

# 1. 序論

近年のコンピュータ性能の向上に伴う情報化の波を受け、社会的なニーズもより多様なもの、複雑なものへと変化しつつある。その一つの問題として「多目的」化が挙げられる。

本来多くの問題において、その評価基準は唯一とは限らない。例えば、ある製品を購入する場合、その製品の機能、価格、外見、重量、大きさなどその製品の評価基準は複数に及ぶ。しかも、通常それぞれの評価基準が最適の製品は存在せず、一般に各評価基準は何らかの形で互いに相反するトレードオフの関係にある。このような複数の評価基準が存在し、かつ複数の評価基準が互いにトレードオフの関係にある問題より最適解を探し出すものを多目的最適化問題と呼ぶ。故に、一般には多目的最適化問題において、解は複数個及び無限個の集合として存在する。従来の多目的最適化問題に対する手法として、複数の目的関数を任意の重み付けにより単一化する重みパラメータ法、任意の目的関数以外の目的関数を制約条件化し、任意目的関数の最適化に集約する 制約法などが提案されている。しかしながら、これらは複数もしくは無限にある解集合の中のある一つの解しか求めることができず、多目的最適化における目的関数間でのトレードオフをバランスさせた妥協解を得るという意味では不十分である場合が多い。

一方、多目的最適化の理論について見ると、目的関数間でのトレードオフをバランスさせ得る解に関して、「パレート最適性」が重要な概念として挙げられている。一般に、このパレート最適性を満足する解(パレート最適解)は複数個あり、これらを集合として求めることが、効率的かつ適切に多目的意志決定を行う上で重要となる。

そこで近年、遺伝的アルゴリズム (Genetic Algorithm, 以下 GA) の持つ “集団による探索(多点探索)” を行うという特徴に注目し、直接的に解集合を求めることを目的とした多目的 GA に関する研究が報告されその有効性が検証されている<sup>1-5)</sup>。

GA とは生物の進化を模した確率的探索手法の一つであり、その多点探索という特徴により、従来の手法では困難とされていた多峰性の問題にも適応できき、かつ離散的な問題にも対応できる最適化手法である。

GA を用いた多目的最適化では、競合する複数の関数における多目的性を直接扱うため、一度の探索においてパレート解集合を求めることが可能となるが、その際解の精度と伴に多様性という観点が非常に重要になってくる。つまり、いかに幅広く隙間のないパレート解集合を求めるかという従来の GA には無い解の幅広さと言う概念が

不可欠である．この多様性の保持に関して Horn らが提案したシェアリング (Sharing) が非常に有効であることが、幾つかの論文により明らかになっている<sup>3-5)</sup>．

しかし、GA の多目的への応用に当たっては未だ実験段階を出ておらず、特に GA により得られた解集合の定量的な評価方法、終了条件などにおいてはその有効な手段は未だ発表されていない．また、GA において個体数を分割して行う分散 GA により、より少ない計算量で解の精度が向上する事が報告されている<sup>13)</sup>．これは解の多様性保持に関して分散させた場合の方が良いこと、分散された母集団内における収束性の速さに起因するものと思われる．これらの結果は多目的最適化問題においても同様の結果が得られると考えられ、特に多目的 GA では、多様性という観点が重要となるため分散化は非常に有効であると思われる．しかし、分散型遺伝的アルゴリズムを多目的最適化に応用している例はきわめて少ない．

そこで本論文では、まず 2 章で GA による多目的最適化問題のこれまでの研究を整理する．その上で、3 章にて多目的 GA における検討事項である、得られたパレート解の評価方法及び終了条件について独自の手法を提示する．本論文において提示する評価方法は、簡便でかつ目的関数の数によらない評価が可能である．また、提示する終了条件は従来の世代、計算回数などによる終了条件ではなく、パレート解集合の探索度合いにより探索終了を判断するというものである．次に 4 章にて、本論文の主眼であるパレート解の多様性を重視した多目的分散型 GA における新たなシェアリング手法、全体シェアリングの提案を行う．従来の研究により多様性という観点からはシェアリングが非常に有効であることが証明されているが、この新たに提案する手法を用いることにより、シェアリングの特徴を最大限に生かしたより大域的な観点による効率の良い選択を実現している．このことによりパレート解における精度の改善、計算効率の向上が実現されている．特に提案する手法は、GA の並列分散化を視野に入れたものであり、並列分散化した場合における有効性を重視したものである．5 章では、今回提案したアプローチの有効性を確認するための例題、及び例題を適用した場合における数値実験結果、考察について述べている．数値実験としては、シェアリング、分散、及び本論文にて提案する全体シェアリングの効果について確認を行っている．尚、今回適用した数値計算例は簡単であるが、目的関数の数を任意に変化させることができるという特徴を持っている．

## 2. GA による多目的最適化への応用

本章では、まず多目的最適化における数学的な定義及びパレート解を求めるための最適化手法について概観する。次に GA によるこれまでの多目的最適化手法を紹介する。その中で、多目的最適化における GA の選択手法、幾つかの選択手法に用いられるシェアリング手法について説明を行い、多目的 GA の分散化のアルゴリズムについて概説を行う。

### 2.1 多目的最適化

単一目的に関する最適化問題では、対象問題に存在する複数の評価基準を一つの目的関数に縮約している。しかし、複数の目的関数をまとめることができない、もしくはまとめることが不適切な場合も存在する。このような複数の評価基準を持つ問題を多目的最適化問題という。

多目的最適化とは「複数個の互いに競合する目的関数を与えられた制約条件の中で何らかの意味で最小化する問題」と定義される。目的関数が互いに競合しあっているため、与えられた複数の目的関数に対して完全最適解を求めることはできない。具体的な多目的最適化問題の例として、リスクの最小化とリターン最大化を目的とするポートフォリオ問題を挙げてみる。ポートフォリオ問題において、リスクを最小化した場合リターンは最小化し、逆にリターンを最大化した場合リスクは最大化してしまう。つまりリスクとリターンの逆数は互いに相反するトレードオフの関係にあるため、最小のリスクと最大のリターンを満たすような最適解は一般に存在しない。

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えないような解」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。故に、多目的最適化とはこのパレート最適解 (集合) を導出することに最大の目標がある。

#### 2.1.1 多目的最適化問題

最適化問題において複数の目的関数を持つような問題は特に多目的最適化問題 (Multiobjective Optimization Problems, MOPs) と呼ばれる。一般に、多目的最

適化問題は，k 個の互いに競合する目的関数

$$\begin{aligned} f_1(x_1, x_2, \dots, x_n) &? \\ f_2(x_1, x_2, \dots, x_n) &? \\ &\square \\ f_k(x_1, x_2, \dots, x_n) &? \end{aligned} \quad (2-1)$$

を，m 個の不等式制約条件

$$\begin{aligned} g_1(x_1, x_2, \dots, x_n) &? 0 \\ g_2(x_1, x_2, \dots, x_n) &? 0 \\ &\square \\ g_m(x_1, x_2, \dots, x_n) &? 0 \end{aligned} \quad (2-2)$$

のもとで最小化するという問題として定式化される．あるいは等価的に，ベクトル最小化 (vector-minimization) の形式で

$$\begin{aligned} \min \quad & f(x) = (f_1(x), f_2(x), \dots, f_k(x))^T \\ \text{subject to} \quad & x \in X = \{x \in R^n \mid g_j(x) \leq 0, j = 1, \dots, m\} \end{aligned} \quad (2-3)$$

と定式化される．ここで  $x = (x_1, x_2, \dots, x_n)^T$  は n 次元の決定変数ベクトルで  $f_i(x) = f_i(x_1, x_2, \dots, x_n), i = 1, \dots, k$  と  $g_i(x) = g_i(x_1, x_2, \dots, x_n), i = 1, \dots, m$  は与えられた n 変数  $x_1, x_2, \dots, x_n$  の非線形の実数値関数 (real-valued function) で，実行可能領域 (feasible region) を表す．

多目的最適化問題では，一般に全ての目的関数  $f_k(x) (k=1, \dots, p)$  を同時に最小化する事はできない．むしろ，目的関数間にトレードオフの関係があることが問題の本質である．従って，目的関数間での協調をはかって各目的関数をできるだけ最小化するようにしなければならない．

### 2.1.2 パレート最適解

まず，p 次元定数ベクトル a, b 間の不等関係を，

$$\begin{aligned}
 a \succ b & \Leftrightarrow a_i \succ b_i \quad (i=1, \dots, p) \\
 a \succ b & \Leftrightarrow a_i \succ b_i \quad (i=1, \dots, p) \text{ かつ } a_i \succ b_i \quad (i=1, \dots, p) \\
 a \succ b & \Leftrightarrow a_i \succ b_i \quad (i=1, \dots, p)
 \end{aligned}
 \tag{2-4}$$

で定義する。ただし、 $a_i$  及び  $b_i$  は、それぞれ  $a$  及び  $b$  の第  $i$  要素である。ここで、

$$f(x) = (f_1(x), \dots, f_p(x)) \tag{2-5}$$

とすると、多目的最適化問題における解の優越関係は次のように定義される。

定義（優越関係）： $x^1, x^2$  とする。

- a.  $f(x^1) = f(x^2)$  の時、 $x^1$  は  $x^2$  に優越するという。
- b.  $f(x^1) < f(x^2)$  の時、 $x^1$  は  $x^2$  に強い意味で優越するという。


もし、 $x^1$  が  $x^2$  に優越しているならば、 $x^1$  の方が  $x^2$  より良い解である。従って、他のいなか解にも優越されない解を選ぶことが合理的な方法であるといえる。

定義（パレート最適解）： $x^0$  とする。

- a.  $x^0$  に強い意味で優越する  $x^?$  が存在しないとき、 $x^0$  を弱パレート最適解という。
- b.  $x^0$  に優越する  $x^?$  が存在しないとき、 $x^0$  を（強）パレート最適解という。
- c.  $x^0$  が任意の  $x^?$  に対して優越するとき、 $x^0$  を（完全）パレート最適解という。

定義より、最適解であればそれはパレート最適解であり、最適解が存在するときは、それ以外のパレート最適解は存在しない。従って、パレート最適解は多目的最適化に対する最も合理的な解（集合）であるといえる。

目的関数が二つ（ $p=2$ ）の場合におけるパレート最適解の例を Fig 1 に示す。図中、実線がパレート最適解を、破線が弱パレート最適解をそれぞれ示している。



**Fig 1 : Pareto Optimal Solution**

### 2.1.3 多目的最適化手法

一般に，パレート最適解は唯一解ではなく複数もしくは無限の集合をなしている．故に，多目的最適化問題を扱う元々の立場からいえば，何らかの過程を経て解を一つに絞ることが必要となる．そのような過程は，意志決定者の選考を陽に引き出し，これを定量化することであると考えられる．

最適解は最終的に決定者（人間）の選考によるものであり，その意味では単なる数理計画問題とは異なる．しかし，選考に関する情報をなるべくスムーズに引き出し，また，決定過程における矛盾を無くして合理性を与えるのが多目的最適化手法の役割である．

以下に代表的な多目的最適化手法を紹介する．

#### a. 重みパラメータ法

目的関数の加重和を最小にする問題：

$$\min_{x \in F} \sum_{k=1}^p w_k f_k(x) \quad (2-6)$$

ただし，

$$w_k \geq 0, \quad \sum_{k=1}^p w_k = 1 \quad (2-7)$$

を考える。この問題を解くことによって、パレート最適解の一つが得られる。ここで問題における重みパラメータ  $w_l$  を可変パラメータとして救解を繰り返すと、 $f$  空間における可能領域が凸の場合には、パレート最適解が全て求まる。しかし、非凸の場合には双対ギャップが生じるため、全てのパレート解を求めることはできない。

## b. 制約法

一つの目的関数  $f_1$  のみを残して、他は定数  $w_k$  で制約したスカラ最小化問題：

$$\min_{x \in E} f_l(x) \quad (2-8)$$

ただし、

$$E = \{x \mid f_k(x) \leq w_k, k = 1, \dots, l-1, l = 1, \dots, p\} \quad (2-9)$$

を考える。このとき、 $w_k$  の値を変化させて救解を繰り返すと、 $f$  空間における可能領域が非凸の場合でも、パレート最適解を求めることができる。この方法では、 $f_1$  の選択及び  $w_k$  の設定に意志決定者の選考が反映されることになるが  $f_1$  とそれ以外の目的関数のいずれがより重視されるかは明らかでない。

## c. 辞書式配列法

目的関数に優先順位をつけ、その優先順位に従って解を絞り込んでいく方法である。例えば、 $f_1$  のみによって順位を決め、 $f_1$  が同じものについては  $f_2$  により、さらに同じものには  $f_3$  により、……というように解を求める方法である。この方法では、明らかに先に採用される目的関数が重視されるので、その優先順位の決め方に意志決定者の選考が反映されることになる。

## d. 目標計画法

まず各目的関数の理想値  $\hat{f}_k$  を決め、 $f$  空間上の理想点  $\hat{f}$  を定める。一般に、 $\hat{f}$  は  $f$  の空間の可能領域外にある。次に  $f$  空間上の各点について  $\hat{f}$  からのズレの量を

$$\|f(x) - \hat{f}\|_q = \left( \sum_{k=1}^p |f_k(x) - \hat{f}_k|^q \right)^{1/q} \quad (2-10)$$

のように定義し，これをリグレット関数と呼ぶ．そして，リグレット関数を最小にする  $x$  を選考解とする．この方法では，意志決定者は理想点  $\hat{f}$  及びパラメータ  $q$  をあらかじめ決めなければならない．

### e. 目標到達法

目標計画法の場合と同様に理想点  $\hat{f}$  を定め，問題：

$$\begin{aligned} \min \quad & r \\ \text{s.t.} \quad & f(x) \leq r \leq \hat{f} \\ & x \in X \end{aligned} \quad (2-11)$$

を解くことにより選考解を求める．ここで， $r$  はスカラ， $\alpha > 0$  は一種の重みパラメータである．尚，この方法では，理想点  $\hat{f}$  及び方向  $q$  に意志決定者の選考が反映される．

### f. 対話的手法

上で述べた方法は，幾つかのパラメータ値や関数値をあらかじめ与えることによって単目的化し選考解を求めるものである．しかしこれらの値は意志決定者自身にとっても未知であらかじめ設定するのは難しいことが多い．また，これらのパラメータを，決定（解）過程を通して常に一定とすることも根拠はない．そこで，繰り返し型の計算によって，解の探索途中の段階で意志決定者に質問しながらその選考を取り入れる対話的な方法が有効であると考えられる．対話的手法としては，IFW（Interactive Frank-Wolfe）法，SWT（Surrogate-Worth Tradeoff）法及び ICS（Interactive Constrained Simplex）法などがある．

以上，代表的な多目的最適化手法を概説したが，それぞれの方法について，

- ?? 多目的最適化問題から単目的最適化への変換方法によっては，意志決定者の選考が十分に反映されない恐れがある．
- ?? パレート最適集合を得られている方が，意志決定者の選考をよりスムーズに引き出す事ができる．

といえる．そこで，多目的最適化問題の解法として，

?? パレート最適解を集合として求める．

?? 得られたパレート最適解の中から，最終的な選考解を選び出す．

という枠組みが有効であると考えられる．尚，従来の方法によっても，パラメータを変えながら繰り返し問題を解くと，パレート最適解を集合として求めることができるが，膨大な計算時間が必要となる．このような点を踏まえ，GA を用いてパレート最適解を求める手法が，これまでに幾つか提案されている．GA では，集団（解候補の集合）を用いて探索が進められるので，パレート最適集合を直接的，効率的に求めることが期待される．

## 2.2 多目的遺伝的アルゴリズム

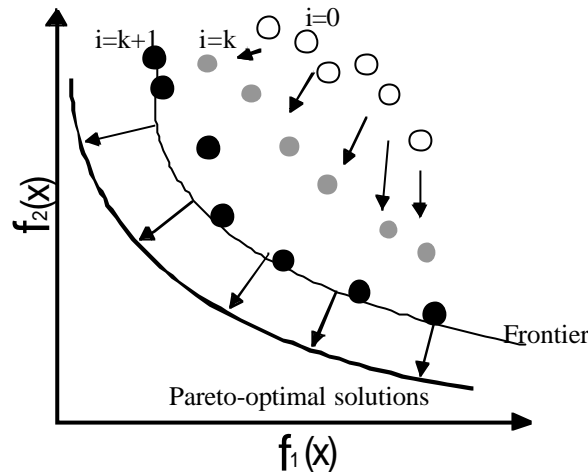
GA は自然界における生物の進化をモデル化した，最適化手法である．GA では世代を形成している個体の集合（個体群）の中で，環境への適合度の高い個体が次世代により多く生き残り，また交叉及び突然変異を起こしながら次の世代を形成していくといった操作を繰り返すことにより最適な解を探索していく．従来までの最適化手法は，そのほとんどが関数の感度を利用した山登り法に類する一点探索によるものであるため，離散的な問題や準最適解が複数存在する多峰性のある問題において最適解を探索することは困難であった．これに対して GA は多点探索であるため多峰性のある問題においても最適解が探索でき，かつ離散的な問題にも対応できる非常に強力な最適化ツールの一つである．

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，探索の各段階で，個体評価における多目的性を直接扱うことが可能である．すなわち，それぞれの目的関数に対してある程度良い値をとる個体を同時に持ちながら探索を進めることができ，Fig 1に示されるようなパレート最適集合を直接求めることが可能となる．

### 2.2.1 GA によるパレート解生成法

多目的最適問題における GA では，Fig 2に示すように設計領域内に遺伝子を生成し，交叉により新たな遺伝子を発生させなんらかの方法で選択することにより，より真のパレート最適解集合に各個体を近付ける．それぞれの世代において優越している個体

によって決定できる曲面を解のフロンティアと呼ぶ。故に、概念としては、世代が進むに連れ個体の作り出すフロンティアは真のパレート曲線（最適解集合）に近づいていくものとして捉えることができる。



**Fig 2 : The conceptual diagram of the MOPs genetic algorithm search**

GA を多目的最適化問題に対して適用する場合、パレート最適解を適切に評価し、次世代に残していくことがキーポイントとなる。従来の「一つの最適解」を求める単目的の場合と異なり、多目的では、他の解に劣っていない解(パレート解)全てが解候補となるため、単純に単目的における適合度をそのまま適応させることはできない。その点に関して、従来


- ?? おのおのの目的関数について独立に選択演算を行う（非パレートのアプローチ）
- ?? 解の優越関係に基づいて選択演算を行う（パレートのアプローチ）

という考え方に基づいて、種々の方法が提案されている。非パレートのアプローチには、J.D.Schaffer の VEGA ( Vector Evaluated GA ) がある<sup>11)</sup>。この研究は、GA の持つ多点探索という特徴に注目し多目的最適化へ応用した初めての例である。また、パレートのアプローチとしては代表的な手法としてランキング法が挙げられる。

**・ VEGA による方法**

Schaffer によって提案された VEGA は、SGA あるいは Grefenstette の GENESIS に多評価関数を導入した手法であるともみなされ、再生と交叉、突然変異の遺伝的操作

により構成されている。交叉，突然変異に関しては，単一の評価による適合度の場合と同様の方法を用いているが，単一評価 GA との根本的な違いは，個体群を目的関数の種類に等しい部分個体群に分割された部分個体群の中で，それぞれの適合度評価ごとに，独立に再生が行われる点にあった。VEGA の基本的な概念図を Fig 3 に示す。



**Fig 3 : VEGA**

しかし，パレート最適解を明に考慮していないため，ある 1 つの目的関数値のみが極端に良いパレート最適解しか得られず，多様なパレート最適解（特に，各目的関数間のバランスを考慮するようなパレート最適解）は得られにくいという問題点が指摘されている。

### ・ランキング法を用いた手法


GA では，複数の目的関数に対する個体間の相対評価，つまり個体の各目的関数を各世代内で相対的に評価し，個体に順番をつけることが可能である。

パレートランキングによる方法とは，上記における GA の特徴を生かし，解の優越関係に基づいて定められるランクとして適応度関数を作り，これにより選択を行うという手法であり，Goldberg ,Fonseca らによる方法がある<sup>3,12)</sup>。この手法では，個体間の優越関係を直接扱うことにより，バランスのとれたパレート解を考慮することが可能である。個体間の優越関係に基づきランキングする手法として，Goldberg と Fonseca による手法があるがここでは，より明確に個体間の区別が行える Fonseca によるランキング法を説明する<sup>3)</sup>。

Fonseca らのランキング法では，個体  $X_i$  が  $n_i$  個の個体に優越されているとき， $X_i$  のランク  $r(X_i)$  を

$$r(X_i) = 1 + n_i \quad (2-12)$$

のように定めることにしている．この手続きによるランキング例をFig 4に示す．



**Fig 4 : Ranking method**

このランキング法では，並列選択による方法に比べれば多少広い範囲のパレート最適解を得ることができるが，特別に多様性を維持する機構がないため分布がかなり偏ったものになってしまう．また，ランキングを測定する際全ての個体の優越関係を調べる必要があるので，計算量が多くなるという問題点がある．

このランキング法を用いた選択手法としては，ランクの値を適合度に変換し用いるルーレット選択，各世代でパレート最適個体（ランク 1 の個体）のみ残すパレート最適個体保存選択などがある．特に，パレート最適個体保存選択は，個体がランク 1 かそうでないかのみを判断すれば良いため非常に計算負荷が低い．

### 2.2.2 シェアリング

多目的最適化問題に対し GA を適する上で最大の重要点は，解をパレート最適解集合上により広範囲にかつ途切れることなく分布させることである．そのため，多目的 GA における多様性の維持は単目的の場合以上に非常に大きな意味をもっている．

現在，多目的 GA において主流であるパレートの手法では（基本的に）個体集合中のパレート解に対して同等の適応度評価を与える．そのため，これだけでは個体集合がパレート最適解集合上に偏って存在する可能性がある．しかも，このような偏りは，

選択・複製が確率的に行われる場合には遺伝的不動の効果により、世代の進みと伴に、より強調されてしまう。そこで、個体集合をパレート最適解集合上に分散させるために明示的に多様性を維持する機構を GA に導入する必要がある。

その一つの有効的な方法として Horn らによって提案されたシェアリングがある<sup>5)</sup>。以下に、シェアリングの概念を適応度に反映させる手法について述べる。

まず、各個体についてその個体の近傍の混み具合をあらかじめ与えられた関数に従って、ニッチ数として計算する。ここではニッチ数  $m_{x_i}$  を

$$m_{x_i} = \sum_{j=1}^N s(d(x_i, x_j)) \quad (2-13)$$

と定義しておく。 $d(x_i, x_j)$  は個体  $i, j$  間の距離で、その定義としては幾つかの方法が提案されている。シェアリングの適用に関し、表現空間で行うことを提案しているもの<sup>4)</sup>、目的関数空間で行うことを提案しているもの<sup>3)</sup>があるが、本論文では、個体  $i$  と  $j$  の表現型でのユークリッド距離を用いるものとする。

また、 $s(d)$  はシェアリング関数と呼ばれ、例えば近傍を定めるパラメータ(シェアリング半径)  $>0$  を与えて

$$s(d) = \max\left\{1 - \frac{d}{r}, 0\right\} \quad (2-14)$$

を用いる。

このようにして算出したニッチ数  $m_{x_i}$  でその個体の適合度  $g(i)$  を割り、それを新たな適合度  $g_S(i)$  とする：

$$g_S(i) = \frac{g(i)}{m_{x_i}} = \frac{g(i)}{\sum_j s(d(x_i, x_j))} \quad (2-15)$$

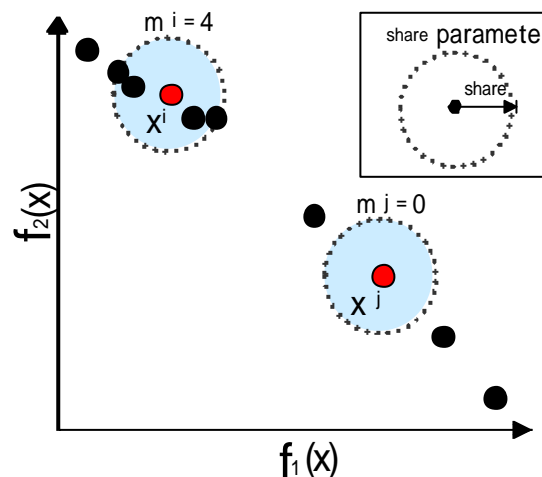
上式により再計算された適合度は、個体間の集中度合いも考慮に入れているため、この適合度を用いた選択を行うことにより個体が均一に分散された状態で次世代に受け継がれるものと考えられる。

シェアリングにおいて、個体間の近傍を定めるパラメータ、 $r_{share}$  (シェアリング

半径)は最も重要なパラメータであると言える。そこで本研究では、まず各設計変数空間ごとに最大値と最小値の差を求め、その差の2乗和に根号をかけたものを変数空間における個体間の最大距離として求める。続いて、シェアリングレンジ (sharing range) というパラメータを導入し、求めた最大距離をこのパラメータで割ることによりシェアリングパラメータ  $share$  を求めている (ここで用いるシェアリングレンジとは、パレート曲面上に分布するべき最低必要個体数を意味する。故に、シェアリングレンジによって分割された小領域内における各個体の選択確率総計は、ほぼ等しいものとなる)。

本論文におけるシェアリングは、個体数の膨張を防ぐ目的で用いられている。故に、シェアリングは毎世代行うのではなく、個体数がある一定数 (limit population size) を越えた段階でのみシェアリングが適用されるものとした。具体的には、シェアリングレンジにより導出された  $share$  を用いて式 (2-14)、(2-15) を適用し各個体の適合度を計算する。さらに計算した適合度より、ルーレット選択を用いて任意の選択個体数 (choice population size) を選択する。結果として、一定数以上の個体数 (limit population size) は、選択個体数分 (choice population size) に削減されていることになる。

シェアリングを適合度に反映させない手法としては、任意の個体におけるシェアリング範囲に含まれる個体を任意個体除いて全て削除するという手法も考えられる。この場合、個体間の距離測定が個体数の階乗で済むため計算時間の短縮が期待されるが、シェアリングの影響が直接的に現れるためパラメータ設定により注意が必要となる。Fig 5に2次元空間におけるシェアリングの概念図を示す。



**Fig 5 : Sharing**

## 2.3 GA の分散化

Cohonn, Hen により GA の並列分散化が提案されて以来, GA の分散並列化に関する研究が盛んに行われている. その最大の背景として, GA の優れた並列性が挙げられる. GA 研究の当初より, 個体の独立による並列化の可能性は指摘されていた. しかし一方では, 交叉や選択といった大域的な制御や逐次的な計算が存在するため, 同期制御による計算待ちや高コストのプロセッサ間の通信を要求し, 古典的な Holland 流の SGA をそのまま並列化しただけでは高い台数効果を得ることはできない.

また, SGA の難点として早熟収束問題 (premature convergence problem) がある. 相対的に適合度の高い個体が存在すると, 強い淘汰が行われ, まだ十分に探索が行われていないにも関わらず適合度が低い個体が死滅し, 大域的な探索が行われる前に局所最適値に収束してしまうという問題である. この問題は古くから指摘されており, スケーリングによる適合度の計算や uniqueness (唯一性) による遺伝オペレータ改良などにより初期収束を回避する試みがなされてきた. しかしながら, これらの方法は収束性を改善するものの, 特殊な遺伝オペレータを追加したり, 対象とする問題分野に依存していたりするため, 結局ロバストな解法とは言い難かった.

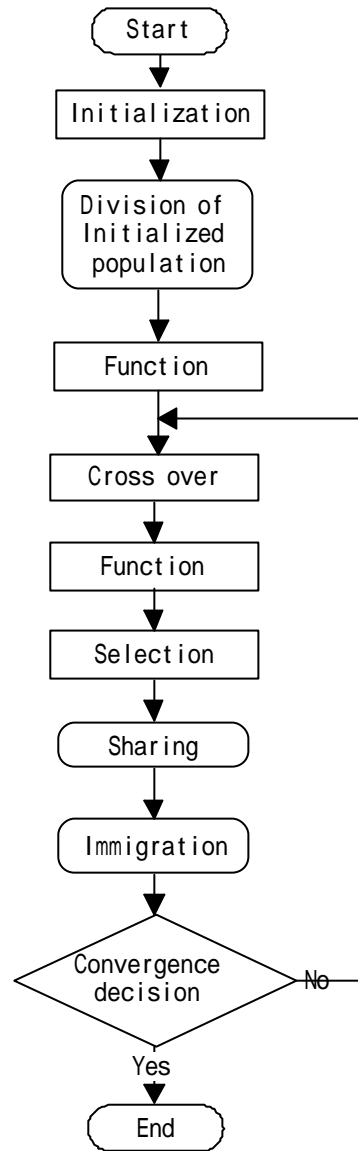
GA の並列化は, 台数効果による高速化は勿論のこと, この初期収束問題の解決を最大の目的として生まれた. GA における並列化手法としては, 大きく 2 つに大別できる. 即ち評価部の並列化と個体数分割による並列化である. 前者による手法は, 主に適合度計算が非常に掛かるような計算負荷の高い問題に対し, 単純に適合度計算の負荷を分散させたものである (micro-grained GA). しかし, GA では複製, 交叉, 選択などの大域的な情報を必要としているため, 通信コストが高く, 同期メカニズムを必要とするなどの問題点を持っている. 後者は島モデル (island model) に代表される手法で, 島と呼ばれる幾つかの独立したサブ集団について並列に計算を行い, 定期的または非定期的な島間における個体の交換を行うというものである. 島モデルは生物学的な棲み分けと分化の現象を土台に作られた. この手法における最大の利点は, 母集団を幾つかの島に分割することにより, 全体としての多様性を維持できることにある. また, 並列化効率の面を見た場合でも, GA における操作のほとんどを独立して行うことにより通信コストを最小限に抑えているなどの利点が挙げられる.

島モデルに関しての研究は, Tanese<sup>9)</sup>以来, 非常に多く行われており, 多くの成果が報告されている<sup>7,8)</sup>. さらにそれらの報告の多くは, 単なる計算時間の短縮だけでなく, 解品質の向上を指摘している. これは, 並列化による効果では無く分散化によ

る効果に他ならない．そこで，逐次型処理にも島モデルの概念を取り入れ個体の多様性保持を実現しようとする試みが生まれた．このアプローチは特に，分散 GA (Distributed GA : DGA) と呼ばれている．DGA では，島モデルにおける個体分散の概念を取り入れているため，初期個体における収束を防ぎ，個体全体による多様性の保持を実現できるものと考えられる．

島モデル分割 GA では，分割された島毎に GA の操作が独立して行われる．すなわち，島毎に異なった異なった解への収束が行われているものと期待される．移住間隔 (migration interval) と呼ばれるパラメータにより決定される世代数毎に，移住率 (migration rate) と呼ばれるパラメータにより決定される幾つかの個体を選択され，その他の島へ移動する操作を行う．この操作は移住と呼ばれる．その後，島内で遺伝的操作が行われ何回かの移住が行われて解が求められる．

DGA では，島内の個体数が少ないために各島での収束が急速に生じる．しかしながら，全体として多様性を保持しているため移住による情報交換によって探索できる．それ故に，DGA では少ない個体数で解が探索できるのである．この効果は単目的に限らず多目的にもその効果は期待できるものと考え，本論文では，多目的 GA を分散化させる手法を用いている．Fig 6に分散型のフローチャートを示す．



**Fig 6 : DGA flow chart**

# 3. 多目的 GA における新たな評価方法と終了条件の提案

## 3.1 多次元空間でのパレート解評価手法

多目的最適化 GA では、得られたパレート解に対する定量的な性能評価方法が確立されていない。研究例の多くは、得られたパレート解をそのままグラフ化することにより、得られたパレート解の評価を行っていた。これに対し、比屋根はパレート最適解の定量的な評価方法として注目すべき幾つかの手法を提案している<sup>2)</sup>。それによると、基本となるパレート解の評価基準として個体数、絶対精度、被覆率、多様性の4種類を提案している。各評価項目はそれぞれ、

**個体数**：パレート最適解が幾つ得られたか。

**精度**：真のパレート最適解集合にどれだけ近いか。

**被覆率**：真のパレート最適解集合の何%をカバーしているか。

**多様性**：パレート最適個体が適当に散らばっているか。

を意味している。これらの4つの評価項目は、パレート解の性質を測る上で、適切なものであると考えられる。しかし、これらの評価基準に対する評価方法の内幾つかは、真の解が既知であること、目的関数が2目的までに制限されていることなどの問題点を含んでいる。但し精度に関しては、真のパレート解との誤差を測定するため、真のパレート解が既知であることが絶対条件である。

そこで本論文では新たに、比屋根の提案する4つの評価項目について、目的関数の数に依存しない定量的評価方法を提案する。提案する評価手法は、簡便なものであるが、パレート解空間の次元に捕らわれず、極力真の解が未知の場合でも対応できるように考慮してある。以下、提案する各評価項目における概略、手法について述べる。

### a) 個体数

パレート最適個体の数は重要な評価基準であるといえる。ただし、同じ値の個体が重複している可能性、パレート最適個体以外の個体が混じっている場合もあり、純粹にその個体数を評価するのは危険である。個体数を評価基準として

用いる場合，純粹にその個体がパレート個体であるか，他のパレート個体と重複していないかを検査する必要がある．解候補が少なすぎる場合，最終的にパレート解集合より最適解を選択する選考者にとって期待する解が得られなくなる可能性がある．逆に，解候補があまり多すぎる場合には，選考者にとって不都合となる可能性がある．これは，解選考者にとって膨大な解候補の中より最適解を選ぶよりも，ある程度限られた解候補の中で最適解を選ぶ方が選考しやすいためである．しかし，この場合最終の選考段階においてシェアリングなどを用いて個体数を効率的に削減することは可能であるので，大きな問題にはならない．

## b) 精度

精度とは，得られた解と真の解との誤差である．そのため，真の解が既知であることが絶対条件となる．

最も正確な精度を計測するためには，得られた解と（真のパレート解における）最近接点とのユークリッド距離を用いて測定する必要がある．しかしながら，目的関数が 3 目的以上の場合，得られた解に対する最近接点を計算することが困難となる．そこで，今発表では，以下のような簡易的な精度測定法を用いた．今，得られた個体  $k$  を  $x^k = (x_1^k, \dots, x_m^k)$  とし，真のパレート解が  $f(x_1, \dots, x_m) = C$  で表されるものとする．そこで簡易誤差  $e(x^k)$  として，

$$e(x^k) = C - f(x_1^k, \dots, x_m^k) \quad (3-1)$$

とする．また，パレート最適解集合の精度  $E$  は誤差の平均値で表される．

$$E = \frac{1}{N} \sum_{k=1}^N e(x^k) \quad (3-2)$$

## c) 被覆率

例えば，パレート最適解の一点のみが探索された場合，解の精度は，非常に良くなるが，パレート解集合として十分とはいえない．そのため，精度とは異なる横幅の広さを示す指標が必要であるといえる．被覆率とは，いかに真のパレート解隙間無く詳細に求めているかを評価する基準で，概念的には，精度が真のパレート解への接近を目指す縦の尺度であると考えれば，被覆率は全体的な隙間のない広がり重視する横の尺度であるといえる．正確に真の解をどれだ

け覆っているのかを測るためには、純粹には真の解の存在は不可欠である。しかし、対象問題によっては真の解が分からないような場合もある。そのような場合においても、求められるような被覆率評価方法として次のようなものが考えられる。

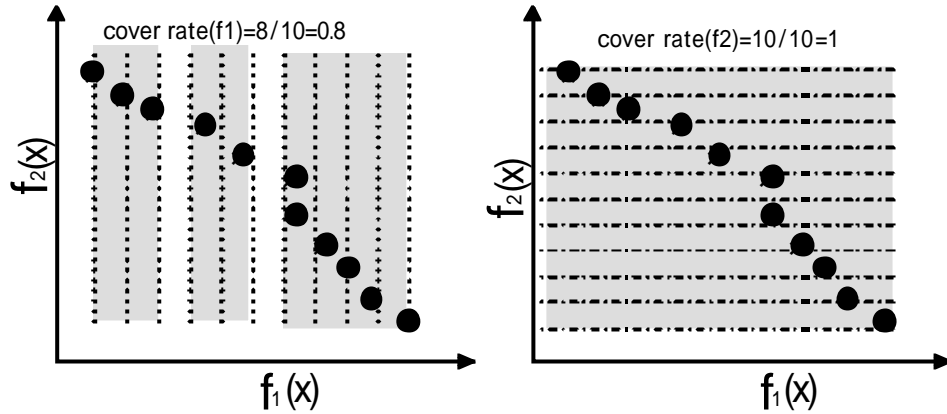
真の解が既知の場合、正確な各目的関数値の最大と最小を用い、各目的関数を軸に、最小値と最大値の間を任意数に分割し、分割された領域をどれだけカバーしているかをその値とするものである。尚、真の解が未知の場合には、得られたパレート最適解より各目的関数値の最小値、最大値を用いて同様の評価を行うことにより対応することができる。ある目的関数  $f_k$  における  $C_k$  は

$$C_k = \frac{N_k}{N} \quad (N \text{ は分割数, } N_k \text{ はパレート最適解を含む小領域の数}) \quad (3-3)$$

により求められる。また、パレート最適解集合の被覆率  $C$  は各目的関数毎における被覆率  $C_k$  の平均により表される。

$$C = \frac{1}{N} \sum_{k=1}^N C_k \quad (3-4)$$

この手法は非常に簡便なものであり、得られるパレート解空間の形状に左右されやすいという問題点がある。しかし、パレート解集合の次元に一切捕らわれないため、非常に汎用的な手法であるといえる。被覆率の評価方法に関する概念図をFig 7に示す。

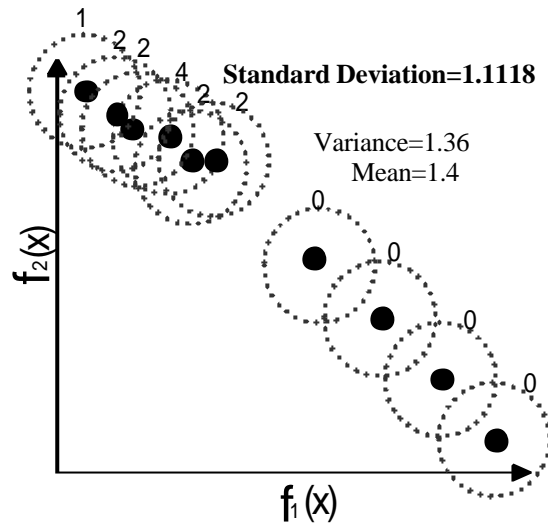


**Fig 7 : Cover rate**

d) **多様性**

多様性とは、解がいかに均一に分布しているかを示す評価基準である。計算コストなどを考えた場合、より少ない個体数でパレート最適解を表現したい。多様性とは、いかに解のばらつきが少ないもしくは多いかを示す指標といえる。今、真のパレート曲線が既知でありかつ目的関数が 2 目的である場合には、比屋根の提案する曲線に沿った相対累積度数分布曲線をその基準として用いることができるが、真のパレート解が未知である場合、目的関数が複数の 2 目的以上の場合には適用することができない。そこで、今研究では、真の解の既知、未知及び目的関数の数に依存しない以下のような評価手法を提案する。

各個体ごとに、任意距離内における個体の数を調べ、この範囲内における個体数の平均、分散、標準偏差を調べることにより個体間同士のばらつき度合いを調べることができる。故にこの手法は、シェアリングの概念を取り入れた評価方法であるといえる。多様性の評価方法に関する概念図をFig 8に示す。



**Fig 8 : Diversity ( various rate )**

今研究では，各個体の任意の範囲内に含まれる個体数の平均（mean）を標準偏差（standard deviation :  $s$ ）で割ることにより得られる変動計数の値を多様性のパラメータとして用いている．

$$V \approx \frac{s}{mean} \quad (3-5)$$

変動計数は，0以上の値をとり，0に近いほど平均の割りに標準偏差が低い，つまりパレート解集合が均等に分布している解集合が得られていると判断することができる．多様性のパラメータである変動計数には，任意範囲に含まれる平均個体数も大きく考慮されるようになっている．これは，平均個体数が多いほど標準偏差の値は大きくなる傾向にあり，範囲内に含まれる平均個体数と標準偏差の値双方より多様性（ばらつき）を評価する必要性があるためである．

上記に挙げた4項目に関する評価方法に共通していることは，その汎用性の高さである．パレート解空間の次元に捕らわれないこの評価方法は，特に多次元になるほどその特徴が活かされるものと思われる．現在までに研究されている多目的の多くは，2目的問題に限定されているため，容易にパレート解を視覚化することができ，得られたパレート解を確認することができる．しかし，今後多目的最適化に関する研究はより複雑な3目的，4目的へと発展することが予想され，現在のように単純に視覚化

し、その評価を行うことは困難であると思われる。そういった意味において、パレート解の評価及びその評価方法今後ますます重要になってくるものと思われる。

### 3.2 新たな終了条件の提案

従来までの多目的 GA に関する研究のほとんどが、あらかじめ設定された特定の世代を越えた段階で終了するという、世代に基づく終了条件を用いていた。しかしながら単目的、多目的に関わらず、探索の終了条件として世代を用いるのは決して良い方法とは言えない。その最大の理由は、終了条件に探索の収束具合が反映されない点にある。これは、世代による収束条件では、解の収束を明示的に扱うことができないことに起因する。次に、個体数、交叉率、突然変異、移住率などにより探索能力、探索の性質は大きく異なるため GA における世代の持つ本質的な意味は無いことが挙げられる。特に、個体数を一定ではなく可変としている場合には、さらに世代の持つ意味は薄れてしまう。

世代以外の終了条件としては、計算回数、計算時間を用いる方法が考えられる。世代に比べ、これらの条件は解の精度に対する計算効率、計算速度をより明確に比較することができるように思われる。しかし、世代の場合と同様に、明示的に収束状況を扱っているわけではないので、終了条件に解の収束具合が反映されず、探索終了の条件として適当ではないと思われる。

そこで、従来の世代、計算回数、計算時間とは異なる、アルゴリズムの探索具合より、終了を判断する新たな終了条件を提案する。この提案する手法では、明示的にパレート解の探索具合を扱っているため、より正確な手法の比較が行えるものと思われる。提案する終了条件を以下に記す。

任意の世代  $N$  におけるパレート最適個体群（ランク 1 個体）を  $P_N$ 、世代  $N$  から任意世代後の  $N+T$  世代におけるパレート最適個体群を  $P_{N+T}$  とする。この両者のパレート最適個体群を足し合わせ、その中よりパレート最適個体を抽出する。その上で、 $P_N$  全体の内、何個体が抽出されたのかその割合を計測し、一定以上の割合で  $P_N$  がランク 1 として抽出されていたならば、その時点により探索を終了する。

この終了条件における  $P_N$  が抽出される割合は、探索の進行具合を示す一つの指標であるといえる。つまり、一定割合以上の  $P_N$  が抽出されているということは、 $N$  世代の個体  $P_N$  が作り出すフロンティアと  $N+T$  世代後の個体の作り出すフロンティアに変化が無いことを意味しており、このことは探索の停滞を意味しているものと考えられる。故に、この提案する終了条件は、パレート個体の作り出すフロンティアの形成具

合に基づく方法といえる。本論文では、この終了判定に用いる任意の割合を終了パラメータ (Termination parameter) として設定している。


しかし、この提案する終了条件では、終了しない場合がある。著者は、世代の進行と共に、 $P_N$  が抽出される割合は高まっていき、限りなく「1」に近づくものと予想していた。しかし、実際には無限に探索を進行する場合があることを確認した。これは、非常に微少ずつフロンティアが真のパレートフロンティアに近づくことに起因しており、この微少な近づきが限りなく0に近いにも関わらず、フロンティアが探索を続けていると判断するためである。得られたパレート解のフロンティアは、真のパレート解局面に接近する必要があるが、局面と接近すればするほどその探索速度は、遅くなり必要以上の精度を得るために無限に近い膨大な時間を費やしてしまうことがある。

この必要以上の精度を求めるために、計算を続けるのは、あまり意味がなく計算時間の冗長の原因となる。そこで、本論文では、終了条件判定時における個体間比較においてのみ、許容誤差  $\epsilon$  を取り入れ計算時間の助長を防ぐ手法を取り入れている。この場合の定義を下に示す。

定義(優越関係) :  $x^1, x^2$  とする。

$f(x^1) = f(x^2) + \epsilon$  の時、 $x^2$  は  $x^1$  に優越していないものとする。

つまり、個体間比較における目的関数の差が許容誤差範囲に収まっている場合、その個体は、許容誤差内においてより良い値を持つ個体が存在しても、優越されていないと判断するように若干の幅を持たせている。許容誤差  $\epsilon$  は、最適解を決定する選考者の求める精度によって決定されるものであり、GA におけるパラメータとは異なる。提案する終了条件の手法にこの誤差の概念を導入することにより、選考者はある程度期待する精度に基づいて探索の進行を制御することができる。逆に、この誤差が無ければ、精度を限りなく0に近づけようと探索は続けられ場合によっては永遠に探索し続けることも考えられる。従来の世代や計算回数、計算時間を用いた終了条件では無駄な探索を続けたり、逆に必要な探索が行われていないことが考えられる。しかし、提案する終了条件では、誤差パラメータにより探索の進行を間接的に把握する事ができるため、(パラメータ)設定者の期待する探索を過不足なく行うことができる。提案する終了条件の概念図をFig 9に示す。



**Fig 9 : Termination criterion**

Fig 9における終了条件の概念は、世代間における探索進行距離（Search progress distance）が任意の誤差内であれば終了するというものである。つまり、探索距離がある任意以下（誤差）になった段階により探索を終了する。

## 4. 多目的分散 GA における全体シェアリングの提案

母集団を島モデルに分散させることにより，早熟収束が回避できる，解の多様性が保持されやすくなるといった分散の効果に関して幾つかの研究によりその有効性が確認されている．しかし，母集団を分散させることによるデメリットとして次の事柄が考えられる．

### 1. 計算効率の悪化

個体を島毎に分散させることにより各個体は，全体的な視野を失う．そのことにより，全体を考慮した個体の選択が行えなくなるため計算効率が悪化する．また，局所的な視野内でシェアリングが行われるため，効果が十分に発揮できない恐れがある．

### 2. 個体の成長遅延

分割された母集団は，基本的に独立した島内において成長するため，単一島の場合に比べ，どうしても個体の成長が遅れてしまう．

### 3. パラメータ設定の難化

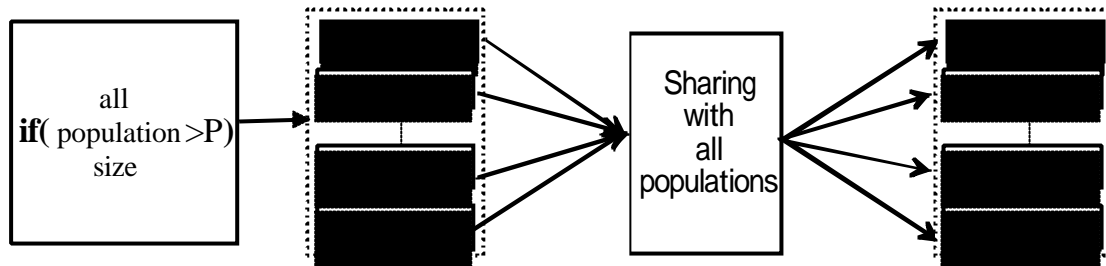
単一に比べ，各一島辺りの個体は，小規模なものになってしまう．そのため，各パラメータの値に対し敏感になる傾向がある．特に，シェアリングパラメータは，個体群が小規模かつパレート解空間全体をも視野に入れる必要があるため，その設定が非常に難しくなる．また，移住間隔，移住率という新たなパラメータが増え，よりパラメータ設定が困難になるという問題もある．

そこで，本論文では上記の問題点，特にシェアリングの問題を解決すべく，非定期的に全島全体からシェアリングを行う全体シェアリングを提案する．この手法は GA の並列への拡張を視野に入れたものであり，並列化した際における本手法の有効性を重視したものである．

この手法における概要，アルゴリズムとその有効性について以下述べる．

## 4.1 全体シェアリング

全体シェアリングとは，非定期的に母集団全体を一カ所に集計し，母集団全体を用いてシェアリングを行うという単純な手法である．全体シェアリングにおける概念図をFig 10に示す．



**Fig 10 : Sharing with all population in DGA**

本論文では，多目的 GA における選択手法としてパレート最適個体保存選択を採用しており，2 章 2 節で説明したように，シェアリングは個体数の膨張を防止するための，効率の良い個体数削減のための手法として用いている（アルゴリズムに関する説明は，5 章 2 節にて行っている）．故に，新たに提案する全体シェアリングに限らず，シェアリングは全てある一定数以上の個体数を開始条件として設けている．個体数膨張の防止策としてシェアリングを用いたのは，より広範囲の効率の良い探索を続行するためである．以下，全体シェアリングの簡単な流れを説明する．

全体シェアリングは，Fig 10に示されるように，各島における個体数の総計がその開始条件となる．開始条件となる総個体数は問題領域及びマシンのメモリ許容に依存するため一概には言えない．総個体数が任意の個体数を世代において，母集団全体を一カ所に集める．その上で，まず母集団全体より全個体を用いた比較を行いランク 1 の個体（パレート解）のみを選択する（第一段階の選択）．尚，本論文における選択手法としてランク 1 の個体のみを選択するというパレート最適個体保存選択を用いている．故に，各島においてはランク 1 の個体しか存在しない．選択されたパレート解の内，重複している，もしくはほぼ同値であると判断された個体を削減する（第二段階の選択）．最後に，残った個体を用いて任意のシェアリングパラメータを用いてシェアリングを用いたルーレット選択を行う（第三段階の選択）．このように三段階の選択を行った後，各島に対しほぼ平等の個体数になるようにランダムに振り分け，従来の分散 GA の動作に戻り一連の動作終了となる．

このように，全体シェアリングでは，個体数増に対し，実際には三段階の選択により個体を選別している．故に，個体増に対するより効率的な削減が実現するものと考えられる．

## 4.2 全体シェアリングの有効性について

上節で述べたように，全体シェアリングは単にシェアリングに留まらず，全体的な視野に立った三段階の選択を行っている．全体シェアリングによる効果，利点として，次の事柄が挙げられる．

### 1. 計算効率の向上

非定期的に広域的な視野に基づく選択（パレート最適個体保存選択 + シェアリング）を行うことにより，無駄な計算を防止する効果が期待される．

### 2. 並列化に対応

本手法は，分散 GA を土台として成り立っており，GA を並列化した場合にも対応することが出来る．

### 3. 島間における個体数，探索能力の是正

各母集団が独立している場合には，各島における個体数は島間において当然異なってしまう．そのため，島間における探索能力にも大きな差が生じ全体として無駄が生じることが考えられる．しかし，母集団を一旦全て集計し，その中で選択された個体を再度各島に平等に分配することにより，個体数，探索能力の島間の差異は削減される．

### 4. 移住の必要性減少

移住は独立して探索を行う島間における個体交換を行っているのだが，母集団全体シェアリングは個体を一旦全て集計し，その後選択された個体をランダムに各島に振り分けるため，各島間における個体交換の役目も担っていると考えられる．特に，島間における情報交換と言う意味では移住に比べより強力であるといえる．

### 5. パラメータ設定の影響力減少

島内におけるシェアリングでは，島内個体数が任意数以上になった段階で，ある程度の個数まで個体数の削減を行う．しかし，各島における個体数をどの程度の個数まで削減するかを決めることが非常に困難である．島内における個体数がある任意数まで削減してしまうと，その島における固体集合の被覆率が大幅にダウンし，削減しすぎてしまう可能性がある．しかし，ある程度削減を行わなければ全体としての個体数が極大化する可能性があるため，そのバランスが非常に難しい．特に，島数が多ければ多いほどこの問題は深刻化する傾向にある．しかし，母集団全体においてシェアリングを行う場合には，最低必要個体数と削減後の個体数の関係が直接的であるため，そのような問題は無い．

上記に共通した事として，独立した島の意味合いが薄れ，より各サブ母集団が一つとして探索を行っていることが挙げられる．これは，各島が独立して探索を行っているにも関わらず，各島の個体が全体としての解を意識していることを意味している．つまり，従来の島内におけるシェアリングの場合では，各島毎に独自のパレート解を得ることに主眼がおかれていたのに対して，全体シェアリングでは各島全ての個体より，完全なパレート解を得ようとする傾向が強いといえる．

このように，全体シェアリングを行うことにより分散 GA における問題点であった，全体的な視野を各島，各個体に与えることが期待され，より効率的な探索が実現されるものと思われる．そのことにより分散の効果が薄まることが予想されるが，本手法のように増加しすぎた個体削減においてのみ全体的な選択を行っている場合には，さほど分散の効果は消えないものと思われる．つまり，全体シェアリングは，分散における多様性の効果，単一島における広域的な視野といった双方の利点を兼ね備えた手法であるといえる．

## 5. 数値実験

本章では、実際に例題を解くことによりシェアリングの効果、分散の効果、提案する手法の有効性について検討を行う。また、実際に例題を解くにあたり、用いたアルゴリズムについても概説を行う。今回、本論文で用いたアルゴリズムの最大の特徴は、突然変異を用いず、解探索を交叉のみに依存している点にある。交叉方法としては、三村らの提案する重心を用いた正規分布交叉を適用している<sup>14)</sup>。この手法は形質遺伝性に優れた交叉方法であるため、十分な初期個体を用いた場合の突然変異の必要性は無いものと思われる。

### 5.1 例題

本研究では、提案した手法の有効性を検討するために以下に示すような単純な関数による  $n$  次元の多目的最適化（最小化）問題を検討する。

#### 目的関数

$$\begin{aligned} f_1 &= x_1 \\ f_2 &= x_2 \\ &\vdots \\ f_{n-1} &= x_{n-1} \\ f_n &= x_n \end{aligned} \quad (5-1)$$

#### 制約条件

$$\begin{aligned} g_j &= x_j & (j = 1, 2, \dots, n) \\ g_{n-k} &= x_k \leq 6 & (k = 1, 2, \dots, n) \\ g_{2n-1} &= 1 - x_1 - x_2 - \dots - x_n \leq 1 \end{aligned} \quad (5-2)$$


ここで適用する例題は、簡単な関数であり、容易に目的関数の次元数を拡張できるという特徴を持っている。

これまでの多目的 GA に関する研究で用いられてきた例題の多くは、2次元の問題に限定されている<sup>1,2,9)</sup>。これは、2次元におけるパレート集合の場合、容易に表示する事が可能であるため、視覚的にアルゴリズムの評価を把握することができるからである。さらに最大の理由として、2次元のパレート解に限定することにより、問題領


域が限定された，比較的複雑性のない単純な問題領域内での探索が行えることが挙げられる．

しかしながら，多目的最適化問題において次元を 2 次元に限定することは，限られた多目的最適化問題を対象としていることになり，広義の多目的最適化問題を対象にしているとは言い難い．さらに，2 次元の場合には有効であった手法も 3，4 次元もしくはそれ以上の次元において有効であるかどうかは，適用してみない限り判断できない．特に，多次元化することにより最適必要個体数は指数的に増加することが予想され，膨大な個体数を用いた探索に対応できるかどうかの問題となる．例えば，2 次元の問題において最低  $100(10^2)$  個のパレート最適個体が必要であったとするならば，3 次元では  $10^4$  個体，4 次元では  $10^6$  個体が最低必要であろう個体数と考えられる．個体数の増加は，個体間のランク付け，シェアリングなどに大きく影響を及ぼすため，計算時間も非常に膨大なものになることが予想される．また，問題領域の多次元化はシェアリングパラメータの設定を難しくさせることも大きな問題である．これは，パレート解空間の多次元化に伴いパレート解空間の把握が非常に困難になるためである．つまり，2 次元の場合，パレート解曲面のおおよその長さを把握すれば良いのに対して，3 次元では立体曲面状のパレート解空間におけるおおよその面積を把握する必要がある．さらに 4 次元以上では，概念では理解することができないが，面積よりもさらに高次のパレート解空間に関する情報を把握する必要がある．このように，次元数が高くなるほどパレート解空間の把握は難化する傾向にあり，パレート空間の形状に基づくシェアリングパラメータの設定も難しくなる．このような理由により，数値計算例によるアルゴリズムの検討はこれまで行われているような 2 次元の問題では十分とはいえず，3 次元以上の問題への適用が必要であると考えられる．そのため，本論文では，3 次元 ( $n=3$ ) の問題を対象として実験を行っている．

また，すでに述べているようにアルゴリズムの性能を正確に評価するためには，真のパレート解の存在が不可欠である．それに対し，今回用いた例題では，次元数の増加に対しても容易に真のパレート最適解集合が得られるという特徴を有している．Fig 11及びFig 12に 2 次元の場合，3 次元の場合におけるパレート最適解集合を示す．



**Fig 11 : Pareto optimum solution ( n=2 )**



**Fig 12 : Pareto optimum solution ( n=3 )**

## 5.2 アルゴリズムの構成

本論文において用いるアルゴリズムは，島モデルにおける分散遺伝的アルゴリズムを基本としている．また，各島内において行う操作は，Fig 6に示した流れと同様である．

今回用いたアルゴリズムにおける特徴を以下に示す．

- ?? 遺伝子としてビット型ではなく，ベクトル型のものを利用している．
- ?? 交叉方法として，重心を用いた正規分布交叉を採用している．
- ?? 突然変異を用いない．
- ?? 選択手法として，パレート最適個体保存選択を採用している．
- ?? 個体数膨張の防止として，シェアリングを用いている．

?? 終了条件として，新たに提案したフロンティアを考慮した条件を用いている．

本論文におけるアルゴリズムでは，遺伝子としてビット型ではなくベクトル型を用いている．即ち，各遺伝子は例えば，

$$a_1 = [0.02, 1.035, \dots, 7.52] \quad (5-3)$$

といったベクトルで表現でき，各要素は設計変数の値を直接示す．そのため，個体における表現型と遺伝子型についてコード化，デコード化といった操作を行う必要はなく計算負荷を軽減することができる．特に，今回は関数ベクトルをその対象問題として用いたため，遺伝子をビット型で表現する必要性は無いものと思われる．ただし，ビットを用いていないため，従来の SGA における一点交叉，多様交叉などの交叉方法は用いることができない．そこで本論文では，三村の提案する重心を用いた正規分布交叉を採用している．具体的な操作を以下に示す．

設計変数が  $n$  個の場合について考える．まず，親候補個体群より  $n+1$  個の親個体  $P_i (i=1, \dots, n+1)$  を抽出する．これは，設計変数の次元 ( $n$ ) に対応した選択個数となっており，正確に  $n$  次元空間を考慮に入れるための抽出個体数 ( $n+1$ ) となっている．次に，その  $n+1$  点の親個体間における重心 ( $G$ ) を計算し，重心と  $n+1$  点間において  $n+1$  点の子供候補  $C_k (k=1, \dots, n+1)$  を次式に従い導き出す．

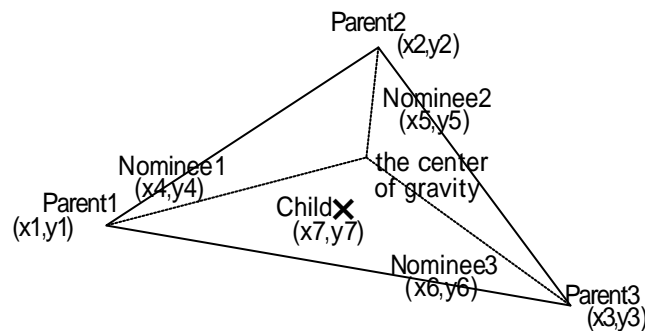
$$C_k = G + N(0, \sigma^2) \frac{GP_i - G}{|GP_i - G|} w \quad (5-4)$$

上式における  $N$  は正規分布であり分散  $\sigma^2$  は親個体  $P_k$  と  $G$  間の距離としている．また  $w$  は，生成される子供候補の幅をさらに広く（もしくは，狭く）するためのパラメータである．故に， $w$  が大きい場合，子供候補の値は，重心  $G$  付近よりも離れた，遠く的位置に生成されやすくなり，逆に小さい場合には，重心  $G$  付近にしか生成されないようになる．本論文では， $w = 1.5$  としてある．

上式に従い，全ての生成された子供候補よりその平均を用いて次世代の子供  $C$  とする．

$$C = \frac{1}{n+1} \sum_{i=1}^{n+1} C_k \quad (5-5)$$

設計変数が 2 の場合における，この交叉方法の概念図をFig 13に示す．

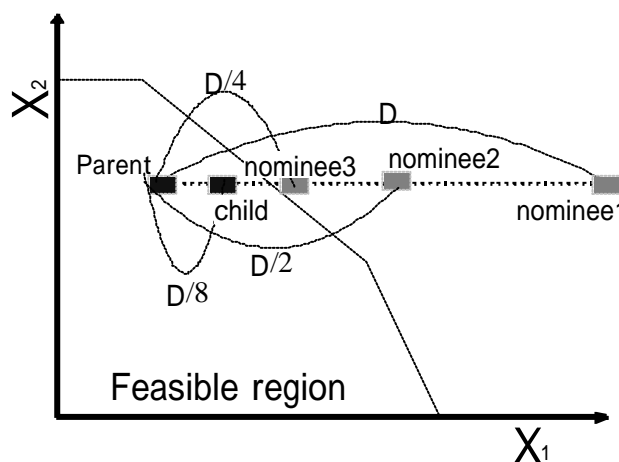


**Fig 13 : Normal distribution crossover used center of gravity**

また，この交叉方法によって生成された子個体  $C$  が制約条件を満たしていない場合には，次式により代替個体  $C^*$  を得る．

$$C^* = P_1^? P_2^? P_3^? C \quad (5-6)$$

上式は，子個体の親個体への接近を意味している．上式における  $\alpha$  は，代替個体がどの程度現在の子個体から親個体に近づいた位置に置かれるかを表すパラメータであり，本論文では  $\alpha = 0.5$  と設定した．代替個体が，制約条件を満たすまで，上式は繰り返され，制約条件内に入った段階で代替個体は真の子個体となる．  $\alpha = 0.5$ ，設計変数 2 におけるこの操作の概念図をFig 14に示す．



**Fig 14 : Operation of replacing child into the constraints**

この交叉方法は、形質遺伝性に優れており、必ず親個体付近に子個体が生成されるようになっている。故に、初期個体の段階において最低限の多様性を保持していれば突然変異は必要ないと判断される。故に、本論文におけるアルゴリズムでは突然変異を用いていない。突然変異はその性質上、探索領域を無限に広げる可能性を持った探索手法の一面を持っている。しかし、その本質はランダムサーチであり、GA は突然変異に依存すべきではなく、むしろ突然変異は用いないほうが良いといえる。

また、多目的 GA における選択手法としては、パレート最適個体保存選択を用いている。この選択手法は、ランク 1 の個体のみを全て次世代に残しランク 1 以外の個体は全て除去するという非常に単純な手法である。パレート最適個体保存選択の最大の特徴は、その単純さ故に、他の選択手法と比較において計算負荷が非常に低いことである。しかしこの選択手法を用いることにより、ランク 1 の個体が非常に膨れ上がった場合には、個体数もそれに伴い非常に膨大化してしまうことが予想される。そこで、個体数がある任意個体数を越えた段階において、2 章 2 節において説明したシェアリングを用いて多様性をできるだけ維持する形で選択を行い、個体数を減少させるという手法を用いる。

さらに本論文におけるアルゴリズムでは、3 章 2 節にて提案したパレート解の作り出すフロンティアの変化に基づく新たな終了条件を適用している。この終了条件では、現在の世代におけるパレート最適個体群とどれだけ離れた（前世代の）パレート最適個体群を比較するか、その世代間隔が重要になってくるが、今回は特にシェアリングに注目し、N 回目のシェアリング終了後の個体と N+1 回目のシェアリング直前の個体を比較するようにした。つまり、N+1 回目のシェアリングを行う直前に、N 回目のシェアリング直後における個体を用いて、終了判定を行っている。母集団を分散させた島モデルでは、島毎にシェアリングが行われるため、各島毎に終了判定の値を出し、その平均を用いて最終的な終了判定の材料としている。

### 5.3 GA の設定

数値実験には、単一母集団遺伝的アルゴリズム（CGA）と、母集団を十島に分割した DGA（島モデル）の大きく分けて 2 種類の GA を適用して用いている。SGA、DGA に共通するパラメータを Table 1 に示す。ただし、表における初期個体数（initial population size）は、初期総個体数を意味するものであり、全ての実験条件において乱数で与えた同一の初期値を用いているものとする。また、DGA 特有のパラメータについて Table 2 に示す。

さらに，SGA，DGA 共通の終了条件に関するパラメータをTable 3に示す．本論文では，Table 3に示した終了条件において終了しない場合，200 世代になった時点で強制的に終了させるという手法を用いている．これは，解の無限探索をくい止めるための強制的な防止策である．

尚，今回の実験を行うに辺り使用したマシン環境は，CPU：Pentium 400MHz，Memory：128MBytes，OS：Linux 2.0.36 となっている．また，全ての実験結果は10 回試行の平均値を用いている．

**Table 1 : GA Parameter setting**

Parameter	Value
initial population size	1000
crossover rate	1
mutation rate	0
limit last generation	200

**Table 2 : Parameter setting for DGA**

DGA Parameter	Value
migration interval	5
migration rate	0.1
island number	10

**Table 3 : Parameter setting for termination criterion**

Termination criterion Parameter	Value
Termination Parameter tolerance	0.98 0.0001

## 5.4 実験結果及び考察

例題に対する数値実験として，以下の3つの項目について行った．

- ?? シェアリングの効果
- ?? 分散の効果
- ?? 全体シェアリングの効果

まず，シェアリングに関するパラメータが解に与える影響について（シェアリン

グ半径)を中心に考察を行い、最適なパラメータ設定について検討を行う。次に、母集団を分割させた場合におけるその効果について実験を行い、分散させた場合の特徴について考察する。最後に、提案する全体シェアリングの効果について、DGA、CGAの場合と比較し、その効果について考察する。

#### 5.4.1 シェアリングの効果

まず、シェアリングのパラメータによる影響について調べる。本論文における、シェアリングに関するパラメータは、シェアリング開始個体数(limit population size)、シェアリングレンジ(sharing range)、シェアリング選択個体数(choice population size)の3つである。これらの3つのパラメータは、互いに密接に関わり合っており、結果に対し少なからず影響を与えるものと考えられる。そこで、CGAを用いて何種類かのパラメータによる結果比較を行い、パラメータの持つ特徴、傾向について考察を行う。

シェアリングの効果に関する実験条件をTable 4に示し、結果Table 5に示す。尚、Table 4における各Caseは、それぞれ次のような意味を持っている。

- ?? Case1, 2 はシェアリング開始個体数が比較的少ない場合
- ?? Case3, 4 はシェアリング開始個体数とシェアリング選択個体数に差がある場合
- ?? Case5, 6 はシェアリング開始個体数が比較的大きい場合
- ?? Case 番号の偶数と奇数は、シェアリングレンジの大小を区別

**Table 4 : Experiment condition in CGA**

Case	limit population size	sharing range	choice population size
1	6000	100	5000
2	6000	4000	5000
3	10000	100	5000
4	10000	4000	5000
5	10000	100	8000
6	10000	8000	8000

**Table 5 : Result to the Example in CGA**

Case	number of solutions	accuracy	cover rate	diversity	generations	Calculation time[sec]	function call
1	5000	0.014773	0.99	0.2754	12.3	640.92359	44459.5
2	5000	0.016671	1	0.3785	14.9	916.6307	57443.8
3	5000	0.010062	1	0.2857	27.4	2624.9196	158529
4	5000	0.011333	1	0.2926	37.2	4048.9504	225971
5	8000	0.010977	0.99	0.2622	12.2	1516.2988	62285.2
6	8000	0.013082	1	0.397	16.1	2528.2454	93411.6

Table 5より,シェアリング半径が結果に対し大きな意味を持っていることが分かる。即ち,シェアリング半径が大きい程(シェアリングレンジが小さい程),計算時間及び計算回数が少ない傾向がある。これは,シェアリング半径の広いシェアリングでは,全体的なばらつきを考慮した個体数保持が行えるため,計算効率が優れていることに起因していると思われる。

また,シェアリング範囲の広い方が,パレート解の評価値全般において良い結果を出している。評価項目の内,多様性が優れているのは,上述と同じく全体的なばらつきを考慮した選択が実現されているためである。精度に関しては,次のような理由であるためと考えられる。

個体の精度を上げるには,ある程度周辺に個体が存在することが条件となる。これは,真のパレート解への接近を目指す精度において,局所的な個体の集中は不可欠であることに起因している。個体の局所的な集中は,全体的な広がりを求める被覆率,多様性といった観点からは矛盾するものであるが,シェアリング半径が広いことにより局所的な個体のある程度残しつつ,全体的な多様性の保持を実現することができる。故にシェアリング半径の大きい場合,局所的な個体を排除しつつ個体の精度を高めるという一見矛盾した行為を行うことが可能となる。

次に,シェアリング開始個体数が少ない方が計算回数,計算時間が少ないことが分かる。本論文で用いたアルゴリズムでは,比較的早い世代においてある程度探索が終了する。そのため,探索に必要な個体数はCase1,2における6000個体で十分であるといえる。また必要個体数が少ない場合,その分局所的な探索を行うことができないため,探索は収束しやすいことも原因であると考えられる。特に,Case1とCase5を比較した場合,計算回数の差に比べ計算時間に大きく差が生じているのが分かる。これは個体数の増加が,個体全ての距離,位置を比較する必要があるシェアリング,個体のランク付け操作などの計算時間増に影響するためである。

しかし、個体数を多く用いて探索を行った方が、より精度の良い個体が得られていることが分かる。これは、上述のように精度を向上させるためにはある程度、局所的な個体の集中が必要であるのに対し、個体数の上限が高い場合、より局所的な個体の集中が生じやすいからである。このことより、ユーザーの求める精度によりシェアリング開始個体数（必要個体数）は変化させるべきであり、より高次の精度を求めるためにはより多くの計算回数、計算時間を要すると考えられる。

また結果より、シェアリング開始個体数とシェアリング選択個体数の差は少ないほど計算回数、計算時間が短いことが分かる。特に計算回数においては大きな開きが認められる（Case3, Case5 の比較）。これは、シェアリングによる選択（間引き）による影響はより少ない方が良いことを意味している。シェアリングでは、多様性保持のため全体的なばらつきを考慮して個体選択を行う。しかし逆に、局所的に集中している個体を排除することは、精度の向上を妨げてしまい、結局、解の（精度面における）進行を遅らせる若しくは停滞させてしまう。故に、シェアリングに基づいた個体数の削減は、出来る限り最小限で行うことが計算効率の面から重要であるといえる。結論として、次のことがいえる。

計算効率的、パレート解の各評価値において、シェアリング半径は広くとる必要がある。また、シェアリング開始個体数（上限個体数）とシェアリング選択個体数の差はあまり大きくしてしまうと、シェアリングの効果が強く出てしまい解の探索を遅らせる原因となるため差をあまり大きくしないようにしなければならない。解の精度は、シェアリング開始個体数（個体数の上限）と密接に関わっており、より精度の良いパレート解を得るためにはより多くの個体数を必要とする。しかし、個体数の増加は、計算回数、計算時間の増加につながるため、求める精度との兼ね合いを考慮する必要がある。

#### 5.4.2 分散の効果

母集団を分割した場合（DGA）の効果について調べる。CGA の場合と同様、DGA においても、シェアリングの効果は結果に大きく影響することが考えられる。そのため、幾つかのパラメータ設定による場合を実験し、それらの結果と CGA における結果を比較することにより DGA の特徴について考察を行う。

分散の効果に関する実験条件を Table 6 に示す。また、結果を Table 7 に示す。尚、Table 6 に示したパラメータは分割された 1 母集団辺りのものである。

**Table 6 : Experiment condition in DGA**

Case	limit population size	sharing range	choice population size
1	600	100	500
2	600	500	500
3	1000	100	500
4	1000	100	600
5	1000	100	800
6	1000	800	800

**Table 7 : Result to the Example in DGA**

Case	number of solutions	accuracy	cover rate	diversity	generations	Calculation time[sec]	function call
1	4613.2	0.016085	1	0.2745	14.8	105.87386	63522.2
2	4551.2	0.016002	1	0.3298	16.7	126.15989	73218.4
3	4915.6	0.008843	1	0.243	200	2112.8243	1378704
4	5546.8	0.01444	1	0.2642	14.9	153.13716	76706.1
5	7418.3	0.012779	1	0.2469	15.2	257.42779	97704.6
6	7302.7	0.012517	1	0.3242	17.6	323.45895	117496

尚，Table 7における Case3 は，10 試行全てにおいて終了条件を満たせず，200 世代にて強制的に終了を行った．終了条件を満たせなかった理由としては，2 つ考えられる．即ち，シェアリング開始個体数とシェアリング選択個体数の差が大きすぎることで，シェアリング開始個体数（個体数の上限）が比較的大きいことである．前述のように，シェアリング開始個体数とシェアリング選択個体数の差が大きい場合，多様性重視の選択を行うシェアリングの効果が強調され探索の進行を遅らせてしまう．しかし個体数の上限がやや大きくとられているため，シェアリング後からの探索は（上限個体数に至るまで）局所的な個体集中は容認され探索は進む．そのため，シェアリングにより探索を止められ，次のシェアリングまでの間（上限個体に至るまでの間），僅かずつ探索を進めることができるため個体は，常に僅かずつではあるが探索を進行させているのである．しかし，このような探索の方法は非常に効率面からは無駄が多い（探索が進むたびに，シェアリングによりその探索進行を止められ，また探索が進行し始めた段階においてシェアリングが行われるからである）．パレート解評価値における精度については，良い値を示しているものの計算回数は膨大な回数行われており，精度に見合った計算回数を行っているとはいえない．CGA と（全体としてみれば）同様のパラメータ設定にも関わらず，このように終了しない状況が生まれるのは

分散化させた場合の方がシェアリングパラメータによる影響を受けやすいためと考えられる。

結果より、CGA と比較した DGA の特徴として計算回数的大幅な短縮が挙げられる。これは、一島辺りの個体数が少ないため実現されたと考えられる。つまり、一島辺り個体数が少ないため全個体間の距離、位置関係を調べる必要のあるシェアリング、リンク付けなどの操作が短時間でできるのである。

しかし逆に計算回数、終了世代では若干増加の傾向があるのが分かる。これは、分散させたことによる計算効率の悪化が原因であると思われる。個体を分散させる DGA では、一島辺りの初期個体数は島数分の 1 になる上、一島辺りの個体数の上限も（ハードウェアの制約上）島数分の 1 に限られるため、CGA に比べ少ない個体数を用いて探索を行わなければならない。そのため DGA における各島単位で見した場合、CGA に比べ十分な探索を行うことができない。また、移住は行っているものの基本的には、各島が独立しているため解の重複なども避けることができない。基本的に、十分な探索が行われていない個体群（島）を集めた場合より一つの個体群により十分探索した場合の方が有利であると考えられるため、個体を分散させた DGA では計算効率は、CGA に比べ多少悪くなる傾向がある。

パレート解評価項目に関しては、CGA と比べ大きく異なる項目は無い。しかし、多様性、精度について若干異なっている。多様性について見た場合、全体的に CGA に比べ良好な値を示している。これは、解を分散させることにより、解の収束性を島数に分散できるからである。つまり、CGA のように単一島の場合、相対的に良い個体に全体が影響される恐れがあるが、DGA では母集団を分割することによりその影響を緩和しているのである。また、精度に関して若干値が劣っていることが分かる。これは上述の DGA の持つ分散させた場合の不利な条件によるものであると考えられる。

また、3つのシェアリングパラメータによる影響について見た場合、CGA の場合とほぼ同様の傾向があることがわかる。故に、シェアリングパラメータによる影響は、CGA、DGA に関わらず普遍的な傾向があるものと思われる。

個体群を分割して遺伝的操作を行う DGA は、並列化への拡張を行うための予備実験的な意味を含んでいる。DGA による結果より、並列へ拡張した場合にもある程度期待する並列化効率を得られることが予想される。しかし、分散化することによる計算効率の悪さは並列化した場合にも該当する問題と思われるため、分散化させた場合におけるより計算効率の良い方法が必要であると思われる。

### 5.4.3 全体シェアリングの効果

分散の効果として、より少ない計算時間により結果を得られることが分かった。これは、主に一島辺りの個体数差によるシェアリング計算時間の差に起因するものである。しかし、母集団を分散させることにより計算効率は悪化する傾向にあり、目的関数などの評価関数にある程度時間を要するような場合、DGA はあまり有効的とは言えない。

ここでは、DGA に全体的な視野を取り入れた全体シェアリングについてその有効性を検証する。全体シェアリングの効果に関するシェアリングパラメータは、CGA におけるパラメータTable 4と同一のものをを用いた。また、結果についてTable 8に示す。

尚、全体シェアリングを用いる DGA では移住を行っていない。これは各島ごとに独立した個体群がシェアリング時に一カ所に集められ、混ぜ合わされて分配されるため、各島ごとの個体交換を行う移住の必要性が無いためである。

**Table 8 : Result to the Example in DGA with new sharing method**

Case	number of solutions	accuracy	cover rate	diversity	generations	Calculation time[sec]	function call
1	5000	0.014659	0.99	0.2581	12	735.02431	48558.8
2	5000	0.015601	1	0.3581	12.8	849.60091	52581.4
3	5000	0.009678	1	0.275	36	3735.1935	230683
4	5000	0.012121	1	0.2928	32.8	3695.0529	208678
5	8000	0.011114	1	0.2477	12	1847.7396	70637.3
6	8000	0.011943	0.99	0.3813	13.4	2235.3621	81831.7

結果より、従来の DGA に比べ計算効率が大幅に向上しているのが分かる。これは全体シェアリングが、単なる島内でのシェアリングに比べより全体的な視野に基づいてシェアリング選択を行っているためである。つまり全体シェアリングでは、解集合を島毎に分割しているにも関わらず各個体は全体を意識した探索を実現している。そのため無駄を極力削減することができ、計算効率が向上するのである。分散させた場合における計算効率の向上は、GA の並列への拡張においても非常に重要な意味を持って来る。即ち、並列化させた場合において問題となるであろう計算効率に関して、その向上手段としての可能性を秘めている。

また、パレート解評価値について見た場合には CGA、従来の DGA と比較して大きな違いはなく、精度について見た場合には僅かながら最も良好な値を示している。こ

れは解を分散させ幾つかの島に独立に成長を行い，増加しすぎた個体に対し全体を用いたシェアリング選択を行うによる効果であると思われる．しかし，多様性について見た場合，CGA よりは優れているものの，従来の DGA と比べ僅かに改悪されているのが分かる．これは，全体シェアリングが分散の効果を弱める特徴があるためである．全体シェアリングでは，非定期的な個体全てを統合する操作を行うため島毎の独立性は一部失われる．ただし，その差が僅かであること，CGA には勝っていることより分散の効果はある程度保持されているものと考えられる．

さらに，計算時間について見た場合，従来の DGA における計算時間短縮という特徴は完全に失われているのがわかる．これは，シェアリング時において全個体を用いた計算を行っているためである．また，シェアリング時における個体の集中，分配といった作業も計算時間の増加の一因である．

以上より全体シェアリングは，DGA における欠点であった計算効率，パレート解の精度を改善した手法であると言える．しかしながら，個体間選択（シェアリング，ランク付け）に時間がかかるため，特に評価関数の計算に膨大な時間が掛かるような場合，有効な手法であるといえる．

## 6. 結論

本論文では，個体群の多様性を保持する上で有効なシェアリングの特徴に注目し，分散遺伝的アルゴリズムにおける新たなシェアリング手法として，全体シェアリングの提案を行った．適用例題として3目的3変数の関数を用いて，シェアリングにおけるパラメータの影響，多目的最適化 GA の分散化による影響，そして提案する全体シェアリングを用いた分散遺伝的アルゴリズムの有効性について検証を行った．

また，多目的最適化 GA では多数のパレート最適解集合が得られるため，その定量的な評価が難しいが，本論文では多次元空間にも対応できる汎用性の高い新たな評価方法を提案し，有効性を実証するため利用した．さらに，多目的最適化 GA では従来の多くの手法が終了条件として世代や計算回数，計算時間に基づくものを用いていたのに対し，解の探索具合に基づく新たな終了条件を提案し，その有効性を実証するため利用した．

### 6.1 結論

本論文では数値実験として，シェアリングにおけるパラメータの影響，多目的最適化 GA の分散化による影響，多目的分散 GA における全体シェアリングの有効性について検証を行った．

その結果，シェアリングにおけるパラメータの影響として次のことが判明した．

- ?? シェアリング半径が広いほど早く，かつ少ない計算回数で終了した．
- ?? シェアリング半径が広いほど，各評価項目の値は全般に優良であった．評価項目の内，特に多様性についてはその傾向が顕著であった．
- ?? シェアリングによる影響はより小さい方が計算効率も良く早く終了した．
- ?? 個体数の上限は高いほど精度の良い解を得ることができたが，探索に時間がかかった．

故に，良いシェアリングパラメータの条件としては，シェアリング半径を広くとりシェアリングによる影響を小さくことが考えられる．また個体数の上限については，選考者の求める精度によって定めるべきである．

また，多目的最適化 GA の分散化 (DGA) による影響として次のことが判明した．

- ?? 計算時間が短縮された．
- ?? 計算効率が悪化した．
- ?? パレート解の評価項目の内，精度において多少劣化する傾向があった．
- ?? 多様性が向上した．
- ?? シェアリングパラメータによる影響は増大する傾向にあった．

故に DGA では目的関数などの評価関数の計算時間が短い場合には非常に友好的な手段であることが分かった．また，GA を並列へ拡張した場合には，台数による計算負荷の分散だけでなく個体間評価の計算負荷軽減が期待されるものと思われる．

さらに，全体シェアリングにおける特徴として次のことが判明した．

- ?? (DGA と比較して) 計算効率が改善した．
- ?? 精度が向上した．
- ?? (DGA と比較して) 計算時間が増大した．

全体シェアリングでは，解の分布が一様であることより，シェアリングが効果的に行われる手法であるといえる．また，通常の DGA に比べ優れた計算効率を実現できるため，GA を並列へ拡張した場合にも有効な手法として期待できる．全体シェアリングを用いた場合，個体間評価における計算負荷は増大するものの，評価関数の計算負荷が高い問題では並列化することにより計算台数の線形に近い計算時間短縮が実現できるものと思われる．

## 6.2 今後の課題

今後の課題を以下に示す．

- ?? 並列分散 GA への全体シェアリングの適用
- ?? より多次元の複雑な問題への適用

本論文において提案した分散遺伝的アルゴリズムにおける新たなシェアリング手法は，GA の並列化を意識したものであった．故に，実際に並列分散 GA に対し提案する手法の有効性を検証する必要がある．

また，より複雑な問題，特に目的関数の数が3目的以上の問題に対し多目的GAの適用を試みる必要がある．しかし，より複雑，広範囲にわたるパレート解集合を探索するためには膨大な個体数を必要とするため，ハードウェア的な要素からも並列化は必要不可欠である．

## 謝辞

本研究を行うにあたり，多大なるご指導，そしてご協力をいただきました同志社大学知識工学科システムデザイン研究室の三木光範教授，廣安知之助手，さらに本研究全般にわたり温かい助言を下された大分大学の三村泰成さんに心より感謝いたします．

また，本論文作成に辺り一つ一つ丁寧に指導頂いた同志社大学 システムデザイン研究室の畠中一幸さんに深く感謝いたします．

## 7. 参考文献

- 1) 玉置 久, 森 正勝, 荒木 光彦, “ 遺伝的アルゴリズムを用いたパレート最適解集合の生成法, ” 計測自動制御学会論文集, Vol.31, No.8, P1185 ~ 1192, 1995 .
- 2) 比屋根 一雄, “ 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 回自律分散シンポジウム, 計測自動制御学会, P295 ~ 300, 1997 .
- 3) C.M.Fonseca and P.J.Fleming , “Genetic algorithms for multiobjective optimizations , ” Proc.of 1st Int.Conf.on Genetic Algorithms and Their Applications , pp.93-100 , 1985 .
- 4) N.Srinivas and K.Deb , “Multiobjective optimization using nondominated sorting in genetic algorithms , ” Evolutionary Computation , Vol.2 , No3 , pp.221-248 , 1995 .
- 5) J.Horn,N.Nafpliotis and D.E. Goldberg , “A niched Pareto genetic algorithm for multiobjective optimization , ” in Proceedings of the First IEEE Conference on Evolutionary Computation , pp.82-87 , 1994 .
- 6) Johgno NANG and Kazuhiro Matumoto , “A Survey on the Parallel Genetic Algorithms , ” 計測と制御 , Vol.33 , No.6 , pp.500-509 , 1994 .
- 7) Theodore C.Belding , “The Distributed Genetic Algorithm Revisited , ” PROCEEDING OF THE SIXTH INTERNATIONAL CONFERENCE ON GENETIC ALGORITHMS , pp.176-183 , 1991 .
- 8) Reiko Tanese : Distributed Genetic Algorithms , Proc.3<sup>rd</sup> International Conf.Genetic Algorithms.Morgan Kaufmann , pp.434-439 , 1989 .
- 9) 森 直樹, 藪本 靖之, 喜多 一, 西川 よしかず: 熱力学的遺伝的アルゴリズムによる多目的最適化, システム制御情報学会論文誌, Vol.11, No.3, pp.103-111, 1998 .
- 10) C.M.Fonseca and P.J.Fleming : An overview of evolutionary algorithms in multiobjective optimization,Evolutionary Computation 3 , pp.1-16 , 1995 .
- 11) J.D.Schaffer : Multiple objective optimization with vector evaluated genetic algorithms , Proc.of 1<sup>st</sup> International Conference on Genetic Algorithms and Their Application , pp.93-100 , 1995 .
- 12) D.E.Goldberg : Genetic Algorithms in Serch,Optimization,and Machine

Learning , Addison Wesley , pp.197-201 , 1989 .

- 13) M.Miki : Parallel Genetic Algorithm with Parameter-Free Approach , Proc.of ICES 98 , Vol.1 , pp.582-587 , 1998 .
- 14) 三村 泰成 , 廣安 知之 , 三木 光範 : ( 仮 ) 実数コードを用いた GA のための交叉方法の開発 , 日本機会学会論文集 ( 投稿中 ) .
- 15) 坂和 正敏 , 田中 雅博 : 遺伝的アルゴリズム , 朝倉書店 , 1995 .
- 16) 三宮 信夫 , 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 .
- 17) 北野 宏明 : 遺伝的アルゴリズム 2 , 産業図書 , 1995 .