多目的遺伝的アルゴリズム

Genetic Algorithms in Multiobjective Optimization Problems

渡邉　真也, 近藤　健史

Shinya WATANABE,Takefumi KONDO

Abstract: In this paper, the most popular multiobjective genetic algorithms(MOGA) thecniques is roughly reviewed: moreover T.Kondo presents visualization of multiobjective genetic algorithms(VMOGA), S.Watanabe presents new parallel method, divided range multi-objective genetic algorithm(DRMOGA). In VMOGA, the behavior of pareto frontier is clealy gasped. Espesally, when performance of new method or algorithm of MOGA is tested, this method is usufule. The other side, DRMOA aim at improvement of serch efficiency in parallel.

1　はじめに

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，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妥協解を探し出すものを多目的最適化問題と呼ぶ．そのため，多目的最適化問題における目的は，これら複数存在する妥協解を探索することにある．

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 [1, 2, 3]．

そこで本研究では，遺伝的アルゴリズムを用いた多目的 GA に関する研究を行い，より広範囲のかつより高精度の解を求めるアルゴリズムの提案およびその検証を行っている．

2　多目的最適化問題

多目的最適化問題（Multiobjective Optimization Problems，MOPs）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，与えられた全て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．完全最適解とは，どの目的関数に関しても最適となっている解である．従って，最も望ましい最適解ではあるが，現実の多目的最適化問題ではこの完全最適解は存在しない場合が多い．

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」を求めることになる．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と言える．目的関数が 2 つの場合におけるパレート最適解の例を Fig. 1 に示す．

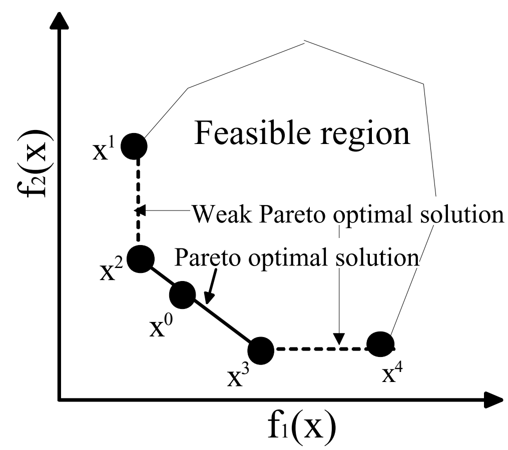

Fig. 1　Pareto optimal solution.

3　GA による多目的最適化への応用

3.1　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 [6]．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解集合を直接求めることが可能となる．

3.1.1 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，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，各個体を真のパレート最適解集合に近付ける．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．概念としては，世代が進むに従い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．概念図を Fig. 2 に示す．

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（非パレート的アプローチ）
- 解の優越関係に基づいて選択演算を行う（パレート的アプローチ）

という 2 つ考え方に基づいて，種々の方法が提案されている．

我々の研究では，より多様なパレート解（特に，各目的関数のバランスを考慮するようなパレート最適解）が得られやすいパレート的アプローチであるランキング法を用いている．

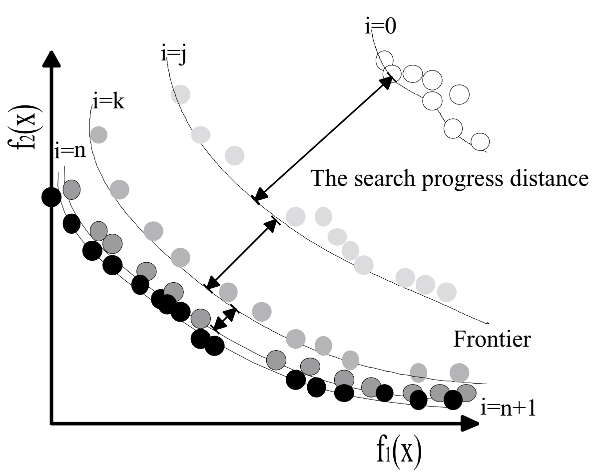

Fig. 2 MOPGA search

3.1.2 ランキング法

GA では，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 [1, 2]．ここでは，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．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

$$r(X_i) = 1 + n_i \tag{1}$$

のように定めることにしている．

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．

4 多目的 GA のビジュアライゼイション

一般的に行なわれている多目的 GA では，途中の世代における解集合の状態を考慮していない．そこで，多目的 GA の各世代ごとの個体分布をビジュアライゼイションすることにより，交叉やシェアリングの手法の違いによる個体推移の違いを把握することができる．

本研究では，多目的 GA のビジュアライゼイションを行うにあたり，Java で開発を行った．多目的 GA を行うクラスと，その計算結果を表示する GUI をつなぎ，単独で画面に表示できるようにした．

4.1 解曲面精度の向上

本研究ではパレート解がより効率的にかつ高い確率で，隙間のないパレート解曲面が生まれるような手法を提案する．

多目的 GA のビジュアライゼイションより，設定した最終世代における解曲面の「疎の部分」を確認することができる．これより,「疎の部分」近辺の個体に着目し，その選んだ一つの個体の設計変数値を基に，領域指定して個体を追加する．そして，多目的 GA の再探索を行う．

これは，多目的 GA の再探索を行う際の「開始領域」，つまり個体群が「疎の部分」近辺にあり，親個体の近傍交叉を行うので，全個体が「疎の部分」から遠のくことは考えにくい．よって,「疎の部分」近辺に追加個体を集中させて再探索させると「疎の部分」が補間できると考えられる．

4.2 実験

通常の多目的 GA の解曲面と，提案する手法による多目的 GA の解曲面の精度の比較検討を行い，提案する手法の有効性を検証する．

4.2.1 例題

本研究では，目的関数が 2 つの問題を使用した．今回の例題は，真の解が既知であるため，どの程度真の解に近づいているかを多目的 GA のビジュアライゼイションを通して把握することが可能となっている．

目的関数

$$
\begin{aligned}
f_1 &= \frac{1}{4}x_1^2 \\
f_2 &= x_1(1-x_2)+5
\end{aligned}
\tag{2}
$$

制約条件

$$
\begin{aligned}
1 \le x_1 \le 4 \\
1 \le x_2 \le 2
\end{aligned}
\tag{3}
$$

4.2.2　多目的 GA のパラメータ設定

今回の数値実験での多目的 GA のパラメータを以下の Table 1 のように設定した．

Parameter	Value
initial population size	100
crossover rate	1
mutation rate	0
Sharing range	10

Table 1　Parameter setting

4.2.3　実験結果

まず，通常の多目的 GA を 30 世代まで行った．その結果を Fig. 3 に示す．結果からもわかるように，30 世代では,「疎の部分」が複数箇所存在してしまった．

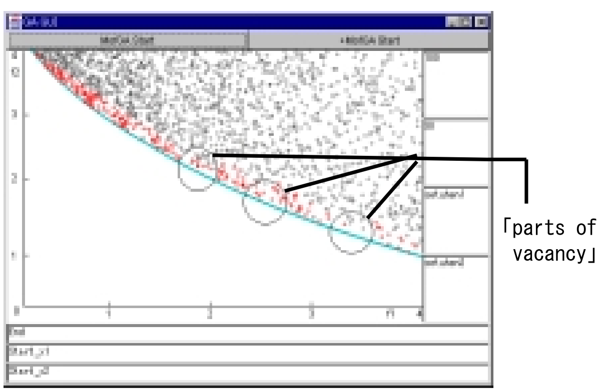

Fig. 3　Individual distribution of the time of 30 ganerations-end of usual GA in MOPs

そこで，解曲面の「疎の部分」を補間するため，再度個体の開始領域を Fig. 4 に指定している「疎の部分」近辺に決め，10 世代多目的 GA を行った．その結果を Fig. 4 に示す．結果から，指定した「疎の部分」周辺にランク 1 の個体が生まれ,「疎の部分」にうまく補間された．

実験結果より，多目的 GA の解曲面精度においては,「疎の部分」から再度多目的 GA を行う手法の方が，通常の多目的 GA に比べ「疎の部分」が全体的に減っているので，この手法は有効と言える．

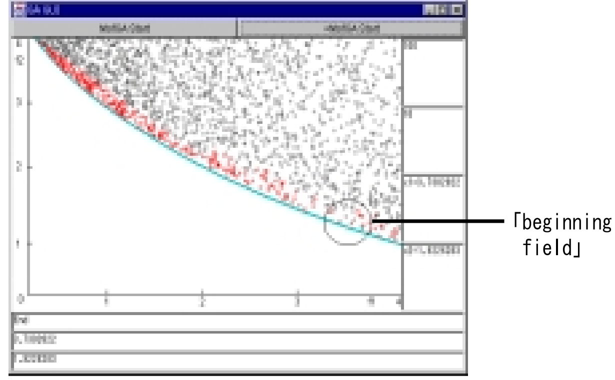

Fig. 4　Individual distribution of the case of resuming computation after 30 ganerations-end of usual GA in MOPs

4.3　結論

本研究では，多目的 GA のビジュアライゼイションによって，各世代における個体分布を視覚的に把握することが可能となった．また,「疎の部分」の補間という新たな手法を提案し，解曲面の精度を向上させることができた．

5　新たな並列モデルの提案

多目的最適化問題においてパレート解を求めるためには，複数存在する目的関数および制約条件の値を繰り返し算出する必要があり膨大な計算時間が必要となる．また，対象となる問題の目的関数の数が多い場合には，必要となる個体数が指数的に増加する場合があるなどの問題点がある．

これらの解決法の一つとして多目的最適化問題の GA による解決を並列処理により行うことが挙げられる．従来より単目的 GA における並列処理は研究されており，島モデルに代表される個体集団全体を幾つかの個体群に分割するモデルなどが提案されている．しかしながら，単一目的の場合と多目的の場合では最終的に求める点が唯一のものと解集合という大きな違いがあるために，多目的最適化 GA に適した並列モデルが存在するものであると考えられる．

そこで，本研究では多目的問題におけるそれらの問題点に対し，新たな分散型並列 GA 手法，領域分散型多目的 GA（以下，DRMOGA）を提案しその有効性について検証を行う．

5.1　領域分散型多目的 GA

本手法では，得られたパレート解集合を任意の目的関数を基にその関数における最大値順にソートし，分割数に従って各分割領域における個体数が平等になるように個体をソート順に各プロセッサに振り分けていく．分割数 3 の場合について Fig. 5 に示す．Fig. 5 に示すように，本手法では分割された領域がそれぞれ異なるパレー

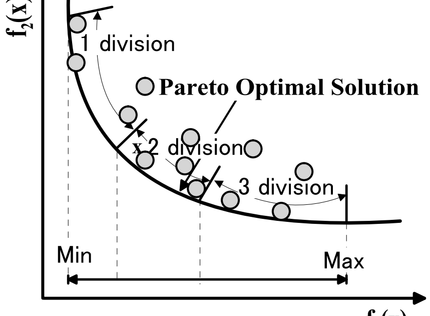

Fig. 5 DRMOGA

ト解空間を探索するため分割領域毎に探索領域が重なることがない．従来までの GA における分散型手法，島モデルでは，各個体を基本的にはランダムに各島へ分配していたが，提案する手法では各分割領域がそれぞれ異なるパレート解空間を独立で探索する点において従来の島モデルと異なっている．その意味で，本手法は多目的に特化した分散並列アルゴリズムであると言える．

5.2 対象問題

昨年度までは，主な対象として [3] などによって考案された簡単な連続関数の数値関数を扱ってきた．その結果，これらの連続関数対して提案する手法の有効性は検証された [4]．

そこで本年度より，離散的問題に対する提案手法の有効性の検証を行っていく．ここでは，具体的な対象とする離散問題として，サイズの異なる矩形ブロックの枠制約付きレイアウト問題を取り上げる．従来までの単目的レイアウト問題の多くは，ブロック間のフローを用いた重み付き距離の総和を目的関数として用いるものであった．この目的関数とレイアウト面積の間にはトレードオフの関係があることが既に分かっている．故に，この 2 つの評価はお互いに独立に，すなわち多目的として扱うのが妥当であると考えられる．そこで，本研究では，従来までの目的関数にレイアウト面積も目的関数として加えた 2 目的問題として解探索を行う．

本アプローチ手法におけるパッキングに関する概念図を Fig. 6 に示す．

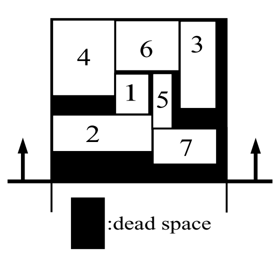

Fig. 6 Illustrating packing method

5.3 数値実験とその結果

得られた結果について，従来までの並列手法，島モデルとの比較を行う．島モデルにより得られた結果を，Fig. 7 に，提案する手法，DRMOGA により得られた結果を Fig. 8 に示す．

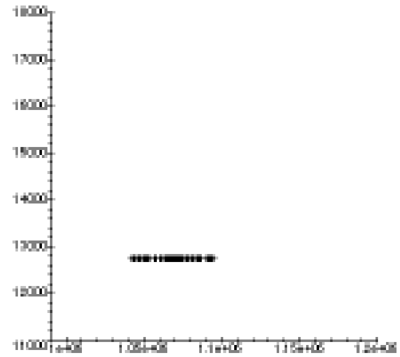

Fig. 7 DGA(island model) result

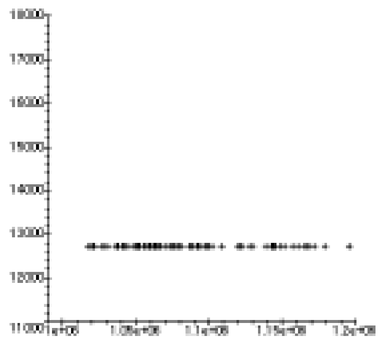

Fig. 8 DRMOGA result

Fig. 7,8 より提案する手法がより広範囲に解を検出している様子が分かる．これは，島モデルなどの DGA は局所的に個体が集中しやすいのに対して，提案する手法では，領域ごとに個体群が区切られているため，より全体としての個体の多様性が保たれるためであると考えられる．

5.4 提案手法の結論と今後について

この数値実験により提案する手法が，離散的な問題，少なくともブロック配置問題において有効であることが検証された．今後の課題としては，より具体的な問題，例えば LSI 部品の配置問題などにも取り組んで行く予定である．

参考文献

1) C. M. Fonseca and P. J. Fleming, Genetic algorithms for multiobjective optimization: Formulation, discussion and generalization, Proceedings of the 5th international coference on genetic algorithms, pp416–423, 1993.

2) D. E. Goldberg, Genetic Algorithms in search, optimization and machine learning, Addison-Wesly, 1989.

3) Tamaki, Mult-Objective Optimization by Genetic Algorithms: A Review, Proceedings of 1996 IEEE International Conference on Evolutionary Computation, pp517-522, 1996.

4) 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投稿中