へ

与える影響についても考察を行った。

実験によって、得られた結論を以下に示す。

- ・ 提案する MSLC は、その他の手法に比べ良好な結果を得ることができた。
- ・ DGA, DRMOGA は、用いるプロセス数(島数)が解へ大きく影響する。
- ・ DRMOGA は、DGA と比べ解探索の性能が優れており、プロセス数による解への影響も少なかった。

提案した MSLC は、ほぼ全般的に他の手法よりも良好な結果を示した。特に、SGA, DGA と比較した場合、その優位性は明白である。また、MSLC はマスタースレーブモデルの一つであるために用いるプロセス数による解への影響が無い。対して、分割母集団モデルである DGA, DRMOGA では、用いるプロセス数(分割数)によって解が大きく影響を受けることを確認することができた。そのことより、MSLC は、その他の並列手法と比較して有効な手法であると言える。また、SGA よりも探索性能が優れているために、MSLC は並列アルゴリズムとしてだけでなく、単一プロセスにおける手法としても MSLC が有効であると言える。

## 参考文献

- 1) C. M. Fonseca and P. J. Fleming. Genetic algorithms for multiobjective optimization: Formulation, discussion and generalization. In *Proceedings of the 5th international conference on genetic algorithms*, pp. 416–423, 1993.
- 2) D. E. Goldberg. *Genetic Algorithms in search, optimization and machine learning*. Addison-Wesley, 1989.
- 3) J. D. Schaffer. Multiple objective optimization with vector evaluated genetic algorithms. In *Proceedings of 1st International Conference on Genetic Algorithms and Their Applications*, pp. 93–100, 1985.
- 4) L. Nang and K. Matsuo. A survey on the parallel genetic algorithms. *J.SICE*, Vol. 33, No. 6, pp. 500–509, 1994.
- 5) H. Sawai and S. Adachi. Parallel distributed processing of a parameter-free ga by using hierarchical migration methods. In *Proceedings of the Genetic and Evolutionary Computation Conference (GECCO'99)*, Vol. 1, pp. 579–586, 1999.
- 6) 比屋根. 並列遺伝的アルゴリズムによる多目的最適化問題のパレート最適解集合の生成法と定量的評価法. 第 9 回自律分散システムシンポジウム, pp. 295–300, 1997.
- 7) B.R. Jones, W.A. Crossley, and A.S. Lyrintzi. Aerodynamic and aeroacoustic optimization of airfoils via a parallel genetic algorithm. In *Proceedings of the 7th AIAI/USAF/NASA/ISSMO Symposium on Multidisciplinary Analysis and Optimization*, pp. 1–11, 1998.
- 8) D.Q. Vicini. Sub-population policies for a parallel multiobjective genetic algorithm with applications to wing design. In *Proceedings of International Conference on Systems, Man, and Cybernetics*, pp. 3142–3147, 1998.
- 9) 渡邊 真也廣安知之. 領域分散型多目的遺伝的アルゴリズム. 情報処理学会論文誌「数理モデル化とその応用」, tom4 号, pp. 79–89, 2000.
- 10) El-ghazali Talibi Herve Meunier and Philippe Reininger. A multiobjective genetic algorithm for radio network optimization. In *Proceedings of International Workshop on Emergent Synthesis (IWES'99)*, pp. 317–324, 2000.
- 11) C. A. Coello. An updated survey of evolutionary multiobjective optimization techniques: State of the art and future trends. In *Proceedings of Congress on Evolutionary Computation*, pp. 1–11, 1999.
- 12) K.C.Tan, T.H.Lee, and E.F.Khor. Increasing multi-objective evolutionary algorithms: Performance studies and comparisons. In *First International Conference on Evolutionary Multi-Criterion Optimization*, pp. 111–125, 2001.
- 13) Yamamura-M. Satoh, H. and S. Kobayashi. Minimal generation gap model for gas considering both exploration and exploitation. In *Proceedings of the 4th International Conference on Juzzy Logic, Neural Nets and Soft Computing*, pp. 734–744, 1997.