

修士論文

多目的遺伝的アルゴリズムにおける
解の精度と幅広さの向上の検討

同志社大学大学院 工学研究科 情報工学専攻
博士前期課程 2008年度 751番

王 路易

指導教授 三木 光範教授

2010年1月23日

Abstract

Multi-objective optimization problems have several types of objective function. As there is often a tradeoff relationship between objective functions, it is usually impossible to find a single optimal solution. In this case, one of the goals of multi-objective optimization problems is to obtain Pareto optimal solutions, which are solutions with objective values that cannot be simultaneously improved without degradation of at least one other value. There have been many recent studies involving the adaptation of Genetic Algorithms (GAs) to multi-objective optimization, as the GA search is performed by multiple individuals and is capable of obtaining Pareto solutions in a single search. GAs for multi-objective optimization are called Multi-objective Genetic Algorithms (MOGAs). Many MOGAs have been developed to derive Pareto optimal solutions. In multi-objective optimization, it is desirable to obtain solutions of high quality with regard to accuracy, uniformity, and broadness. While many MOGAs have mechanisms to improve accuracy and uniformity of the solutions, there are few MOGAs capable of improving the broadness of the solutions. Broadness of the solutions is decided by the optimal solutions of each objective, and is important for understanding the tradeoff relationships among the objectives. This thesis presents a novel optimization method called Dual Procedures Multi-Objective Genetic Algorithm (DPMOGA), which can derive broader solutions compared to conventional MOGAs without deterioration of accuracy. The DPMOGA consists of two search phases, because it is difficult to improve accuracy and broadness of the solutions simultaneously. The proposed algorithm has two phases. The reference point is utilized in the first phase to improve accuracy of the search, and the SOGA search is adopted in the second phase to improve broadness of the solutions. Numerical experiments were performed using test problems to verify the effectiveness of DPMOGA. The results indicated that higher-accuracy and broader solutions could be obtained by DPMOGA than conventional methods.

目次

1	序論	1
2	多目的最適化	2
2.1	多目的最適化問題	2
2.2	パレート最適解	2
2.3	多目的遺伝的アルゴリズム	4
2.4	NSGA-II	4
2.5	多目的遺伝的アルゴリズムにおける問題点	7
3	精度と幅広さの向上を考慮した 2 段階プロセス多目的 GA	8
3.1	2 段階プロセス多目的 GA の設計指針	8
3.2	1 段階目：精度の向上を重視した探索	9
3.3	2 段階目：幅広さの向上を重視した探索	11
3.4	探索の切り替え (Step 3, Step 4-4)	12
4	数値実験	14
4.1	実験概要	14
4.2	評価手法	14
4.3	実験パラメータ	17
4.4	実験結果	17
5	結論	20

1 序論

最適化とは、ある制約条件のもとで目的とするものを最小化（最大化）することである。一般には、1つの目的（評価基準）に対する最適化を行う。しかしながら、世の中には複数の評価基準を同時に考慮すべき問題が数多く存在する。このような、複数の評価基準を同時に考慮しながら最適化を行う問題を多目的最適化問題という。多目的最適化問題における複数の評価基準は互いに競合することが多く、そのような場合にはただ1つの最適解は存在しない。そのため、多目的最適化では、「パレート最適解」という概念を用いて探索を行う。パレート最適解とは、「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つの目的関数の値を改悪せざるを得ないような解」と定義されている。一般にパレート最適解は複数存在することが多く、目的関数間に存在するトレードオフの関係を知らずとも、パレート最適解を数多く求めることが重要となる。

多目的最適化では、多点探索によってパレート解集合を一度の探索で得ることができる遺伝的アルゴリズム（GA：Genetic Algorithm）を用いることが多い¹⁻⁶⁾。GAを多目的最適化に適用したものを多目的遺伝的アルゴリズム（多目的GA）と呼ぶ。多目的GAの多くの手法は、解集合の精度と均一性を向上させるためのメカニズムを有するが、解集合の幅広さを向上させるメカニズムが組み込まれているものは少ない。そのため、多目的GA手法と単一目的GA手法を同時に用いる分散協力型スキームが奥田らによって提案された⁷⁾。しかし、探索の序盤から解集合の幅広さを向上させることによって、精度の低下がこれまでの実験においてみられた。このように、解集合の精度と幅広さを同時に向上させることは困難である。

本研究では探索のプロセスを2段階に分割することによって、精度と幅広さを個別に向上させる多目的最適化手法DPMOGA（Dual Procedures Multi-Objective Genetic Algorithm）を提案する。探索の1段階目は解集合の精度を向上させるための探索とし、2段階目を幅広さを向上させるための探索とする。本論文では、DPMOGAの有効性について検証し、一般的な多目的GA手法より精度および幅広さ共に向上する結果を得られた。

本論文の構成を以下に示す。まず、第2章では多目的最適化および多目的遺伝的アルゴリズムの説明を行う。そして、第3章で提案するDPMOGAのアルゴリズムについて述べる。第4章でその有効性をテスト関数を用いた数値実験により検証する。最後に第5章で結論を述べる。

2 多目的最適化

2.1 多目的最適化問題

複数の目的を同時に最適化する問題を多目的最適化問題という。多目的最適化問題は一般的に、 n 個の設計変数を扱う k 個の目的関数 $\vec{f}(\vec{x})$ を、 m 個の制約条件 $\vec{g}(\vec{x})$ のもとで最小化（最大化）する問題として式 (2.1) のように定式化される⁸⁾。

$$\begin{cases} \min(\max) & f_i(x_1, x_2, \dots, x_n) & (i = 1, 2, \dots, k) \\ \text{subject to} & g_j(x_1, x_2, \dots, x_n) \leq 0 & (j = 1, 2, \dots, m) \end{cases} \quad (2.1)$$

多目的最適化問題では、一般に複数の目的関数同士が互いに競合する場合が多いため、全ての目的関数 $f_i(\vec{x})$ を同時に最適化することはできない。そこで、多目的最適化問題では、ただ 1 つの最適解を求めるかわりに、パレート最適解の集合を求める。

2.2 パレート最適解

パレート最適解は、多目的最適化問題における解の優越関係により定義される⁹⁾。多目的最適化における解の優越関係の定義を以下に示す。ただし、全ての目的関数の最適化は最小化であると仮定する。

定義（優越関係）： $\mathbf{x}_1, \mathbf{x}_2 \in \mathfrak{S}(\mathbf{x} = (x_1, x_2, \dots, x_n))$ とする。

- (a) $f_i(\mathbf{x}_1) \leq f_i(\mathbf{x}_2) (\forall i = 1, 2, \dots, k)$ の時、 \mathbf{x}_1 は \mathbf{x}_2 を優越するという。
- (b) $f_i(\mathbf{x}_1) < f_i(\mathbf{x}_2) (\forall i = 1, 2, \dots, k)$ の時、 \mathbf{x}_1 は \mathbf{x}_2 を強い意味で優越するという。

もし、 \mathbf{x}_1 が \mathbf{x}_2 を優越しているならば、 \mathbf{x}_1 の方が \mathbf{x}_2 よりも良い解である。そのため、多目的最適化では、他のどの解にも優越されないような解の探索を行う。次に、この優越関係に基づくパレート最適解の定義について以下に示す。

定義（パレート解）： $\mathbf{x}_0 \in \mathfrak{S}(\mathbf{x} = (x_1, x_2, \dots, x_n))$ とする。

- (a) \mathbf{x}_0 を強い意味で優越する $\mathbf{x} \in \mathfrak{S}$ が存在しないとき、 \mathbf{x}_0 を弱パレート最適解 (Weak Pareto-optimal solution) という。
- (b) \mathbf{x}_0 を優越する $\mathbf{x} \in \mathfrak{S}$ が存在しないとき、 \mathbf{x}_0 をパレート最適解 (Pareto-optimal solution) という。

Fig. 2.1 に目的が 2 つ ($k = 2$) の場合におけるパレート最適解の例を示す。図中の黒丸はパレート最適解を、白丸は弱パレート最適解を示している。また、Feasible Region とは実行可能領域を示し、解が存在し得る領域を示している。一般に、図中に実線で示されるパレート最適解集合が形成する面のことを、パレート最適フロントと呼ぶ。また、探索途中で得られた、他のどの解と比較しても劣らない解を非劣解と呼ぶ。

多目的最適化では Fig. 2.2 に示すように精度、幅広さ、均一性といった性質において優れているパレート解集合を求めることが探索目標となる。精度とは、Fig. 2.2(a) に示すように得られたパレート

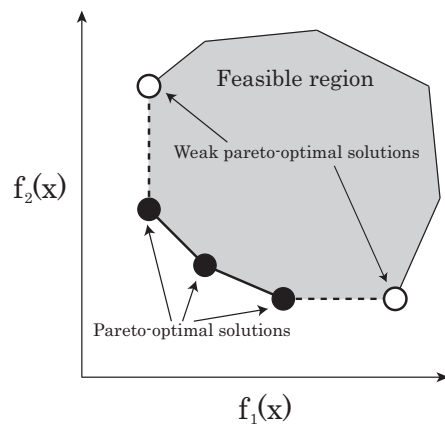


Fig. 2.1 パレート最適解

解集合が目的関数空間において、パレート最適フロントにどれだけ近いかを表す指標である。パレート最適フロントに近いパレート解集合ほど精度が高く、パレート解集合において重要な性質となる。次に、幅広さとは、Fig. 2.2(b) に示すように得られたパレート解集合が目的関数空間で集中することなく、どれだけ幅広くパレートフロントを覆っているかを表す指標である。最後に、均一性とは、Fig. 2.2(c) に示すように得られたパレート解集合が目的関数空間でどれだけ均一に分布しているかを表す指標である。多目的最適化手法により得られたパレート解集合の中で、どの解が最も好まれるのかは意思決定者の選択に委ねられる。意思決定者に数多くの選択肢を与えるため、様々なパレート解を意思決定者に提示することが望まれる。従って、幅広く均一に分布しており、精度の高いパレート解集合を導出することが重要となる。

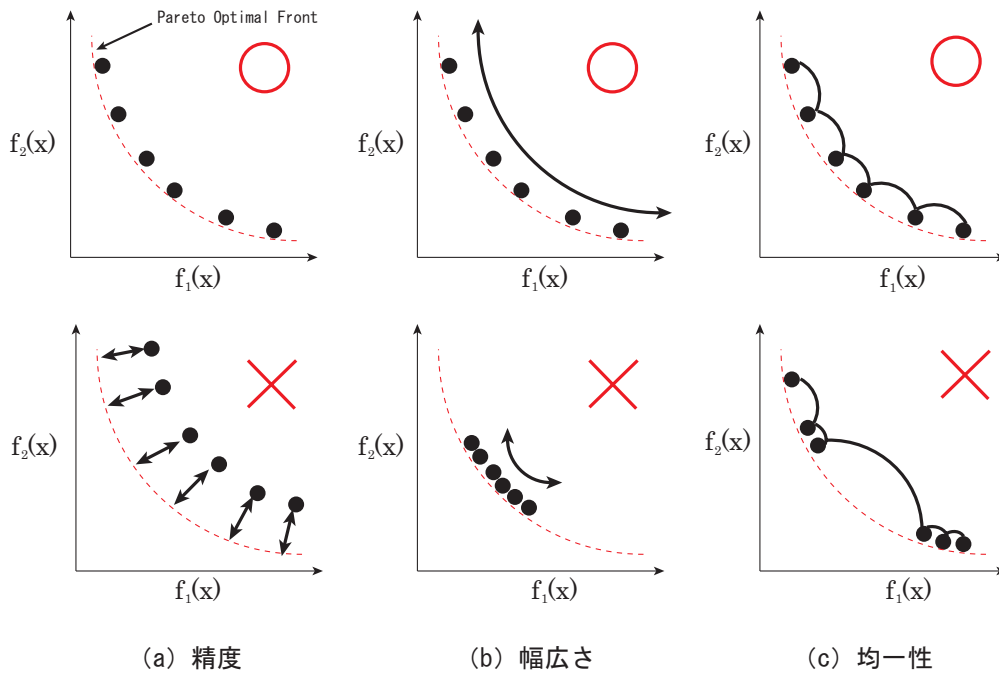


Fig. 2.2 多目的最適化の目標

2.3 多目的遺伝的アルゴリズム

多目的最適化の分野では、様々な進化的アルゴリズムが適用されているが、特に遺伝的アルゴリズム (Genetic Algorithm: GA) を多目的最適化に適用した多目的遺伝的アルゴリズム (多目的 GA) は最も多く研究されている⁶⁾。多目的 GA は多点探索であることから、一度の探索でパレート解集合を求めることができる。Fig. 2.3 に多目的 GA の探索の様子を示す。

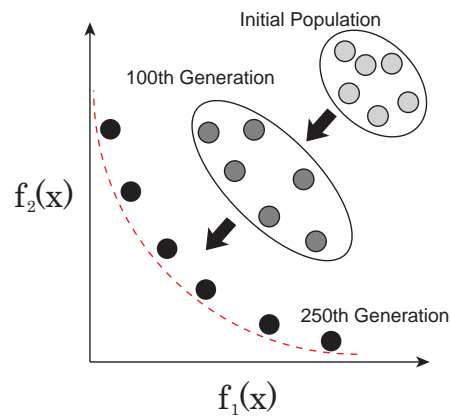


Fig. 2.3 多目的 GA の探索

GA を多目的最適化問題に適用する場合、非劣解集合を適切に評価し、次世代に残していくことが重要となる。多目的最適化では、単一目的最適化において「1つの最適解」を求める場合とは異なり、パレート最適解が全て解候補となるため、単純に単一目的における適合度の割り当てをそのまま適用させることはできない。そこで、多目的 GA の適合度の割り当て方法には以下の2つが挙げられる。

- (1) 解の優越関係を用いずに適合度を割り当てる (非パレートのアプローチ)
- (2) 解の優越関係に基づいて適合度を割り当てる (パレートのアプローチ)

近年提案された多目的 GA 手法の多くは、解の優越関係に基づいて適合度値を割り当てる、パレートのアプローチに分類される。その中でも、Deb らの NSGA-II⁴⁾ と Zitzler らの SPEA2⁵⁾ は、適合度値の高い個体の保存、多様性に優れた個体の選択など、多目的 GA における重要なメカニズムが組み込まれており、優れた探索性能を有していることが報告されている。

2.4 NSGA-II

NSGA-II (Elitist Non-Dominated Sorting Genetic Algorithm) は、Deb, Agrawal らによって 2000 年に提案された、NSGA の改良アルゴリズムである⁴⁾。NSGA-II の主な特徴として、以下に示すものが挙げられる。

- 非優越ソート (Non-Dominated Sort) によるランキング方法。
- 混雑距離 (Crowding Distance) の導入。
- 混雑度トーナメント選択 (Crowded Tournament Selection) の導入。

以下、NSGA-II のアルゴリズムと上記に挙げた特徴について説明する。

2.4.1 NSGA-II のアルゴリズム

NSGA-II では、保存する母集団（アーカイブ母集団） P_t と交叉・突然変異といった遺伝的操作を用いた探索を行うための母集団 Q_t の 2 つの独立した母集団を用いて解探索を進めていく。NSGA-II では、非劣個体を保存する母集団 P_t を親母集団として、探索を行うための母集団 Q_t を子母集団として用いることにより解探索を行っている。具体的には、個体数 N とした場合、まず世代 t における親母集団 P_t から探索を行うための子母集団 Q_t を選択する。そして、 Q_t に対して各遺伝的操作を行い Q_t を更新する。次に、 Q_t と親母集団 P_t を組み合わせた $R_t = P_t \cup Q_t$ を生成し、アーカイブ更新操作によって個体数 $2N$ の R_t から個体数 N の P_{t+1} を新たに選択し探索を進めていく。

以下、NSGA-II のアルゴリズムの流れを示す。

Step 1 $t = 0$ とする。探索母集団 Q_t を初期化し、アーカイブ母集団 P_t を空にする。

Step 2 探索母集団 Q_t の評価を行う。

Step 3 アーカイブ集団と探索母集団を組み合わせて $R_t = P_t \cup Q_t$ を生成する。 R_t に対して非優越ソートを行い、全個体をフロント毎（ランク毎）に分類する： $F_i, i = 1, 2, \dots, etc.$

Step 4 新たなアーカイブ母集団 $P_{t+1} = \phi$ を生成。変数 $i = 1$ とする。

$|P_{t+1}| + |F_i| < N$ を満たすまで、 $P_{t+1} = P_{t+1} \cup F_i$ と $i = i + 1$ を実行。

Step 5 混雑度ソート (Crowding-sort) を実行し、 F_i の中で最も多様性に優れた（混雑距離の大きい）個体 $N - |P_{t+1}|$ 個を P_{t+1} に加える。

Step 6 終了条件を満たしていれば、終了する。

Step 7 P_{t+1} を基に、混雑度トーナメント選択により新たな探索母集団 Q_{t+1} を生成する。

Step 8 Q_{t+1} に対して遺伝的操作（交叉、突然変異）を行う。 $t = t + 1$ をとし、Step 2 に戻る。

このように NSGA-II では、アーカイブ母集団 P_t と探索母集団 Q_t を組み合わせた母集団 R_t の上位 N 個体を選択し、次世代のアーカイブ母集団 P_{t+1} としている。また、探索母集団 Q_t は、アーカイブ母集団 P_t から混雑度トーナメント選択を用いて選択されており、アーカイブ母集団 P_t のより優れた個体に対して各遺伝的操作を用いることで探索が行われている。常に優良個体を保存するアーカイブ母集団 P_t と探索を行う探索母集団 Q_t を分けて保持することにより、それまでの探索で発見した優れた解が欠落するのを防いでいる。NSGA-II のアーカイブ母集団 P_t の更新の概念図を Fig. 2.4 に示す。

2.4.2 非優越ソートによるランキング方法

NSGA-II では非優越ソート (Non-Dominated Sort) と呼ばれる個体のランク付け（適合度割り当て）方法を用いている。非優越ソートに基づくランキングの手続きを以下に示す。

Step 1 ランク $r = 1$ とする。

Step 2 個体群 P の中から非劣個体を求め、これらの個体をランク r とする。

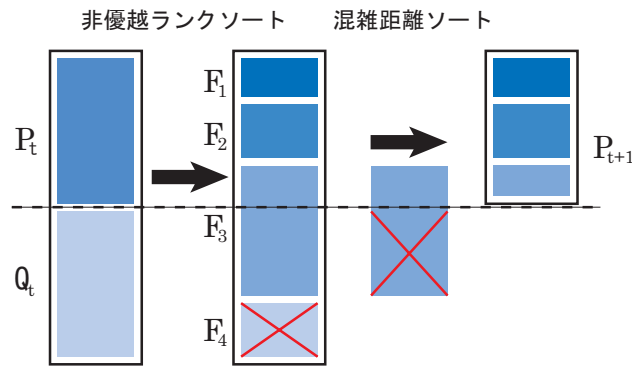


Fig. 2.4 NSGA-II のアーカイブ更新

Step 3 得られた非劣個体群を個体群 P から除き, $r = r + 1$ とする.

Step 4 全ての個体がランク付けされるまで (個体群 P が空になるまで), Step 2 および Step 3 を繰り返す.

最小化問題における非優越ソートによる個体のランク付けの例を Fig. 2.5 に示す.




Fig. 2.5 非優越ソートによるランキング

2.4.3 混雑距離

混雑距離 (Crowding Distance) とは, ある個体 i の周りにある個体の密度を評価するための手法である. 混雑距離は, 同一ランク同士 (同一フロント内) で用いられ, 各目的関数軸において隣り合う個体間の距離を足し合わせたものである. 混雑距離の概念図を Fig. 2.6 に示す.

以下に混雑度距離を計算するためのアルゴリズムを示す.

Step 1 フロント F に含まれる個体数を変数 l に代入する: $l = |F|$. また, このフロントに含まれる各個体 i に対して初期値設定を行う: $d_i = 0$.

Step 2 各目的関数 $m = 1, 2, \dots, M$ に対して, 目的関数値が悪い順に個体をソートする: $I^m = \text{sort}(f_m, >)$.




Fig. 2.6 混雑距離

Step 3 各目的関数 $m = 1, 2, \dots, M$ に対して, まず境界個体 (目的 m の最大値と最小値の個体) に対して最大距離, もしくは無限距離を与える: $d_{I_1^m} = d_{I_l^m} = \infty$. なお, I_j^m は m 番目の目的においてソートした個体の j 番目の個体を意味する. さらに境界個体以外の全ての個体 ($j = 2, \dots, l-1$) に対して以下の式に従った混雑度計算を行う.

$$d_j = \sum_{m=1}^M \frac{f_m^{I_{j+1}^m} - f_m^{I_{j-1}^m}}{f_m^{\max} - f_m^{\min}} \quad j \in [2, l-1] \quad (2.2)$$

2.4.4 混雑度トーナメント選択

混雑度トーナメント選択 (Crowded Tournament Selection) は, 各ランク r により形成されるフロント F_r が一様に分布するように選択を行い, トーナメントサイズ 2 のトーナメント選択に基づいた方法である. この選択方法では, 全ての解 i に対して次の 2 つの属性を持たせ, それらを選択基準として選択している.

- 母集団における非優越ランク (i_{rank})
- 母集団内の局所的混雑距離 (i_{distance})

混雑度トーナメント選択では, i と j の 2 個体の優越関係として以下のいずれかの条件を満たす場合に, “ i は j よりも優れている” と定義している.

- 個体 i のランクの方が個体 j のランクよりも優れている: ($i_{\text{rank}} < j_{\text{rank}}$).
- 個体 i と j はともに同じランクであり, i の混雑距離が j よりも優れている: ($i_{\text{rank}} = j_{\text{rank}}$) and ($i_{\text{distance}} > j_{\text{distance}}$)

2.5 多目的遺伝的アルゴリズムにおける問題点

一般的な多目的 GA 手法では, 非劣解集合の精度や均一性を向上させるようなメカニズムが組み込まれている. 2.4 節で述べた NSGA-II の場合, 非優越ソートによって適切な適合度を非劣解に割り当てることによって, 得られるパレート解集合の精度を向上させている. また, 混雑距離を用いたアー

カイク個体の選択によって、密集した個体を優先的に削減し、解集合の多様性を維持している。このように NSGA-II では、精度と均一性を高めるようなメカニズムが含まれており、良好な解探索を行えることが知られている。同様に、SPEA2⁵⁾ など、その他の代表的な多目的 GA 手法においても同様なメカニズムが存在する。

しかし、多くの多目的 GA 手法では、幅広さを向上させるための明確なメカニズムが考慮されていないことが多い。NSGA-II においても、得られた解集合の幅広さを維持するためのメカニズムしか持たない。解集合が十分な幅広さを持たない場合、意思決定者が最終的な解を選択する際に問題が生じる。意思決定者にとって、その問題における解集合がどのように分布するかを把握することは重要であり、パレートフロントの一部分のみに解集合を導出することは十分ではない。そこで、本論文では解集合の精度と幅広さに注目した、多目的 GA のための探索手法を提案する。

ここで、パレート解集合の幅広さについて重要になるのは、パレート解集合に含まれる解のうち、各目的における最適解である。各目的における最適解はパレートフロントの端に位置し、これらの解を精度良く求めることによって、パレート解集合の幅広さを向上させることができる。そのため、多目的 GA の幅広さにおける性能を向上させるにあたり、各目的関数を最適化する単一目的 GA の利用が有効であると考えられる。

3 精度と幅広さの向上を考慮した 2 段階プロセス多目的 GA

3.1 2 段階プロセス多目的 GA の設計指針

解集合の幅広さに注目した手法として、奥田らの分散協力型スキーム (DC-Scheme: Distributed Cooperation scheme for Multi-Objective Optimization)⁷⁾ が提案されている。DC-Scheme は多目的 GA と単一目的 GA を組み合わせ、それらが協調して探索を行う枠組みであり、解集合の幅広さを向上させることができるが、その一方で探索の精度が低下するという結果が得られている。DC-Scheme の例のように、解集合の幅広さを向上させることによって探索の精度が低下するため、精度と幅広さを同時に向上させることは困難であるとされてきた。

そこで、本論文では探索のプロセスを精度の向上と幅広さの向上の 2 つに分割し、この 2 つのプロセスを適切に切り替えることにより、効率的な探索を実現する 2 段階プロセス多目的 GA (DPMOGA: Dual Procedures Multi-Objective Genetic Algorithm) を提案する。DPMOGA において、探索のプロセスを 2 段階に分割し、1 段階目ではパレートフロントに到達することを、2 段階目ではパレートフロントに被覆することを目的とする。探索の概念図を Fig. 3.1 に示す。意思決定者 (DM: Decision Maker)¹⁰⁾ によって設定された希求点と島モデル型 GA (DGA: Distributed Genetic Algorithm)¹¹⁾ を 1 段階目の探索に適用することで、できる限り精度の高いパレートフロントに到達することを実現する。また、改良した DC-Scheme を 2 段階目の探索に用いることで、各目的における最適解を探索しつつ、解集合の幅広さを向上させる。

探索の順序がこのように設定されているのは、探索の序盤から解集合の幅広さを向上させると、探索の収束性が低下し、最終的な解集合の精度が劣ってしまうからである。そのため、提案手法では解集合の精度をまず確保し、その後に幅広さの向上を目指す。DPMOGA のメインループ処理を以下に




Fig. 3.1 Concept of the Reference Point-based Search

示す．

- Step 1 保存用アーカイブを初期化する．
- Step 2 1段階目のパレートフロント到達を重視した探索を行う．
- Step 3 探索が収束しているかを判定し，条件を満たせば Step 4 へ．満たさなければ Step 2 へ．
- Step 4 2段階目のパレートフロント被覆を重視した探索を行う．
- Step 5 終了条件を満たせば終了．そうでなければ Step 4 に戻る．

以降，探索戦略の各処理について述べる．

3.2 1段階目：精度の向上を重視した探索

1段階目のパレートフロント到達を重視した探索 (Step 2) では，DM の選好情報を希求点として利用する．この希求点は目的関数空間に設定され，実行可能領域内もしくは実行可能領域外のどちらにも位置することができる．この探索の概念図を Fig. 3.2(a) に示す．Fig. 3.2(b) に示す一般的な多目的 GA 手法では解の優越関係によって探索が進行するのに対し，DPMOGA では優越関係と希求点からの距離情報を用いて探索を進める．したがって，希求点により近い解を優先的に探索で用いることにより，高い収束性が期待できる．

しかし，希求点を用いることで高い収束性を有するが，解集合を希求点周辺の領域に収束させることで多様性が失われ，局所パレート解に陥る可能性が高い．そこで，多様性を維持するため，DGA を多目的 GA に適用する．DPMOGA における1段階目のアルゴリズムを下記に示す．ここでは，母集団サイズを N とし，DGA の各島サイズは k とする．

- Step 2-1 ランダムに N 個体を初期化する．
- Step 2-2 母集団を k 個の子個体群に分割する．このとき各子個体群の個体数は $\frac{N}{k}$ とする．
- Step 2-3 各子個体群で探索を行う．
- Step 2-4 全個体群から個体を収集し，全体のアーカイブを更新する．
- Step 2-5 一定世代毎に最良解を各島間で移住する．
- Step 2-6 終了条件を満たせば終了する．そうでなければ Step 2-3 に戻る．

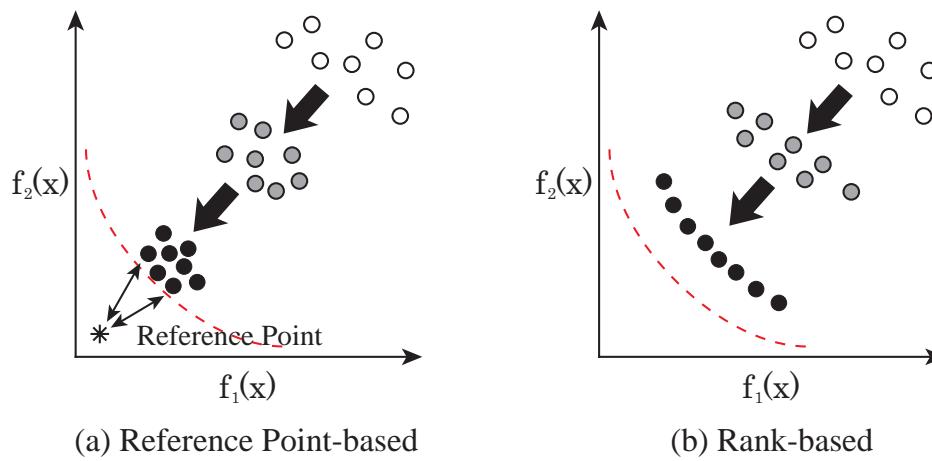


Fig. 3.2 Concept of the Reference Point-based Search

Step 2-3 における各子個体群の世代交代モデルの概念図を Fig. 3.3 に示し，アルゴリズムを以下に示す．

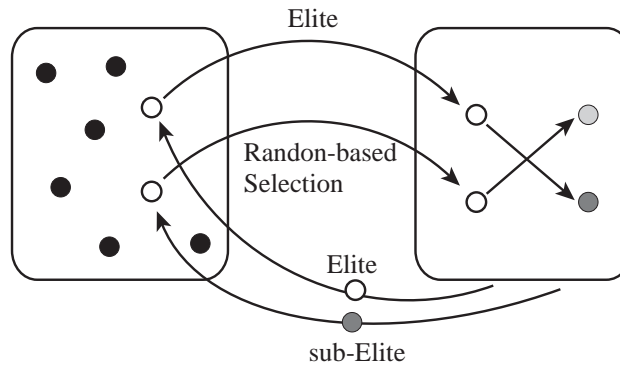


Fig. 3.3 Concept of the Generation Alternation Model

- Step 2-3-1 個体群に対して非優越ソートを実行し，昇順にソートする．Rank=1 の個体が複数存在する場合は，それらの個体に対して希求点からのユークリッド距離によって昇順にソートする．
- Step 2-3-2 上位 1 個体と，この個体を除いた個体群からランダムによって抽出した個体を交叉で用いる親個体とする．
- Step 2-3-3 交叉，突然変異を行う．
- Step 2-3-4 生成した子個体と親個体を会わせた家族内で非優越ソートを実行し，昇順にソートする．Rank=1 の個体が 2 つ以上存在する場合は，それらの個体に対して希求点からのユークリッド距離によって昇順にソートする．
- Step 2-3-5 家族内の上位 2 個体を親個体と入れ替え，個体群に戻す．

Step2-3-2 において個体群内の評価値の最良個体とランダムにより選出した個体を交叉することで収束性と多様性のバランスが取れた探索が期待できる．また，Step2-3-5 において 1 世代における個体群の入れ替えを家族内に限定することにより個体群の急激な変化を防いでいる．このように，希求

点と島モデルを併用することにより、解集合の多様性を維持しながらも非劣解の中で希求点に近い解が優先的に選択されるため、希求点周辺に個体群を収束させることが可能である。

3.3 2段階目：幅広さの向上を重視した探索

2段階目のパレートフロント被覆を重視した探索 (Step 4) には奥田らの提案した DC-Scheme を改良して用いる。DC-Scheme において、探索母集団は単一目的 GA で探索するサブ母集団と多目的 GA で探索するサブ母集団に分割される。これ以降、単一目的 GA および多目的 GA で探索するサブ母集団を、それぞれ SOGA 個体群および MOGA 個体群と呼ぶ。

k 目的最適化問題の場合、探索母集団は1つの MOGA 個体群と k 個の SOGA 個体群に分割され、合計で $k + 1$ 個のサブ母集団が形成される。DC-Scheme の概念図を Fig. 3.4 に示す。

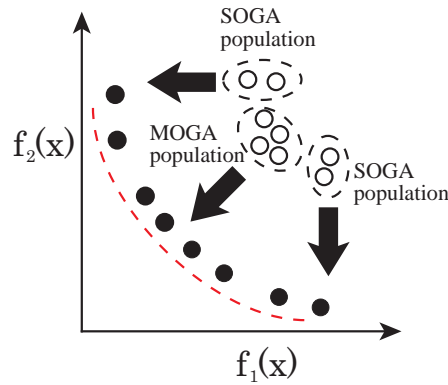


Fig. 3.4 Concept of the Distributed Cooperation Scheme

DC-Scheme において SOGA 個体群はそれぞれの目的における最良解を導出する役割を分担し、MOGA 個体群はそれらの最良解間のパレートフロントを被覆する役割を分担する。そこで、各目的における最良解を導出しながらパレートフロントを被覆するより、最良解を導出した後にパレートフロントを被覆する方が少ない評価回数で同等のパレートフロントを導出できると考えられる。改良を加えた DC-Scheme の概念図を Fig. 3.5 に示す。

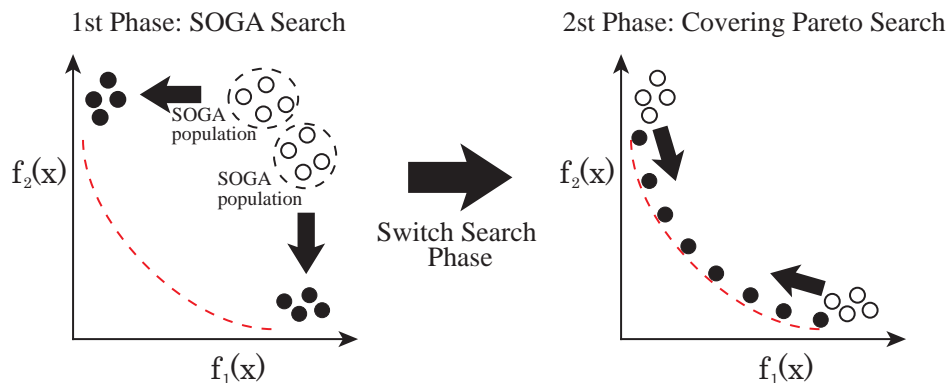


Fig. 3.5 Concept of the 2nd Search Procedures of DPMOGA

探索終盤にパレートフロントを被覆することで、より多くの探索コストを各目的の最良解の導出に費やすことができ、かつより幅広いパレートフロントの導出が期待できる。アルゴリズムを下記に示

す．ここでは，母集団サイズを N とし， M 目的最適化問題を想定する．

- Step 4-1 母集団を M 個 SOGA 個体群に分割する．このとき，SOGA 個体群の個体数は $\frac{N}{M}$ とする．
- Step 4-2 各個体群で各目的における最適解を探索する．
- Step 4-3 全個体群から個体を収集し，全体のアーカイブを更新する．
- Step 4-4 探索が停滞しているかを判定し，条件を満たせば Step 4-5 へ．満たさなければ Step 4-2 へ．
- Step 4-5 最良解間のパレートフロントを被覆するように探索する．
- Step 4-5-1 母集団内非優越解集合に対して混雑度ソート (Crowding-sort) を実行し，交叉のための第 1 親 P_1 を混雑度に基づくルーレット選択によって選択する．
- Step 4-5-2 交叉のための第 2 親 P_2 を P_1 の k -nearest neighbors (k -NN) からランダムに抽出する．
- Step 4-5-3 交叉，突然変異を行う．
- Step 4-6 全個体を収集し，全体のアーカイブを更新する．
- Step 4-7 終了条件を満たせば終了し，そうでなければ Step 4-5 に戻る．

Step 4-5-1 において交叉のための第 1 の親を，個体群において $R_{nak}=1$ の個体の中から，混雑距離に比例する確率にしたがって選択する．これにより，目的関数空間において個体分布の密度が低い領域に位置する個体ほど親として選択されやすくなるため，パレートフロントを均等に被覆する個体の生成確率を高めることができると考えられる．また，Step 4-5-2 において交叉のための第 2 の親を，上記の第 1 親の k -nearest neighbors (k -NN) からランダムに選択する．ここで，個体 P の k -NN とは，個体 P 自身を除く現個体群の中から個体 P との設計変数のユークリッド距離が k 番目に近い個体までを選び出した個体群のことという．このように近傍の個体同士で交叉を行うことにより，非線形パレート解集合にも沿った子個体を生成できると考えられる．

3.4 探索の切り替え (Step 3, Step 4-4)

提案する探索戦略では，まず 3.2 項で述べた精度を重視した探索を行い，その後に 3.3 項で述べた幅広さを重視した探索を行う．また，幅広さを重視した探索においては，各目的における最良解を導出した後，パレートフロントを被覆するように探索を行う．

これらの探索において，どのようなタイミングで切り替えるかは重要と考えられる．単純な切り換え方法として，あらかじめ定められた世代数に達した時点で探索を切り替えることが考えられるが，そのような方法ではパラメータの設定が難しい．そこで，上記 2 つの探索切り替えタイミングは共に，探索が十分に収束した時であることが望ましい．ここでは，以下に示す 2 通りの場合に探索が十分に収束したと判断する．

- パレート最適フロントへの収束が停滞している．
- 新たに生成された非劣解がパレート最適フロントへの収束に貢献していない．

したがって、本研究では探索の収束具合を表す 2 つの指標を用いて探索を切り替える。1 つ目の指標には Jaimes らの MRMOGA¹²⁾ で用いられている指標を利用する。この指標では、探索中におけるアーカイブ内の非劣解がどの程度の割合で次世代の解によって優越されるかを世代ごとに計測し、一定世代数におけるその平均値をとることで収束しているかを判断する。具体的には、世代 i におけるアーカイブ内の非劣解を $PF_{known}(i)$ とし、 $PF_{known}(i)$ に含まれる解のうち次世代の解によって優越される割合を $dominated_i$ とする。世代毎に $dominated_i$ を求め、 g 世代にわたる平均値を算出し、その値が次の式 (3.1) に示す条件を満たした場合に十分に収束したと考える。Fig. 3.6 にこの指標の概念図を示す。

$$\sum_{i=1}^g \frac{dominated_i}{g} \leq \epsilon \quad (3.1)$$

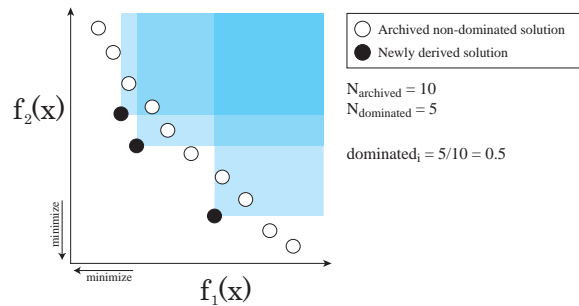


Fig. 3.6 Concept of MRMOGA Dominance Ratio

なお、Jaimes らは式 (3.1) における ϵ について、 $\epsilon = 0.05$ としている。提案する探索戦略では 2 目的最適化問題の場合 $\epsilon = 0.05$ とし、3 目的最適化問題では $\epsilon = 0.025$ とする。これは、目的数の増加とともに解を優越することが困難となるためである。また、 g の値については、3.3 項における移住間隔と同じ 25 世代とする。この指標では、アーカイブ内の非劣解集合が一定の割合で次世代の解に優越される場合、探索はパレート最適フロントに対して進行していると判断する。しかし、実際にどのような解が新たに生成されているのかについては考慮されていない。そのため、2 つ目の指標ではどのような解集合が生成されているのかを把握することを考える。

2 つ目の指標では、アーカイブ内の新たに生成された非劣解が優越する非劣解の数の平均値を扱う。つまり、新たに生成された 1 つの非劣解が、どれだけ解を優越するかを表す。この指標を用いることにより、MRMOGA の指標では考慮されていない新たな非劣解の数を考慮することができる。例えば、優越する解の数が平均で 1 の場合、生成された非劣解はそれぞれアーカイブ内の非劣解を 1 つ優越すると考えられる。1 つの解が多くの解を優越する場合、その解はパレート最適フロントへと探索を収束させる上で効果的な解であるといえる。したがって、この指標は生成された解がどれだけ効果的であるかを示す。平均的に優越する解の数が低い場合、探索は多様性の向上へと移行していると考えられ、十分に収束していると判断できる。Fig. 3.7 にこの指標の概念図を示す。

探索戦略では、 g 世代ごとに指標値の平均をとり、式 (3.2) に示す条件を満たした場合に十分に収束したと考える。このとき、 μ_i は i 世代目における新たに生成された非劣解が優越するアーカイブ内の非劣解の数の平均値である。また、1 つ目の指標と同様に $g = 25$ とする。




Fig. 3.7 Concept of the Effectiveness Indicator

$$\sum_{i=1}^g \frac{\mu_i}{g} \leq \alpha \quad (3.2)$$

本研究では、2目的最適化問題の場合に $\alpha = 0.5$ とし、3目的最適化問題の場合に $\alpha = 0.25$ とした。これらの値は予備実験を行い、良好な結果を示したものである。以上に述べた2つの指標を用いて、式(3.1)と式(3.2)のうちいずれかの条件が満たされた場合に探索戦略の2段階の探索を切り替える。

4 数値実験

4.1 実験概要

提案手法である DPMOGA の有効性を検証するために数値実験を行い、一般的な多目的 GA 手法および DC-Scheme を用いた手法と比較する。なお、比較する多目的 GA 手法は NSGA-II⁴⁾ を用い、DC-Scheme を用いた手法は西岡らが提案した手法¹³⁾ を用いる。

対象問題は、2目的最小化問題の ZDT テストスイート¹⁴⁾、DTLZ3¹⁵⁾、KUR¹⁶⁾ と最大化問題の多目的ナップサック問題³⁾ である。

ZDT テストスイートは、パレート最適フロントの形状がそれぞれ凸型、非凸型の ZDT1 と ZDT2、不連続パレート最適フロントを持つ ZDT3、多峰性関数の ZDT4、および設計変数空間にバイアスを持つ ZDT6 によって構成されている。DTLZ3 は多峰性の問題であり、パレート最適フロントの形状は凸型である。KUR は2目的の連続最適化問題であり、 $f_1(x)$ において連続する2変数間の相互作用を持ち、 $f_2(x)$ において多峰性を有する問題である。多目的ナップサック問題としては KP500-2 (i.e., 2目的, 500 アイテム) と KP750-2 を用いる。各テスト問題の定式を Table 4.1 に示す。

KP500-2 および KP750-2 における $p_{(i,j)}$ は、 i 番目のナップサックの評価値を計算する際の j 番目の荷物に付随する利益値を示す。同様に、 $w_{(i,j)}$ は重み値を表している。また、 W_i は i 番目のナップサックにおける重み値の制約値 (上限値) である。なお、多目的ナップサック問題における引き戻し手法としてラマルク型修復¹⁷⁾ を用い、削除するアイテムはランダムに決めるものとする。

4.2 評価手法

得られたパレート解集合の評価手法として、本研究では Inverted Generational Distance (IGD)¹⁸⁾、Spread¹⁹⁾、HyperVolume²⁰⁾ を用いる。それぞれの評価手法について以下に述べる。

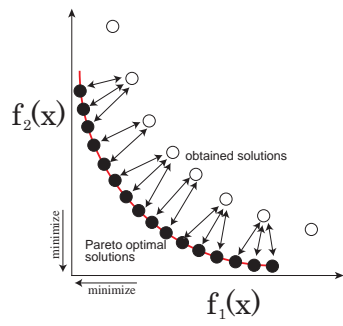
Table 4.1 テスト問題の定式

Problem	Definition	Variable
ZDT1	$\min f_1(x) = x_1$ $\min f_2(x) = g \cdot h$ $g = 1 + 9(\sum_{i=2}^n x_i)/(n-1)$ $h = 1 - \sqrt{f_1/g}$	$x_i \in [0, 1]$ $i = 1, \dots, n \quad n = 10$
ZDT2	as ZDT1, except $h = 1 - (f_1/g)^2$	$x_i \in [0, 1] \quad i = 1, \dots, n \quad n = 10$
ZDT3	as ZDT1, except $h = 1 - \sqrt{f_1/g} - (f_1/g)\sin(10\pi f_1)$	$x_i \in [0, 1] \quad i = 1, \dots, n \quad n = 10$
ZDT4	as ZDT1, except $g = 1 + 10(n-1) +$ $(\sum_{i=2}^n (x_i^2 - 10\cos(4\pi x_i)))$	$x_1 \in [0, 1] \quad x_i \in [-5, 5]$ $i = 2, \dots, n \quad n = 10$
ZDT6	$\min f_1(x) = 1 - \exp(-4y_1)\sin^6(6\pi y_1)$ $\min f_2(x) = g \cdot h$ $g = 1 + 9((\sum_{i=2}^n x_i)/(n-1))^{0.25}$ $h = 1 - (f_1/g)^2$	$x_i \in [0, 1]$ $i = 1, \dots, n \quad n = 10$
DTLZ3	$\min f_1(x) = (1+g)\prod_{i=1}^{M-1} \cos(x_i\pi/2)$ $\min f_{m=2:M-1}(x) = (1+g)(\prod_{i=1}^{M-m} \cos(x_i\pi/2))$ $\sin(x_{M-m+1}\pi/2)$ $\min f_M = (1+g)\sin(x_1\pi/2)$ $g = 100[(n-M+1) + \sum_{i=M}^n ((x_i - 0.5)^2 - \cos(20\pi(x_i - 0.5)))]$	$x_i \in [0, 1]$ $i = 1, \dots, n \quad n = 10$
KUR	$\min f_1(\mathbf{x}) = \sum_{i=1}^{N-1} \left(-10 \exp \left(-0.2 \sqrt{x_i^2 + x_{i+1}^2} \right) \right)$ $\min f_2(\mathbf{x}) = \sum_{i=1}^N \left(x_i ^{0.8} + 5 \sin(x_i)^3 \right)$	$x_i \in [-5, 5]$ $i = 1, \dots, n \quad n = 100$
KP500-2 KP750-2	$\max f_i(\mathbf{x}) = \sum_{j=1}^N x_j \times p_{(i,j)}$	$g_i(\mathbf{x}) = \sum_{j=1}^N x_j \times w_{(i,j)} \leq W_i$ $1 \leq i \leq k$

4.2.1 評価手法1 : Inverted Generational Distance (IGD)

IGDは得られたパレートフロントが、どの程度パレート最適フロントに類似しているかを表す。IGDはパレート最適フロントの各解に対して、得られたパレートフロントの中で最も近い解までの距離の平均によって得られる。この評価手法は解集合の精度と多様性を評価することができる。IGDの概念図をFig. 4.1に、計算式を式(4.1)に示す。式(4.1)において、 N はパレート最適フロントに含まれる解の数である。また、 d_i はパレート最適フロントに含まれる解 i とパレートフロントの中で1番近い解との目的関数空間におけるユークリッド距離である。

IGDを求めるためにはパレート最適フロントが既知である必要があるが、本実験に用いたKUR, KP750-2についてはパレート最適フロントは未知である。したがって、あらかじめ多目的GA手法を実験よりも多くの評価回数探索することによって求められた擬似パレート最適フロントを評価に用いる。

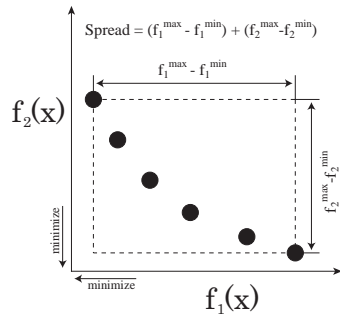


$$IGD = \frac{1}{N} \sum_{i=1}^N d_i \quad (4.1)$$

Fig. 4.1 Concept of IGD

4.2.2 評価手法 2 : Spread

Spread はパレート解集合の幅広さを表し、得られた解集合の各目的に対する最大値と最小値を足し合わせることによって得られる。この値が大きいほど幅広い解集合であると判断できる。Spread の概念図を Fig. 4.2 に、計算式を式 (4.2) に示す。式 (4.2) において、 M は目的関数の数である。




$$Spread = \sum_{i=1}^M [\max f_i(x) - \min f_i(x)] \quad (4.2)$$

Fig. 4.2 Concept of Spread

4.2.3 評価手法 3 : HyperVolume

HyperVolume はパレート解集合が支配している空間を表す手法であり、解集合の総合的な評価を表す。HyperVolume 値が大きいほどより多くの空間を支配しており、優れた解集合であることを意味する。HyperVolume の概念図を Fig. 4.3 に、計算式を式 (4.3) に示す。式 (4.3) において、 n_{PF} はパレートフロントに含まれる解の数である。各個体 i について参照点 W を用いて Hypercube v_i を生成し、これらの和集合が HyperVolume 値である。なお、各テスト問題に対して設定した参照点 W を Table 4.2 に示す。



$$HyperVolume = volume(\cup_{i=1}^{n_{PF}} v_i) \quad (4.3)$$

Fig. 4.3 Concept of HyperVolume

Table 4.2 Reference Point of HyperVolume

ZDT1,2,3,6	ZDT4	DTLZ3	KUR	KP500-2	KP750-2
(1, 1)	(1, 10)	(20, 20)	(-600, 100)	(21000, 21000)	(30000, 30000)

4.3 実験パラメータ

全ての手法において共通する GA パラメータを Table 4.3 に示す . Table 4.3 において , 最大世代数は ZDT テストスイートと DTLZ3 は 500 とし , KUR と多目的ナップサック問題は 1000 とする . また , DC-Scheme を用いる手法および DPMOGA で利用する DGA のパラメータを Table 4.4 に示し , 各テスト問題に対して設定した希求点を Table 4.5 に示す .

Table 4.3 GA parameters

母集団サイズ	120
最大世代数	500 , 1000
交叉手法	2 点交叉
交叉率	1.0
突然変異手法	ビット反転
突然変異率	1/染色体長

Table 4.4 DGA parameters

サブ母集団サイズ	10
エリート数	1
選択手法	トーナメント選択
トーナメントサイズ	4
移住トポロジ	ランダムリング
移住率	0.5
移住間隔	5 世代

Table 4.5 Reference Point

ZDT1,2,4,6	ZDT3	DTLZ3	KUR	KP500-2	KP750-2
(0, 0)	(0, -1)	(0, 0)	(-1000, -400)	(21000, 21000)	(30000, 30000)

4.4 実験結果

各手法によって 30 試行で得られた , IGD , Spread , HyperVolume の平均値と標準偏差を Table 4.6 ~ Table 4.8 にそれぞれ示す . Table 4.6 に示した IGD は , 値が 0 に近いほど得られた解集合がパレート最適フロントに近いことを表す . Table 4.7 と Table 4.8 の Spread と HyperVolume については , 値が大きいほど良い . また , Table 4.6 ~ Table 4.8 において太字で示す値は各手法において最も良い値である . なお , Table 4.7 において導出されたパレート解集合の Spread 値が最大となるものも太字を用いる .

Table 4.6 に示した IGD の平均値から , 提案手法の DPMOGA は DC-Scheme と NSGA-II に比べて , すべてのテスト問題において同等もしくは優れた性能を示していることがわかる . テスト問題の ZDT3 と ZDT6 の値が 0 となっていることから , DPMOGA は不連続パレート最適フロントを持つ問題や , 設計変数空間にバイアスを持つ問題にも有効といえる . Table 4.6 の結果から , 提案手法の DPMOGA は最もパレート最適フロントに近い解集合を得ることができるといえる .

Table 4.6 Inverted Generational Distance

	DPMOGA		DC-Scheme		NSGA-II	
	mean	S.D.	mean	S.D.	mean	S.D.
ZDT1	0.00	0.00	0.00	0.00	0.00	0.00
ZDT2	0.00	0.00	0.00	0.00	0.00	0.00
ZDT3	0.00	0.00	0.00	0.00	0.00	0.00
ZDT4	0.49	0.22	1.61	0.87	1.90	0.92
ZDT6	0.00	0.00	0.00	0.00	0.00	0.00
DTLZ3	1.60	1.17	4.90	3.90	6.90	3.34
KUR	3.95	1.43	20.32	5.93	56.28	5.21
KP500-2	137.85	16.19	195.46	35.38	772.77	58.41
KP750-2	330.05	37.87	471.14	44.29	1528.95	76.10

Table 4.7 Spread

	DPMOGA		DC-Scheme		NSGA-II	
	mean	S.D.	mean	S.D.	mean	S.D.
ZDT1	2.00	0.00	2.00	0.00	2.00	0.00
ZDT2	2.00	0.00	2.00	0.00	2.00	0.00
ZDT3	2.43	0.00	2.43	0.00	2.43	0.00
ZDT4	2.39	0.14	2.93	0.35	3.03	0.30
ZDT6	1.64	0.00	1.64	0.00	1.64	0.00
DTLZ3	5.20	2.35	11.80	7.80	15.80	6.70
KUR	695.43	9.17	682.04	15.30	321.20	23.06
KP500-2	5.62E+03	190.36	4.97E+03	402.33	1.71E+03	224.62
KP750-2	8.55E+03	233.52	7.27E+03	344.26	2.16E+03	257.57

Table 4.8 HyperVolume

	DPMOGA		DC-Scheme		NSGA-II	
	mean	S.D.	mean	S.D.	mean	S.D.
ZDT1	0.66	0.00	0.66	0.00	0.66	0.00
ZDT2	0.33	0.00	0.33	0.00	0.33	0.00
ZDT3	0.69	0.00	0.69	0.00	0.69	0.00
ZDT4	8.97	0.30	7.52	1.07	7.14	1.08
ZDT6	0.32	0.00	0.32	0.00	0.32	0.00
DTLZ3	393.69	4.40	361.76	51.94	342.82	44.46
KUR	1.30E+05	1.23E+03	1.18E+05	3.93E+03	0.90E+05	3.16E+03
KP500-2	8.95E+06	2.09E+05	8.54E+06	3.96E+05	5.50E+06	2.60E+05
KP750-2	1.09E+07	1.92E+05	1.03E+07	2.55E+05	0.64E+07	2.70E+05

Table 4.7 に示した Spread の平均値から、提案手法の DPMOGA は ZDT テストスイーツや DTLZ3 といったパレート最適フロントが既知な問題においては幅広さが最大となるパレート解集合を導出していることがわかる。また、KUR や多目的ナップサックといったパレート最適フロントが未知な問題においても最も幅広い解集合を導出していることがわかる。したがって、1 段階目の探索によって解集合を収束させた後に、2 段階目の探索によって幅広さを向上させることが可能であるといえる。提案手法の DPMOGA は DC-Scheme に比べてより幅広い解集合を導出できることから、2 段階目の探索において探索終盤にパレートフロントを被覆することで、より多くの探索コストを各目的の最良解の導出に費やすことができ、かつより幅広いパレートフロントの導出が可能であるといえる。Table 4.7 の結果から、提案手法の DPMOGA の方が幅広い解集合を導出していることを表している。

Table 4.8 の HyperVolume の値についても、提案手法の DPMOGA はすべてのテスト問題において最も良好な性能を示していることがわかる。また、IGD, Spread および HyperVolume すべての評価指標における標準偏差についても、DPMOGA はすべてのテスト問題において最も小さい値を示していることから、性能のばらつきが小さいことがわかる。これらの結果から、提案手法の DPMOGA は DC-Scheme や一般的な多目的 GA 手法より高精度尚且つ幅広い解集合を導出できることがいえる。

次に、各手法によって 30 試行で得られた、ZDT4, DTLZ3, KUR, KP750-2 における 50%到達領域を Fig. 4.4 に示す。ここでの 50%到達領域とは、全試行の 50%の試行において解集合が到達した領域である。なお、Fig. 4.4(d) の多目的ナップサック問題は最大化問題であり、それ以外の問題は最小化問題である。

Fig. 4.4 に示した探索結果から、提案手法の DPMOGA は DC-Scheme と NSGA-II に比べて精度および幅広さが優れた解集合を導出していることがわかる。解集合精度の向上に加え、幅広い解集合を導出することにより、パレートフロントの形状についての情報をより多く得ることができる。これは特に、KUR や KP750-2 といったパレート最適フロントが未知な問題において重要である。

また、各手法における解集合の幅広さの遷移履歴および探索履歴について、KUR の場合を例とし

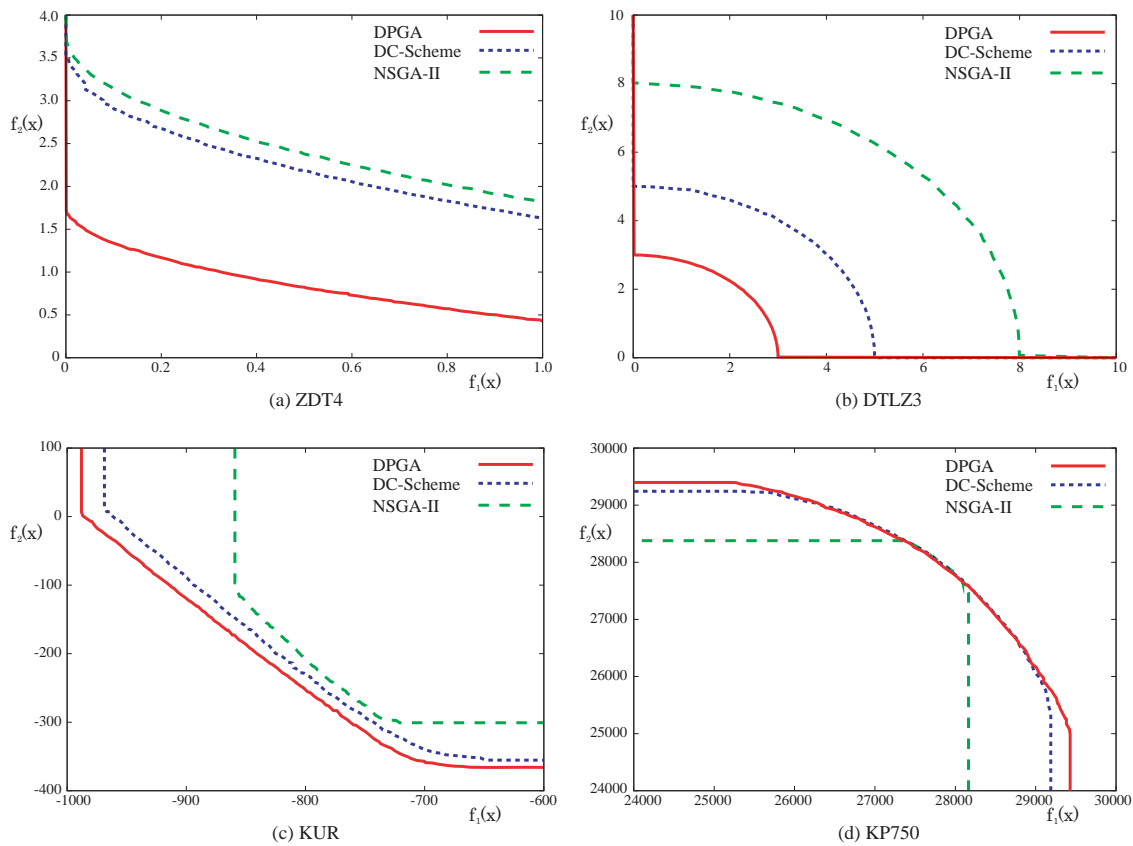


Fig. 4.4 50% Attainment Surface

て Fig. 4.5 に示す . Fig. 4.5(a) は解集合の幅広さの遷移履歴, Fig. 4.5(b) ~ (d) は 200, 400, 1000 世代で導出したパレート解集合を示す . なお, DPMOGA と DC-Scheme における探索の切り替え世代数はそれぞれ 200 と 400 である . Fig. 4.5(a) に示すように, DPMOGA と DC-Scheme といった探索の切り替えを用いる手法では, 1 段階目探索を 2 段階目探索に切り替えた直後に解集合の幅広さが著しく向上したことが確認できた . また, DPMOGA は DC-Scheme より早いタイミングで探索の切り替えを行うことで, より多くの探索コストを 2 段階目の各目的の最良解を導出するための探索に費やすことができ, かつより幅広い解集合の導出を実現した . Fig. 4.5(b) ~ (d) に示した探索結果から, 200 世代の際に提案手法の DPMOGA は最も精度の高い解集合を導出していることを確認できた . それは DPMOGA における 1 段階目探索は希求点および島モデル型 GA を用いることで, 解探索力に優れたと考えられる . 1 段階目探索で高い精度のパレートフロントに到達した後, 2 段階目探索を用い解集合の幅広さできる限り向上することで, 最終的に最も精度の高い尚且つ幅の広い解集合を導出できた .

5 結論

多目的最適化問題において, 目的間のトレードオフ関係を正確に把握するためには, 精度と幅広さに優れたパレート解集合を導出することが重要となるが, 解集合の幅広さを向上させることによって探索の精度が低下するため, 精度と幅広さを同時に向上させることは困難である . そのため, 本論文では探索のプロセスを精度の向上と幅広さの向上の 2 つに分割し, この 2 つのプロセスを適切に切り

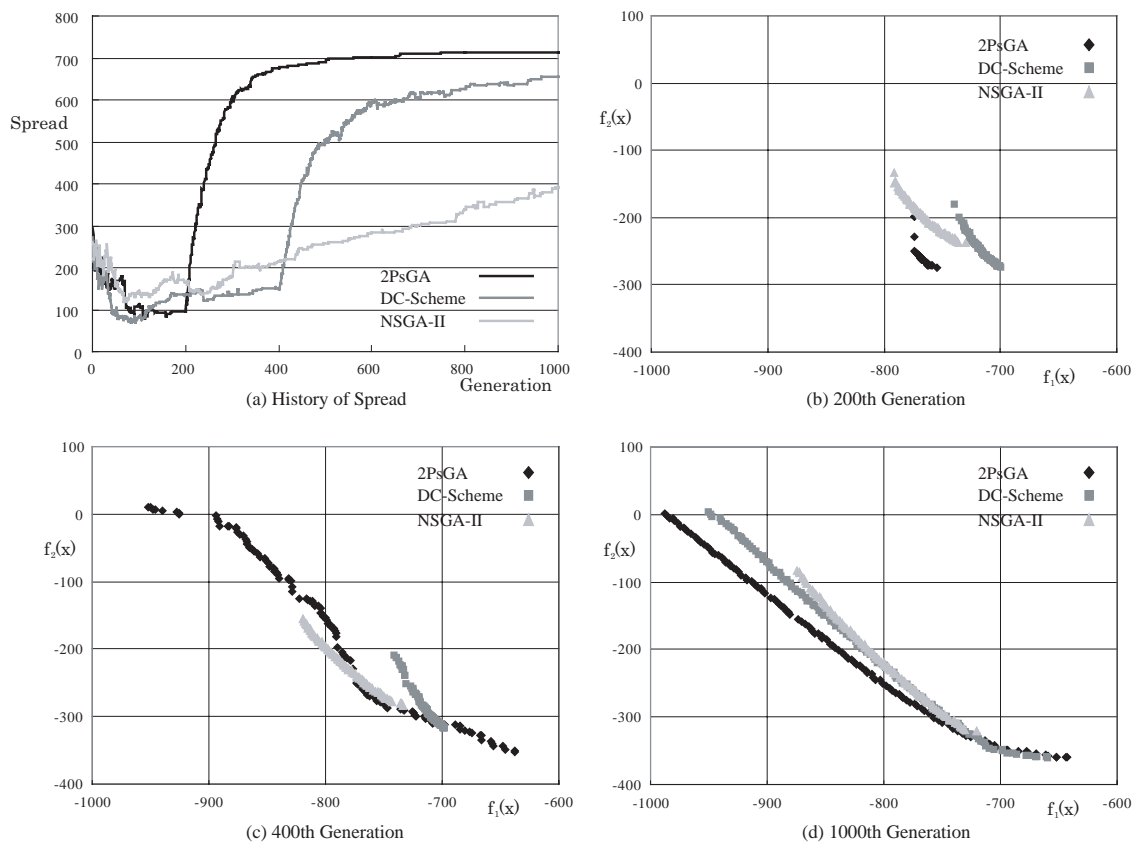


Fig. 4.5 Spread History and Search Result for KUR

替える DPMOGA を提案し、検証を行った。

提案手法では、1 段階目の探索を精度の高いパレートフロントに到達させるための探索とし、2 段階目を幅広いパレートフロントを生成させるための探索とする。このとき、意思決定者によって設定される希求点と島モデル型 GA を 1 段階目の探索に適用することで、収束性と多様性のバランスを保ち、精度の向上を実現する。また、改良した DC-Scheme を 2 段階目の探索に用いることで、各目的における最適解を探索しつつ、解集合の幅広さの向上を実現する。DC-Scheme の改良として、SOGA 個体群がそれぞれの目的における最良解を導出した後にパレートフロントを被覆する。探索終盤にパレートフロントを被覆することで、より多くの探索コストを各目的の最良解の導出に費やすことができ、かつより幅広いパレートフロントの導出が実現する。

本論文では、DPMOGA の有効性を検証するため、DC-Scheme を用いた手法と一般的な多目的 GA 手法 NSGA-II と比較を行った。その結果、パレート最適フロントが既知の問題においては幅広さが最大となるパレート解集合を導出でき、かつ解集合の精度の向上が確認できた。また、パレート最適フロントが未知の問題においても最も幅広い解集合を導出していることが確認できた。解集合精度の向上に加え、幅広い解集合を導出することにより、パレートフロントの形状についての情報をより多く得ることができる。これは特にパレート最適フロントが未知な問題において重要である。

これらの結果から、提案手法の DPMOGA は探索プロセスを精度の向上と幅広さの向上の 2 つに分割し効率的に探索を行うことで、より精度の高い尚且つ幅広い解集合を導出することができるといえる。

謝辞

本研究を遂行するにあたり、ご指導くださいました同志社大学理工学部の三木光範教授および、生命医科学部の廣安知之教授に心より感謝いたします。学部4回生からの3年間、知的システムデザイン研究室で充実した研究生生活を送ることができたことは、このような環境を提供してくださった先生方のおかげです。心より感謝いたします。

また、多目的最適化グループの皆様には大変お世話になりました。3年間を通して多目的最適化の研究をさせていただきましたが、その中で多くの方々からご指導を頂きました。4回生の頃には、室蘭工業大学の渡邊真也講師に多目的最適化の基礎から最先端の研究までご教授いただきました。ご卒業された小林賢二さん、西岡雅史さん、石田裕幸さんには多目的最適化について学び、研究を進めていく上で大変お世話になりました。多目的最適化の分野で興味を深めていくことができたのは、先輩方の影響が大きかったと思います。ありがとうございました。また、後輩の小林祐介君、戸松佑太君、森智弥君とは日々の研究ミーティングなどで議論を交わすことで、活気のあるグループで研究をすることができ、多目的最適化の新しい分野へと挑戦していたことから、私自身も刺激を受けることができました。このようなすばらしい仲間に恵まれたことを感謝いたします。

研究グループ以外の方々にも、研究に関するアドバイスを頂き、お世話になりました。モチベーションの高い人達に囲まれる環境の中で、私自身の成長にもつながったと感じています。また、本論文を執筆するにあたり、就職活動中にも関わらずチェックをしてくださった、戸松佑太君と君には大変感謝いたします。お二人の指導のおかげで、本論文を執筆することができました。

最後に、知的システムデザイン研究室のみなさんには、数多くの貴重なご意見をいただきました。また、皆さんのおかげですばらしい環境の中で研究生生活を送ることができました。この場を借りて感謝いたします。ありがとうございました。

参考文献

- 1) D. E. Goldberg. *Genetic Algorithms in search, optimization and machine learning*. Addison-Wesley, 1989.
- 2) 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.
- 3) E. Zitzler and L. Thiele. Multiobjective Evolutionary Algorithms: A Comparative Case Study and the Strength Pareto Approach. *IEEE Transactions on Evolutionary Computation*, Vol. 3, No. 4, pp. 257–271, 1999.
- 4) K. Deb, S. Agarwal, A. Pratap, and T. Meyarivan. A Fast Elitist Non-Dominated Sorting Genetic Algorithm for Multi-Objective Optimization: NSGA-II. In *KanGAL report 200001, Indian Institute of Technology, Kanpur, India*, 2000.
- 5) E. Zitzler, M. Laumanns, and L. Thiele. SPEA2: Improving the Performance of the Strength Pareto Evolutionary Algorithm. In *Technical Report 103, Computer Engineering and Communication Networks Lab (TIK), Swiss Federal Institute of Technology (ETH) Zurich*, 2001.
- 6) K. Deb. *Multi-Objective Optimization using Evolutionary Algorithms*. Chichester, 2001.
- 7) Tamaki Okuda, Tomoyuki Hiroyasu, Mitsunori Miki, and Shinya Watanabe. DCMOGA: Distributed Cooperation model of Multi-Objective Genetic Algorithm. In *Advances in Nature-Inspired Computation: The PPSN VII Workshops*, pp. 25–26, 2002.
- 8) 坂和正敏, 石井博昭, 西崎一郎. ソフト最適化. 日本ファジィ学会編 ソフトコンピューティングシリーズ 第2巻. 朝倉書店, 1995.
- 9) 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. システム制御情報ライブラリー 17. 朝倉書店, 1998.
- 10) Kalyanmoy Deb and J. Sundar. Reference Point Based Multi-Objective Optimization Using Evolutionary Algorithms. In *GECCO '06: Proceedings of the 8th annual conference on Genetic and evolutionary computation*, pp. 635–642, 2006.
- 11) Reiko Tanse. *Distributed Genetic Algorithms*. Proc.3rd International Conf. Genetic Algorithms. Morgan Kaufmann, pp.434-439. 1989.
- 12) Antonio Lopez Jaimes and Carlos A. Coello Coello. MRMOGA: Parallel Evolutionary Multi-objective Optimization using Multiple Resolutions. In *in 2005 IEEE Congress on Evolutionary Computation (CEC'2005)*, pp. 2294–2301, 2005.

- 13) 西岡雅史, 廣安知之, 三木光範, 横内久猛. パレート解集合の精度と幅広さを考慮する多目的遺伝的アルゴリズムの探索戦略. 最適化シンポジウム講演論文集, No. 8, pp. 219–224, 2008.
- 14) Kalyanmoy Deb and T. Meyarivan. Constrained test problems for multi-objective evolutionary optimization. *KanGAL report 200005, Indian Institute of Technology, Kanpur, India*, 2000.
- 15) M. Laumanns Kalyanmoy Deb, L. Thiele and E. Zitzler. *Scalable multiobjective optimization test problems*. Proc. of 2002 Congress on Evolutionary Computation, pp. 825-830. 2002.
- 16) Frank Kursawe. A Variant of Evolution Strategies for Vector Optimization. In *Parallel Problem Solving from Nature. 1st Workshop, PPSN I*, pp. 193–197, 1991.
- 17) H. Ishibuchi, S. Kaige, and K. Narukawa. Comparison between Lamarckian and Baldwinian Repair on Multiobjective 0/1 Knapsack Problems. In *Proc. of the 3rd International Conference on Evolutionary Multi-Criterion Optimization*, pp. 370–385, 2005.
- 18) H. Sato, H. Aguirre, and K. Tanaka. Local Dominance Using Polar Coordinates to Enhance Multi-objective Evolutionary Algorithms. In *Proc. 2004 IEEE Congress on Evolutionary Computation*, pp. 188–195, 2004.
- 19) H. Ishibuchi and Y. Shibata. Mating Scheme for Controlling the Diversity-Convergence Balance for Multiobjective Optimization. In *Proc. of 2004 Genetic and Evolutionary Computation Conference*, pp. 1259–1271, 2004.
- 20) J. Knowles, L. Thiele, and E. Zitzler. A Tutorial on the Performance Assessment of Stochastic Multiobjective Optimizers. In *TIK Report 214, Computer Engineering and Networks Laboratory (TIK), ETH Zurich*, 2006.

付 図

2.1	パレート最適解	3
2.2	多目的最適化の目標	3
2.3	多目的 GA の探索	4
2.4	NSGA-II のアーカイブ更新	6
2.5	非優越ソートによるランキング	6
2.6	混雑距離	7
3.1	Concept of the Reference Point-based Search	9
3.2	Concept of the Reference Point-based Search	10
3.3	Concept of the Generation Alternation Model	10
3.4	Concept of the Distributed Cooperation Scheme	11
3.5	Concept of the 2nd Search Procedures of DPMOGA	11
3.6	Concept of MRMOGA Dominance Ratio	13
3.7	Concept of the Effectiveness Indicator	14
4.1	Concept of IGD	16
4.2	Concept of Spread	16
4.3	Concept of HyperVolume	16
4.4	50% Attainment Surface	20
4.5	Spread History and Search Result for KUR	21

付 表

4.1	テスト問題の定式	15
4.2	Reference Point of HyperVolume	17
4.3	GA parameters	17
4.4	DGA parameters	17
4.5	Reference Point	17
4.6	Inverted Generational Distance	18
4.7	Spread	18
4.8	HyperVolume	19