

ネットワークインバージョンを利用した多目的遺伝的アルゴリズムのための多様性維持メカニズム

小林 賢二^{†1,*1} 廣安 知之^{†2} 三木 光範^{†2}

近年、多目的遺伝的アルゴリズムの実問題への適用がさかになってきている。実問題適用の際に考慮すべき事項として、高い計算コストへの対処がある。その方法の1つとして、小数個体での探索が考えられるが、計算コストの削減は図れるものの、探索過程において多様性の低下が生じるという問題がある。そのため、計算時間の確保が不十分な場合には多様性が低い解しか得られない。これに対して、目的関数空間において探索個体が集中した場合には、解を均等に再配置することで、高い多様性を持った解集合を得られる可能性がある。しかしながら、この場合、再配置の対象となる空間が目的関数空間であるため、目的関数値から設計変数値を推定する逆解析を行う必要がある。そこで本論文では、従来の多目的遺伝的アルゴリズムに、ニューラルネットワークの技術の1つであるネットワークインバージョンを併用した多様性維持メカニズムの提案を行う。また、クラスタリングの適用により、逆解析の精度の向上も目指す。本メカニズムを代表的な多目的遺伝的アルゴリズムの手法である NSGA-II に組み込み、テスト関数およびディーゼルエンジン燃料噴射スケジューリング問題に適用した結果、提案メカニズムは多様性の維持に対して有効な結果を示した。

Mechanism of Multi-objective Genetic Algorithms for Maintaining Solution Diversity Using Network Inversion

KENJI KOBAYASHI,^{†1,*1} TOMOYUKI HIROYASU^{†2}
and MITSUNORI MIKI^{†2}

Recently, many multi-objective genetic algorithms have been developed and applied to real-world problems. An important issue in resolving this type of problems is how to handle the high calculation cost. One possible solution to this problem is the search with a small population size. Although the calculation cost can be reduced with this approach, the diversity of solutions is often lost. Therefore, solutions that only have a low degree of diversity can be obtained with insufficient calculation time. Our approach to resolve this issue is to relocate the converged solutions uniformly in the objective space, when

solutions are converged to certain points. In this relocation, it is necessary to perform an inverse analysis that presumes the design values from the fixed objective values, because the relocation is conducted in the objective space. In this paper, we propose a new mechanism, which applies not only multi objective genetic algorithms but also Network Inversion, that can preserve the diversity of solutions. In addition, clustering of the training data set is applied to improve the accuracy of the inverse analysis. The proposed mechanism was introduced to NSGA-II, and its effectiveness was examined on mathematical test functions and diesel engine emission and fuel economy problem. In both types of problems with high dimensionality, the proposed mechanism provided solutions with a high degree of diversity even when the search was performed with a small number of solutions.

1. はじめに

最適化問題の中でも複数の評価基準について考慮する問題を多目的最適化問題という¹⁾。多目的最適化問題では、目的間にトレードオフがあることが多く、そのような場合はただ1つの最適解を得ることはできない。そのため、互いに劣らない解であるパレート最適解の集合を求めることが本問題の1つの目標となる。これに対して、遺伝的アルゴリズム (Genetic Algorithms: GA)²⁾ は、多点探索により1度の探索でパレート最適解集合を求められることから、よく用いられている。GAの多目的最適化問題への適用はこれまで数多く研究されており、そして近年、実問題への適用も進んでいる^{3),4)}。しかしながら、GAを用いた探索は多くの評価計算回数を必要とするという特徴がある。これは1度の評価に多大な時間を要する構造物の全体設計のような問題では大きな問題となる。そこで、計算コスト削減の方法として、これまでに並列処理による方法とアルゴリズムの改良による方法の2つの手法が主に提案されている。

1つ目の並列処理のモデルでは、多目的GAの処理操作を複数のノード間で共有して実行する形態をとる。並列モデルにはいくつかモデルがあるが、中でもマスタスレーブモデルは非常によく用いられているモデルである。マスタスレーブモデルを用いた方法では、

†1 同志社大学大学院
Graduate School of Engineering, Doshisha University

†2 同志社大学
Doshisha University

*1 現在、ソニー株式会社
Presently with Sony Corporation

多目的 GA の処理の中で最も時間を要する評価計算部を、複数のノードで分散して処理することにより計算時間の削減を行うものが多い。またその中でも、特に Deb の並列モデルは計算時間の削減が可能であるにもかかわらず、良好な解を得ることができることが報告されている⁵⁾⁻¹⁰⁾。

一方、本論文で扱うのは、2 つ目のアルゴリズムの改良による方法である。目標となるのは、探索時間の削減を図りつつ、良好な解を導出可能な方法の開発である。我々はこれに対し、これまでにニューラルネットワーク (Artificial Neural Network: ANN) を用いた多様性維持メカニズムを提案してきた¹¹⁾。本論文では、これまでのメカニズムでは困難であった、高次元の問題への対応や多峰性関数に関する対応を含めた、2 目的問題に適用可能な多様性維持メカニズムの提案を行う。

2. 多目的最適化

2.1 多目的最適化問題

多目的最適化問題は、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もとで最小化、または最大化する問題と定義されている。これは、 k 個の目的関数 $f(x)$ を m 個の不等式制約条件のもとで最小化 (最大化) する問題として以下のように定式化される¹⁾。

$$\begin{cases} \min & f(x) = (f_1(x), f_2(x), \dots, f_k(x))^T \\ \text{subject to} & x \in X = \{x \in R^n \mid g_i(x) \leq 0, (i = 1, \dots, m)\} \end{cases} \quad (1)$$

上式における $x = (x_1, x_2, \dots, x_n)^T$ は n 次元の変数のベクトルであり、目的関数 $f(x)$ と制約条件 $g(x)$ を形成する変数である。また X は実行可能領域を表す。

多目的最適化問題では、目的関数がトレードオフの関係にある場合、すべての目的関数が最小となる解は存在しない。そのため、最適解としてパレート最適解の概念が導入されている。

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。解の優越関係の定義を以下に示す。ただしすべて最小化を目的とする。

定義 (優越関係): $x_1, x_2 (x_1 \neq x_2) \in R^n$ とする。

a) $f_i(x_1) < f_i(x_2)$ ($\forall i = 1, \dots, k$) のとき、 x_1 は x_2 に強い意味で優越するという。

上式における x_1, x_2 は、 n 次元変数ベクトルである。 x_1 がすべての目的関数に対して x_2 よりも優れた目的関数値を有しているならば、 x_1 は x_2 よりも優れた解であるという。

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 (パレート最適解): $x_0 \in R^n$ とする。

x_0 に優越する $x \in R^n$ が存在しないとき、 x_0 はパレート最適解である。

上記の条件を満たす探索途中の最良解を非劣解、目的関数における最良解をパレート最適解という。一般にパレート最適解は複数存在するため、1 度の探索で複数のパレート最適解を導出する方法が用いられることが多く、その方法の 1 つとして多点探索である GA を用いた手法が提案されている。

2.3 多目的遺伝的アルゴリズム

GA は生物の進化をモデル化した最適化手法であり、多点探索であることから複数のパレート最適解を 1 度の探索で求めることができる。多目的 GA によって導かれるパレート最適解集合は、精度、幅、多様性を有していることが望ましいとされ、その探索方法として、多様性を維持しながら解探索を進めることが重要である。このような探索を実現する手法として、Zitzler らの Improving Strength Pareto Evolutionary Algorithm (SPEA2)¹²⁾ や、Deb らの Elitist Non-Dominated Sorting Genetic Algorithm (NSGA-II)¹³⁾ は、適合度の高い個体の保存や、多様性を維持した解探索により、良好な解を得られると報告されている。

3. 計算コスト削減へのアプローチと課題

3.1 計算コスト削減へのアプローチ

これまで良好なパレート最適解の導出を目指す多目的 GA の開発は数多くなされてきたが、近年、実問題への適用がさかんになるにつれて、解の質だけでなく計算時間についても考慮することが重要になってきた。そのため、できるだけ少ない計算回数で妥当な解を得ることが可能な多目的 GA の設計が求められている。このようなアルゴリズムの設計には応答局面法¹⁴⁾ を用いる方法と少数個体での多目的 GA による方法の主に 2 通りの方法が考えられている。

1 つ目の応答局面法は、対象問題の目的関数の近似関数を作成し、評価計算に用いることで計算コストを削減するものである¹⁵⁾。応答局面法のモデルには、2 次多項式モデル¹⁶⁾、ANN モデル¹⁷⁾⁻¹⁹⁾、Kriging モデル²⁰⁾ などがある。その中でも 2 次多項式モデルは最も単純なモデルであり、近似モデル作成の際の計算コストが小さく扱いやすいという点からよく用いられている¹⁴⁾。一方、ANN モデル、Kriging モデルは複雑で、近似モデル作成に要する計算コストも高いが、複雑な問題にも対処できることが知られている²¹⁾。

一方、本論文では少数個体での多目的 GA 探索による計算コストの削減を検討する。少

数個体での探索は計算コストの削減が可能な一方で、探索過程で探索解どうしの密集度が高まり、多様性が失われやすいという問題がある。これにより、探索時間を十分に確保できない場合には、たとえ高性能なアルゴリズムを用いても、多様性を持った解集合を得ることが困難となる。

そこで、探索過程で多様性が低下した際に、集中した探索解を多層型 ANN により目的関数空間で再配置する多様性復元メカニズムを提案する。多目的最適化における ANN を用いた研究としては、主に 2 通りの方法が考えられている。1 つ目は目的関数を近似した関数の利用により、評価計算に必要な計算コストを低減させるもの。2 つ目は逆関数を近似した関数によりローカルサーチを行うものである^{22),23)}。一方で、本論文での目標はそれらとは異なり多様性の復元である。

提案メカニズムの解の再配置は、配置の決定が 3 目的以上では難しくなるため 2 目的問題に限定している。また、ANN の学習に要する計算コストの議論は、本論文では行わない。これは本論文が対象とする、航空機の全体設計や自動車の衝突解析などの問題では 1 評価の計算時間が非常に大きく、ANN の学習による計算コストはそれに比較すると非常に微小となるためである。

3.2 多様性復元メカニズムへの課題

再配置の方法

提案メカニズムでは、密集した解集合をもとに仮想的なパレートフロントを作成し、そのフロント上に均等な分布を持つように解集合を設定する。そして、それらの解集合と密集した解集合を置き換えることで多様性の復元を行う。本論文では、仮想的なパレートフロント上に均等な分布を持つ解集合のことを、目標解集合と定義する。ただし、目標解集合は目的関数空間のみに存在しているため、目的関数値から設計変数値を推定する逆解析が必要となる。逆解析の一般的な方法として、逆関数の利用が考えられる。しかしながら、逆関数では、目的関数値が入力、設計変数値が出力となるため、特に高次元（入力要素が少なく、出力要素が多い）の問題では困難となる。そこで本研究では、学習済みの多層型 ANN を用いて出力から入力を推定する逆解析手法である Network Inversion (NI)^{24),25)} を用いる。NI による逆解析では、設計変数値を入力、目的関数値を出力とした関数を用いて、出力から入力の解析を行う。NI の詳細は 4 章で述べる。

クラスタリングの必要性

再配置には近似関数の性能が影響するため、学習データの選別に関しても検討を行う。学習データが少ない場合に良好な近似関数が作成される条件として、

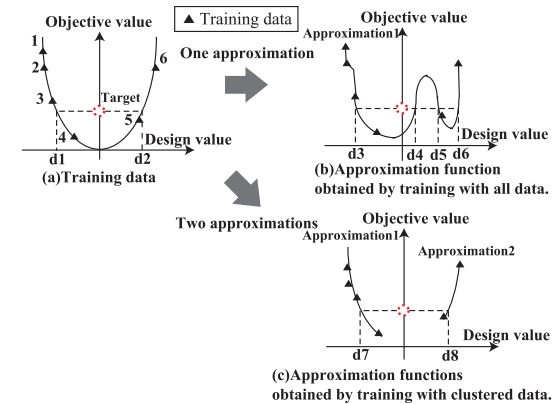


図 1 学習領域に極が存在する場合
Fig. 1 Case where a function pole exists in a training area.

- (i). データ間距離が小さい。
- (ii). 目的関数値と設計変数値の入出力関係が 1 : 1 で、関係性が容易。

などが満たされることが考えられる。一方で、学習領域に極を含む場合は、少ない学習データでの適切な近似は困難となる。このような状況の例を図 1 に示す。

図 1 の (a) で、Target の目標解は、2 つのパターンの設計変数値により得られることが分かる。このとき、学習データ 1~6 をすべて用いて 1 つの近似関数を作成すると、(b) のような実際の関数形状とは大きく異なる近似関数が作成される場合がある。この場合に適切な関数が作成されない理由の 1 点目に、条件 (i) を満たしていない点があげられる。2 点目に、作成された近似関数が複数の設計方法により目標解を得られる関数形状となっていることがあげられる。つまりこの場合、目的関数値と設計変数値の入出力関係が 1 : N (N は 2 以上の整数) であり、(ii) の条件を満たしていない。一方で、(c) のように学習データを 2 つのグループに分割し、各々で近似関数を作成すれば目的関数値と設計変数値の関係は 1 : 1、かつ 1 つの近似関数に対する近似領域も狭くなるため、(i)、(ii) の条件を満たした良好な近似関数の作成が行いやすくなる。本研究では、このような極を含む場合、つまり解の目的関数空間と設計変数空間の近接性が異なる場合の学習データの系統分離を、両空間での

データの近接性を考慮したクラスタリングにより行う。

4. クラスタリングと Network Inversion による多様性維持メカニズム

本章では、クラスタリングと NI を用いた多様性維持メカニズムを提案する。提案メカニズムは、多目的 GA による探索、クラスタリング、ANN の学習、再配置の 4 つのプロセスから成り立っており、後者 3 プロセスにより多様性の復元を実現する。提案メカニズムの概念図を図 2 に示す。

多様性復元プロセス適用のタイミングは、初回は多目的 GA のアーカイブに含まれる個体が最初にすべて非劣解になったときとし、2 回目以降は残り世代に対して均等になるようにする。多目的 GA 後の処理の詳細を以下に示す。

Step 1: 線形補間 多目的 GA で得られた n 個の非劣解集合を通る直線を補間により求める。

Step 2: 目標解の設定 非劣解集合の両端以外の解を取り除き、目標解間の距離が Step 1 で求めた補間直線上において均等になるように、 $n - 2$ 個の目標解を設定する。

Step 3: クラスタリング クラスタリングを多目的 GA で得られた非劣解集合に適用する。

Step 4: ANN の学習 クラスタリングにより得られた解集合を学習データとして ANN の学習を行い、近似関数を作成する。

(入力: 設計変数値, 出力: 目的関数値)

Step 5: 逆解析の実行 近似関数を用いた NI により逆解析を行い、各々の目標解の目的関数値に対応する設計変数値を取得する。

Step 6: 再配置 得られた設計変数値をもとに、真の目的関数で評価計算を行う。これにより得られた解集合とアーカイブを合わせ、多目的 GA のアーカイブ更新メカニズムを適用する。

4.1 線形補間と目標解の設定 (Step1, Step2)

目標解の目的関数値の決定手順について以下に述べる。まず、多目的 GA により得た非劣解集合を通る補間直線を得る (Step1)。この際用いる補間方法には、予備実験より 2 次以上の補間に比べ良好な結果を示した線形補間を用いる。次に、目標解が以下の 2 条件を満たすように設定する。1) 目標解は補間直線上に存在する。2) 目標解は補間直線上において

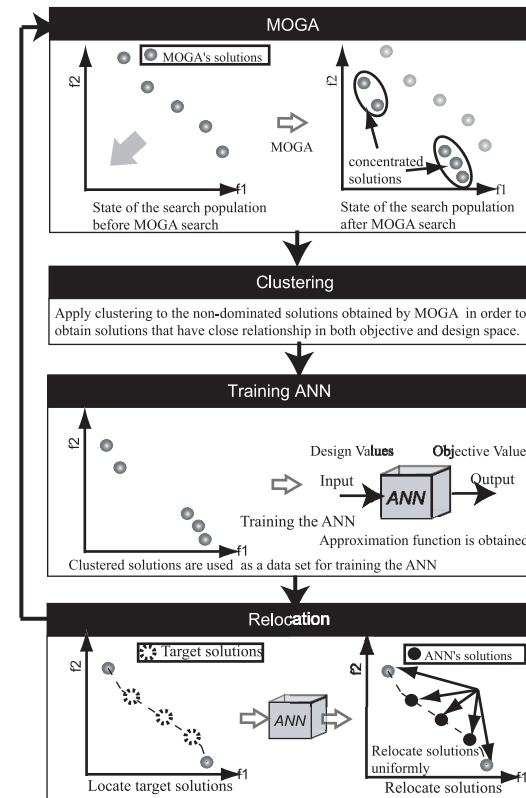


図 2 提案メカニズムの概念図
Fig. 2 Concept of proposed mechanism.

互いに隣り合う解と等距離に存在する。3 目的以上の問題に対しては位置の設定が難しいため、本論文では 2 目的の問題に焦点を絞る。目標解の設定スキームを図 3 に示す。

図 3 の左図は Step1, 右図は Step2 の概念図を示している。

4.2 クラスタリング (Step3)

解集合が目的関数空間で近接していても、設計変数空間で近接していない場合があることは 3.2 節で述べたが、多目的最適化問題でも同様のことが起こる。例として多峰性テスト関数 ZDT4 における、非劣解の目的関数空間と設計変数空間の分布を図 4 に示す。

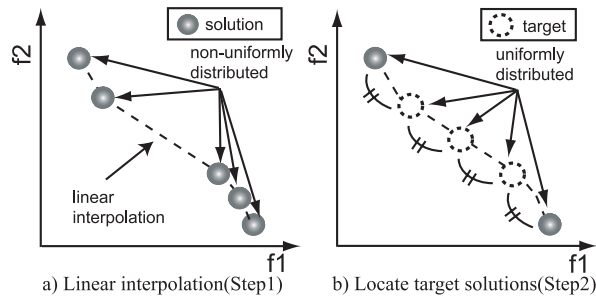


図 3 線形補間と目標解設定の概念図

Fig. 3 Concept of linear interpolation and locating targets.

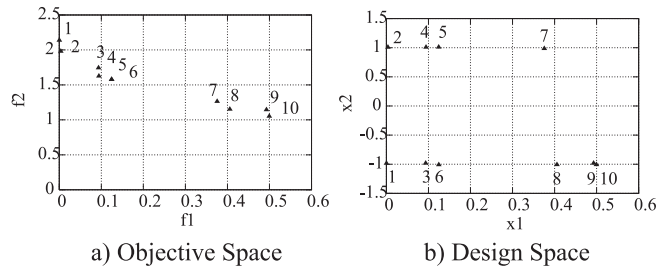


図 4 目的関数空間と設計変数空間の解の分布

Fig. 4 Distribution of a data set in objective and design space.

図 4 で、解 2 は目的関数空間で解 1 と 3 の間に存在しているが、設計変数空間ではしていない。また、解 9 は両空間で解 8 と 10 の間に存在している。本論文では、前者のような状況を解 2 は解 1 と 3 に隣接していない、後者を解 9 は解 8 と 10 に隣接していると呼ぶことにする。前者の状況は、目的関数値は近いにもかかわらず設計変数値は大きく異なる状況であるため、目的関数値と設計変数値の関係は 1 : N (N は 2 以上) であるといえる。このような場合に、すべての学習データで 1 つの近似関数を作成すると、適切な関数の作成が難しい。そこで、2 空間での解の隣接関係を考慮したクラスタリングアルゴリズムを提案する。提案アルゴリズムでは、解集合における目的関数空間と設計変数空間での解の隣接関係が等しくなるようなクラスタの形成を行う。ここでの解の隣接関係の等しい解集合とは、集合を形成する任意の解の両隣の解が、目的関数空間と設計変数空間で同じとなる解集合の

ことをいう。このようなクラスタリングは、データの近接性のみを考慮する一般的なクラスタリング手法では難しい。たとえば、代表的な手法である k-means 法を図 4 の解集合に適用すると、(1,2,3,4,5,6) と (7,8,9,10) の 2 つのクラスタに分かれて、うまくデータ分割できない場合がある。

そこで提案アルゴリズムでは、解集合中の 1 つの解を基準として、その解とすべての解とのユークリッド距離を計算することにより、目的関数空間と設計変数空間でその隣接関係が変化しない解集合を求める。また、予備実験より学習データは多目的 GA により得られた n 個の非劣解のみに絞る。このとき、ユークリッド距離を計測する際に用いる基準とする解を基準解、 n 個の非劣解の中で最小と最大の $f1$ 値を持つ 2 つの解を最端解と定義する。提案アルゴリズムの詳細を以下に示す。

Step 3-1: k 個の非劣解からなる集合に対して、 $f1$ 値が小さいものから大きいものへ順番に 1 から k の ID を付与 ($i = 0$)

Step 3-2: 基準解を設定 ($i = 0$ のとき ID が 1 の解、 $i = 1$ のとき ID が k の解)。

Step 3-3: 基準解とすべての解のユークリッド距離を設計変数空間で計算し、距離の近い順に ID を並べたソートリストを作成。

Step 3-4: ソートリストの隣接要素を 1 番目から順に比較し ($i = 0$:要素 $a >$ 要素 $a + 1$) ($i = 1$:要素 $a <$ 要素 $a + 1$) となるまでの要素を抜き出した集合 A_i を作成 ($a = 0, 1, 2, \dots$)。

Step 3-5: $i = 0$ ならば $i = 1$ として Step3-2 へ。

Step 3-6: 集合 $A_0 =$ 集合 A_1 のときは、集合 A_0 に含まれる解をクラスタとして終了。一方の集合が他方の集合に対して部分集合になるときは、部分集合に含まれる解をクラスタとして終了。それ以外の場合は、最端解を含む集合のみをそれぞれ新しい非劣解集合として Step3-1 へ。

上記のアルゴリズムを、図 4 の解集合に適用した場合の処理を図 5 に示す。

解 1 と 10 が基準解となり、解 1 からの距離が近い順は 1, 3, 6, 8, 9, 10, 2, 4, 5, 7 となる。このとき Step3-4 の条件を満たすのは、1, 3, 6, 8, 9, 10 の解集合である。次に解 10 を基準解として、同様の操作により 10, 9, 8, 6, 3, 1 のリストを得る。Step3-4 では、Step3-1 の ID 付与の際に得られた目的関数空間での解の隣接関係と、Step3-3 で得られた設計変数空間での解の隣接関係を比較することで両空間での解の隣接関係を判断してい

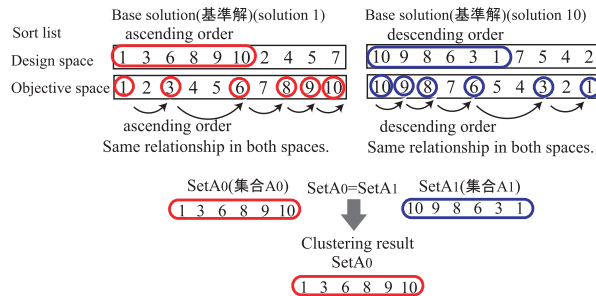


図 5 クラスタリングの概念図
 Fig. 5 Concept of clustering.




図 6 クラスタリング結果のパターン
 Fig. 6 Clustering patterns.

る．このようにして両空間での解の隣接関係が一致したクラスタを得ることができる．また本アルゴリズムでは，クラスタ数を事前に指定する必要がない．2つの最端解が1つのクラスタに含まれている場合はクラスタ数は1つ，最端解がそれぞれ別のクラスタにあるときは2つのクラスタを得ることになる．前者はCase1(すべての解を含む)とCase2(両端を含む)，後者はCase3(片端を含む，片端を含む)と分類できる．それぞれの例を図6に示す．

クラスタ数が2以下になるのは，Case3のような結果を得て，再びStep3-1~Step3-6を繰り返す場合でも，最終的には最端解が含まれているクラスタのみが出力されることになるためである．これは，最端解が含まれるクラスタを用いれば，多くの場合すべての目標解を近似領域内に含めることが可能であるためである．

4.3 ANNの学習と逆解析 (Step4~Step5)

Step4からStep5では目標解の設計変数値をNIにより逆推定し，設計変数値を得ることが目的である．各々の詳細について以下に述べる．

NIにおけるANNの学習

入力を設計変数値，出力を目的関数値(目的関数と同じ構造)としてANNの学習を行う．学習には誤差逆伝播法(Backpropagation: BP)を用いる．BPにおける学習の原理は，勾配法に基づく出力誤差の繰返し最小化である．ネットワークの入出力ベクトルおよび層間荷重による変換をそれぞれ， x, y, f としたとき，学習では $y = f(x)$ の正しい f を得ることが目的となる．まず x と y を与え，出力誤差 E を計算する．次に，出力誤差 E の発生原因が荷重 w_j の誤りによるものとして，

$$w_j(n+1) = w_j(n) - \epsilon \frac{\partial E}{\partial w_j} \quad (2)$$

の更新式によって荷重 w_j の修正を行う． n は学習回数， ϵ は学習係数を表す．以上の処理によりANNの学習を行う．学習データには，多目的GAにより得られた非劣解集合をクラスタリング処理し，その結果得られた部分解集合を用いる．

NIによる逆解析

次に学習したANNを用い，ネットワークの出力側から入力側を推定する．NIの逆推定の原理は，BPによる学習の原理と同様に勾配法に基づく出力誤差の繰返し最小化である．BPでは出力誤差の原因をネットワーク荷重の誤りにあると考え荷重修正を行うのに対し，NIの逆推定では出力誤差は入力の誤りによるものと考え入力に修正を行う点が違いである．また逆推定時は，学習済みのネットワークを用いるが，このネットワークでは $y = f(x)$ の f は正しいと仮定し，目標解の設計変数値 x を求めることが目的となる．まず， f (ネットワークの荷重)は固定したままの状態を，Step3のクラスタリング処理後の部分集合のいずれかの解の設計変数値を入力ベクトル x として与える．これにより，出力ベクトル y を取得し，出力誤差 E を計算する．次に，出力誤差 E の原因が入力 x_j の誤りによるものとして，

$$x_j(n+1) = x_j(n) - \eta \frac{\partial E}{\partial x_j} \quad (3)$$

の更新式によって入力 x_j の繰返し修正を行う． η は逆推定における入力修正の係数を表す．以上の操作により目標解の設計変数値 x を逆推定する．これをすべての目標解に対して繰返し行い，各々に対する予測設計変数値を得る．なお，ANNの学習コストおよびNIによる逆解析の計算コストは，GAの評価計算に要する計算コストに比べて相対的に微小となるため，本論文ではこれらのコストに関する議論は行わない．

4.4 再配置 (Step6)

Step5 の逆解析で得られた予測設計変数値を目的関数で評価し、真の目的関数値を得る。これにより得られた解集合と多目的 GA で得られた解集合をあわせた解集合を、多目的 GA のアーカイブ更新メカニズムで処理することにより、精度および多様性に優れた解を優先的に選出することができる。また、適切に目標解を得ることができなかつた場合でも、アーカイブ更新メカニズムによりそれらの解は淘汰されるため、探索の性能低下は起きないと考えられる。

以上の Step1 から Step6 の処理を多目的 GA に組み込み、繰り返し行うことで多様性を維持した多目的 GA の探索を行うことが可能である。

5. クラスタリングと NI による多様性維持メカニズムの有効性

提案メカニズムは多目的 GA の探索により失った多様性を解の再配置により復元し、かつメカニズムの繰返しにより多様性を維持した探索を行うものである。本章では、提案メカニズムの有効性の検証を、代表的な多目的テスト関数である ZDT1, ZDT2, ZDT4²⁶⁾ に対して数値実験を通して行う。特に ZDT4 は、多峰性関数であり、クラスタリングによる学習データの選別が有効と期待される問題である。ZDT1, ZDT2, ZDT4 の式を表 1 に示す。また本章の実験において、固定となる GA パラメータおよび ANN パラメータを表 2, 表 3 に示す。

評価手法 1: Angular Cover Rate (ACR)

ACR は目的関数空間における解の多様性を評価する手法である。本手法の値は以下の手順により決定される。

- Step 1: アーカイブ中の n 個の非劣解において、 f_1 値の最大値 (f_{1max}) と f_2 の最大値 (f_{2max}) をもとに参照点 (f_{1max}, f_{2max}) を決定する (凸型のパレートフロントを持つ場合)。非凸型の場合は参照点 (f_{1min}, f_{2min}) とする。
- Step 2: 参照点から両端の解へ向かって垂線を引く。
- Step 3: Step 2 で引かれた垂線どうしの間 (90 度) を、90 度 / n で分割し、等角度になるよう分割線を参照点から非劣解が存在する方向へ引く。
- Step 4: 非劣解によりカバーされている分割領域の数をカウントする。
- Step 5: カウント数/分割領域数を計算することにより指標の値を得る。

表 1 テスト関数 (ZDT1, ZDT2, ZDT4)
Table 1 Test functions (ZDT1, ZDT2, ZDT4).

| Problem | Functions |
|---------|---|
| ZDT1 | $\min f_1 = x_1$ $\min f_2 = g \times h$ $g = (1 + 9(\sum_{i=2}^n x_i)) / (n - 1)$ $h = 1 - (x_1/g)^{0.5}$ $x_i \in [0, 1]$ |
| ZDT2 | $\min f_1 = x_1$ $\min f_2 = g \times h$ $g = (1 + 9(\sum_{i=2}^n x_i)) / (n - 1)$ $h = 1 - (x_1/g)^2$ $x_i \in [0, 1]$ |
| ZDT4 | $\min f_1 = x_1$ $\min f_2 = g \times h$ $g = 1 + 10(N - 1)$ $\quad + \sum_{i=2}^n (x_i^2 - 10\cos(4\pi x_i))$ $h = 1 - (f_1/g)^{0.5}$ $x_1 \in [0, 1], x_i \in [-5, 5], i = 2, \dots, 10$ |

表 2 GA パラメータ
Table 2 GA parameters.

| | |
|-------|----------|
| 交叉率 | 1.0 |
| 交叉方法 | 2 点交叉 |
| 遺伝子長 | 20 × 次元数 |
| 突然変異率 | 1/遺伝子長 |

表 3 ANN パラメータ
Table 3 ANN parameters.

| | 2 次元 | 5 次元 | 10 次元 |
|--------------|---------|---------|---------|
| 入力層のニューロン数 | 2 | 5 | 10 |
| 中間層のニューロン数 | 6 | 10 | 20 |
| 出力層のニューロン数 | 2 | 2 | 2 |
| 最大学習回数 | 100000 | 100000 | 100000 |
| 安定化係数 | 0.6 | 0.6 | 0.6 |
| 許容誤差 (2 乗誤差) | 1.0e-04 | 1.0e-04 | 1.0e-04 |

解ができるだけ同じ分割領域に重複することなく存在するほど、良好な結果を示す。最大値は 1.0, 最小値は 0.0 となる指標である。ACR の概念図を図 7 に示す。




図 7 ACR の概念図
Fig. 7 Concept of ACR.

評価手法 2 : Generational Distance (GD)

GD²⁷⁾ はパレートフロントに対する非劣解集合の精度を計測する手法である。GD 値は以下の式により決定される。

$$GD = \frac{\sqrt{\sum_{i=1}^n d_i^2}}{n}$$

n は非劣解の数であり、 d_i は目的関数空間において、各々の解とパレートフロントに一番近い解とのユークリッド距離を示したものである。つまり GD 値が 0 に近いほど、本指標では良好な値を示し、真のパレートフロントにより収束していることになる²⁸⁾。

本章では提案メカニズムを有する多目的 GA をテスト関数に適用し、その有効性の検証を以下の 3 つの実験により行う。

- (1) クラスタリングの有効性の検証
- (2) 提案メカニズムによる多様性向上の検証
- (3) 提案メカニズムの繰返しによる多様性維持と精度への影響の検証

また、提案メカニズムを組み込む多目的 GA 手法は様々考えることが可能であるが、本論文のすべての数値実験では、多目的 GA の中でも最も代表的な手法である NSGA-II を用いた。以降の数値実験では、NSGA-II と NSGA-II+提案メカニズムの 2 つの手法の比較により有効性の検証を行う。

5.1 クラスタリングと NI による近似性能の評価

本論文では、2 空間における解の隣接関係を考慮したクラスタリングアルゴリズムを提案した。本実験では、クラスタリングを用いた後に NI を行う場合と NI のみを行う場合の比較により、クラスタリングが NI の性能に及ぼす影響を検証する。テスト関数には、多峰性

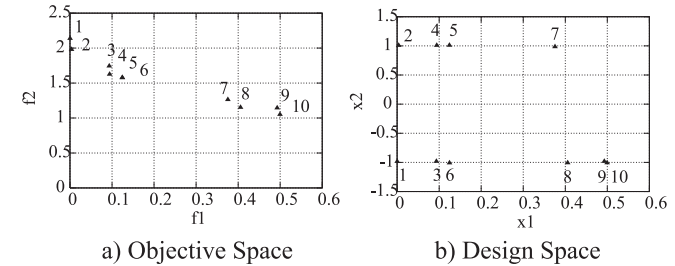


図 8 クラスタリングの効果検証のデータセット
Fig. 8 Test data set to examine the effect of clustering.

関数である ZDT4 を選択した。学習データには、図 8 に示す非劣解集合を用いた。また、提案メカニズムは少数個体での利用を想定しているため探索個体数は 10 とし²⁹⁾、設計変数空間でのクラスタリング効果の観察の容易化のため次元数は 2 とした。

図 8 において、左図と右図はそれぞれデータセットの目的関数空間と設計変数空間での分布を示している。本データセットでは、目的関数空間での解の隣接関係と設計変数空間での解の隣接関係が異なっている。実験結果を図 9 に示す。

図 9 において、上図は目的関数空間における目標解の分布を示している。また左図と右図はそれぞれクラスタリング適用時と非適用時の結果を示している。図 9 から、目的関数空間と設計変数空間における解の近接性に相違が存在する場合は、NI の前にクラスタリングを適用した方が近似精度を向上させられる場合があることが分かる。

5.2 提案メカニズムによる多様性向上の検証

次に提案メカニズムによる多様性の向上を数値的観点から検証する。本実験では、多目的 GA のみを行った場合と、多目的 GA の後に 1 回提案メカニズムを行った場合を比較した。テスト関数には、ZDT1, ZDT2, ZDT4 を使い、各々に対し 3 パターンの次元数について実験を行った。また、数値計測のための指標には多様性を表す ACR を用いた。実験のパラメータを表 4 に、結果を図 10, 図 11, 図 12 に示す。

図 10, 図 11, 図 12 は、両手法を 2 次元, 5 次元, 10 次元でそれぞれ 30 試行を行った際の、ACR の最小値, 中央値, 最大値を示したものである。これらの結果より、提案メカニズムによる多様性の向上は可能であることが分かる。また、高次元でも安定して高い多様性が得られていることが分かる。

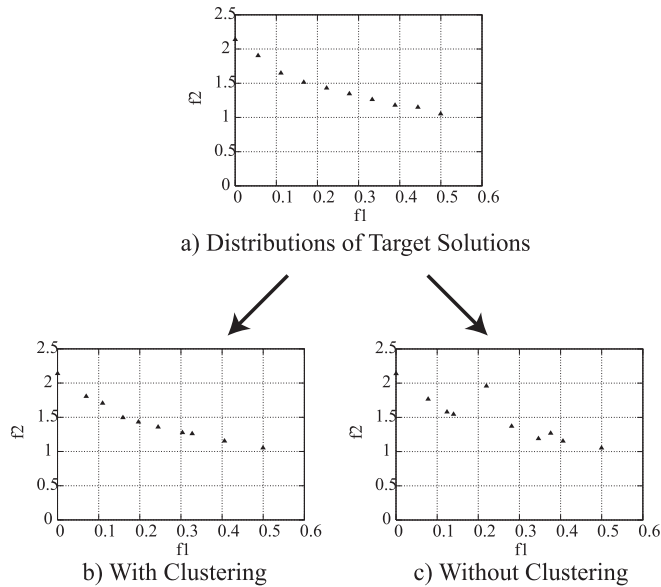


図 9 クラスタリングの効果の検証

Fig. 9 Effectiveness of NI with clustering.

表 4 多様性向上の検証実験パラメータ
Table 4 GA parameters in each problems.

| | ZDT1 | ZDT2 | ZDT4 |
|--------|--------|--------|--------|
| 母集団サイズ | 10 | 10 | 10 |
| 世代数 | 50 | 50 | 100 |
| 次元数 | 2,5,10 | 2,5,10 | 2,5,10 |

5.3 提案メカニズムの繰返しによる多様性維持と精度への影響の検証

これまでの実験から、提案メカニズムは多様性の向上に対し効果的であることが分かった。本実験では、多目的 GA と提案メカニズムを組み込んだ多目的 GA の探索途中における ACR の変化について検証する。本実験は、これまでの実験とは異なり、探索途中に複数回メカニズムを繰り返すことで多様性の維持を図るが、これによる精度の低下が懸念されるため GD 値についても検証する。テスト関数にはこれまでと同様に ZDT1, ZDT2, ZDT4 を用いた。実験のパラメータを表 5 に示す。




図 10 ZDT1 における ACR (Max., Median, Min.)

Fig. 10 ACR (Max., Median, Min.) in ZDT1.




図 11 ZDT2 における ACR (Max., Median, Min.)

Fig. 11 ACR (Max., Median, Min.) in ZDT2.




図 12 ZDT4 における ACR (Max., Median, Min.)

Fig. 12 ACR (Max., Median, Min.) in ZDT2.

まず、提案メカニズムによる多様性維持を ACR の変化により調査する。多目的 GA のみと、多様性維持手法を ZDT1, ZDT2, ZDT4 に適用した結果をそれぞれ図 13, 図 14, 図 15 に示す。

すべての図において、上図は両手法によって得られた 30 試行の非劣解集合をすべてプロッ

表 5 提案メカニズムの繰返し効果の検証実験のパラメータ

Table 5 Parameters to examine the iteration effect of proposed mechanism.

| | ZDT1 | ZDT2 | ZDT4 |
|------------|------|------|------|
| 母集団サイズ | 10 | 10 | 10 |
| 世代数 | 100 | 100 | 300 |
| 次元数 | 10 | 10 | 10 |
| メカニズムの適用回数 | 5 | 5 | 15 |





図 13 ZDT1 における ACR の変化
Fig. 13 Transition of ACR in ZDT1.

トしたもの、下図は世代ごとの ACR の変化を 30 試行の中央値をとりグラフ化したものである。これらの図から、提案メカニズムを用いた探索では、多目的 GA のみを行った場合に比べて高い多様性を維持できていることが分かる。

次に、提案メカニズムによる探索精度への影響を検証する。実験では、両手法により 30 試行で得られたパレート解と真のパレートフロントとの収束性を GD により比較する。30 試行の中央値と標準偏差の結果を表 6 に示す。GD 値を計算する際には、両手法の評価計算回数を合わせた。

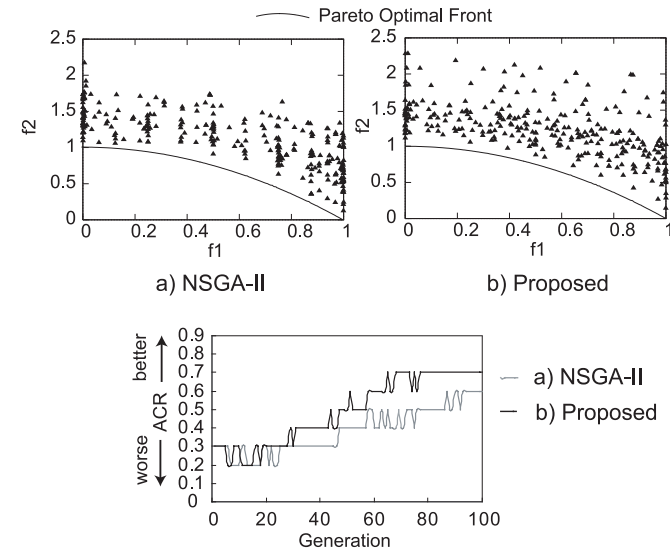


図 14 ZDT2 における ACR の変化
Fig. 14 Transition of ACR in ZDT2.

表 6 GD 値の比較
Table 6 Comparison of GD result.

| | ZDT1 | ZDT2 | ZDT4 | |
|----------|------|-------|-------|------|
| NSGA-II | 中央値 | 0.209 | 0.348 | 3.53 |
| | 標準偏差 | 0.106 | 0.128 | 1.66 |
| Proposed | 中央値 | 0.238 | 0.362 | 3.06 |
| | 標準偏差 | 0.130 | 0.214 | 1.31 |

表 6 の結果から、両手法によって得られた解の精度はおおむね同等であることが分かる。これらの 2 つの実験結果から、提案メカニズムは探索精度を落とすことなく解の多様性を維持することが可能であり、また、高次元探索でも提案メカニズムによる多様性の維持は可能であることが分かる。

6. 提案メカニズムの実問題への適用

これまでの実験より、提案メカニズムはテスト関数に対して有効であることが分かった。

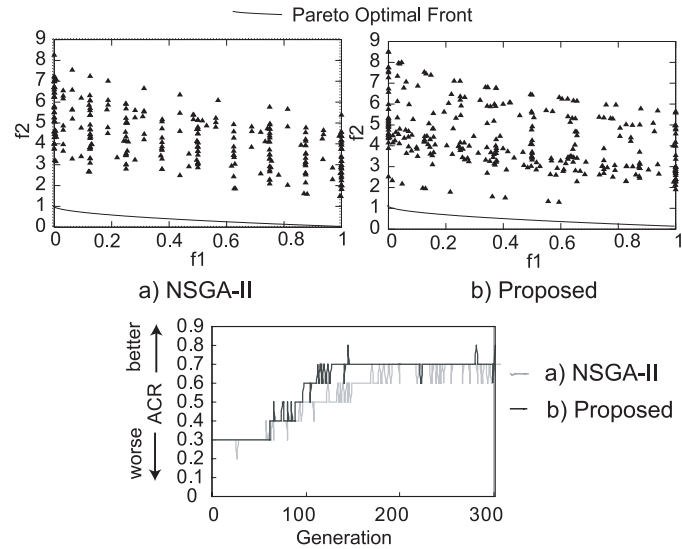


図 15 ZDT4 における ACR の変化
Fig. 15 Transition of ACR in ZDT4.

本章では、提案メカニズムの有効性の検証を、多目的最適化実問題であるディーゼルエンジン燃料噴射スケジューリング問題により行う。まずディーゼルエンジン燃料噴射スケジューリング問題について述べた後、数値実験による検証を行う。

6.1 ディーゼルエンジン燃料噴射スケジューリング問題

ディーゼルエンジンは燃費、耐久性の面でガソリンエンジンに比べ優れていることから大型車両で広く用いられている。また、排出される CO₂ の量が少ないという特徴も持っている。しかし、近年自動車エンジンに対する環境面からの厳しい要求が高まっている。このため、自動車業界では、環境規制を満たすためにガソリンエンジン、ディーゼルエンジンともに排ガスを減らす低エミッション化の研究が行われている^{30)–32)}。

ガソリンエンジンとディーゼルエンジンはともに、空気と燃料の混合圧縮気体を燃焼させることによって動力を得るといった点では同じであるが、燃料や燃焼過程は異なっている。ガソリンエンジンでは CO₂ の排出量が多く、ディーゼルエンジンでは窒素酸化物 (Nitric Oxide: NO_x)、すす (Soot) などの粒子状物質 (Particulate Matter: PM) の排出量が多い。また、NO_x や Soot の排出量はディーゼルエンジン内の燃料噴射スケジュールに依存す




図 16 ディーゼルエンジンの噴射形状
Fig. 16 Injection configuration of diesel engine.

ることが知られている。そこで、ディーゼルエンジンの低エミッション化のために、ディーゼル燃焼の改善に着目して排気特性の最適化を試みる³³⁾。これをディーゼルエンジン燃料噴射スケジューリング問題と呼ぶこととする。ここでの目的関数は

- NO_x の排出量
- Soot の排出量
- 燃料消費量 (SFC)

となり、すべての目的関数を最小化する最適化問題である。本問題は NO_x とすす (Soot)、NO_x と SFC の間にトレードオフの関係があることから多目的最適化問題として取り扱うことが可能である。これらの目的関数値は、次節で説明するシミュレーションより導出する。設計変数値は

- 噴射開始位置 (Start Angle)
- 再循環率 (Exhaust Gas Recirculation Rate: EGR Rate)
- スワール比 (Swirl Ratio)
- 過給圧 (Boost Pressure)
- 噴射形状 (2 段階噴射)

である。これらの設計変数を用いて、排気特性の最適化を行う。本論文で扱う 2 段階噴射を図 16 に、各設計変数の説明を以下に示す。

噴射開始位置

噴射開始位置とはディーゼルエンジンが燃料の噴射を開始するピストンの位置である。単

表 7 設計変数の条件
Table 7 Condition of design variable.

| 設計変数 | Max | Min | Bit 数 |
|---------------------------|------|-------|-------|
| 過給圧 (kg/cm ²) | 3.65 | 3.45 | 5 |
| 再循環率 | 0.3 | 0.0 | 5 |
| 最初の噴射期間 (CA) | 19.0 | 5.0 | 7 |
| 中間無噴射期間 (CA) | 15.0 | 3.0 | 7 |
| 2 度目の噴射期間 (CA) | 19.0 | 5.0 | 7 |
| 最初の噴射角度 | 10.0 | -10.0 | 8 |
| スワール比 | 6.0 | 0.0 | 7 |
| 最初の燃料噴射量 (率) | 0.8 | 0.5 | 7 |

表 8 ディーゼル問題における GA パラメータ
Table 8 GA parameters in diesel engine problem.

| | |
|--------|--------|
| 母集団サイズ | 10 |
| 実行世代数 | 50 |
| 交叉率 | 1.0 |
| 交叉方法 | 2 点交叉 |
| 遺伝子長 | 20×次元数 |
| 突然変異率 | 1/遺伝子長 |

位は ATDC (After Top Dead Center)^{*1}である。

再循環率

再循環率 (EGR Rate) は、吸入過程において吸入する空気に占める、再吸入した排気ガスの割合を示す。この値を高くすることにより、燃焼温度を下げ、NO_x の排出量を低減させることができるとされている³³⁾。

スワール比

効率の良い燃焼を行うためには、空気と燃料がよく混合されている必要があるため、吸入時に空気の渦を作ることによって空気と燃料がよく混ざるようにする。スワール比は、その渦の強さを示す。スワール比の値が大きくなると、燃焼が効率的に行われるため、SFC、Soot の排出量が低下する³³⁾。

過給圧

過給圧とは、吸入時に空気を圧縮する力である。過給圧が強いとき、吸入過程において吸入する空気の量が多くなる。過給圧を適切に設定することにより、ノッキング^{*2}を起こさずに燃焼を行うことができる。ノッキングがないとシリンダ径の制限も受けられないため、排気量を増やして出力を高めることも可能となる。

本研究における設計変数の制約条件を表 7 に示す。

6.2 ディーゼル燃焼モデル

ディーゼルエンジンの燃料噴射スケジュールから NO_x、Soot の排出量、SFC を得るために、ディーゼル燃焼のシミュレーションを行う必要がある。しかし、ディーゼル燃焼のシミュ

*1 ATDC とは、ピストンの上死点後を示す。上死点とは、ピストンが最も上昇した場所で、上死点を 0 度とする。
*2 燃焼室全体のガスが瞬間的に燃焼し、キンキンやカリカリなどの音が発生する現象。主に、ガソリンエンジンで生じる現象である。

レーションには多くの計算が必要であり、また、設計パラメータから NO_x、Soot の排出量、SFC を得る確定的な方法は存在しない。本論文では現象論的モデルである HIDECS^{34),35)} を用いている。

本章では、この HIDECS によるディーゼル燃焼スケジューリングのシミュレーションを、多目的 GA と提案メカニズムを組み込んだ同じ多目的 GA (多様性維持手法) で行い、提案メカニズムによる多様性の向上および、繰返しによる多様性の維持について検証する。

6.3 提案メカニズムによる多様性の向上の検証

本実験では、提案メカニズムを 1 回行った際に多様性の向上が可能かどうかを確認する。ここで多様性は、目的関数空間における解集合の分布と噴射形状などの設計変数の情報についてである。また、提案メカニズムは 2 目的対応のため、目的関数をトレードオフ関係のある SFC と NO_x の排出量の 2 目的に絞り最適化を行う。用いた GA パラメータを表 8 に示す。多目的 GA のみの場合の結果を図 17 の (a) に、多様性維持手法による結果を図 17 の (b) に示す。

図 17 より、3 つのことが確認できる。1 つ目は提案メカニズムを適用した (b) の方が目的関数空間に多様な個体分布を持った解集合を得られていることである。2 つ目は噴射形状についてである。NO_x の減少には、1 段階目と 2 段階目の両段階の噴射における単位時間の燃料噴射量および噴射時間を、同等にする必要があることが分かる。また、SFC を良化させるためには 1 段階目の噴射で多量の燃料を短時間で噴く必要があることも読み取れる。3 つ目は、2 段階噴射で NO_x 値を減少させるための EGR の変化が与える影響についてである。EGR の変化が NO_x の排出量に強い影響を与えていることは解 A と解 B の設計変数値を比較すれば分かるが、多目的 GA のみで探索を行った図 17 の (a) のような多様性がないような状況では、EGR の変化量に対する NO_x 減少への影響度合いを把握することは難しい。一方で、提案メカニズムの図 17 の (b) のように多様性がある状態ならば、EGR の変化量に対する NO_x 減少への影響の関係性の推定がしやすくなる。このように、多様性の保

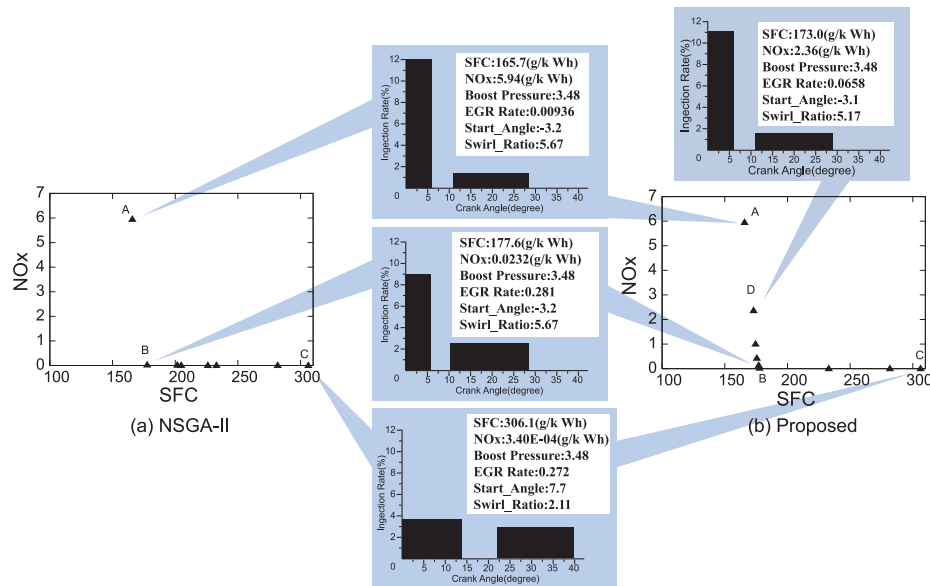


図 17 NSGA-II と提案メカニズムで得られた解集合

Fig. 17 Plot of solutions obtained by NSGA-II and proposed mechanism.

持はディーゼルエンジンの燃料噴射スケジューリングにとって、重要であることが分かる。

6.4 提案メカニズムによる多様性維持の検証

本節では、提案メカニズムによる多様性維持効果について検証する。本実験では、探索途中の ACR の変化について調査する。また、本対象問題ではパレート解が未知であり GD の適用ができないため、探索精度への影響は得られた非劣解集合のプロット図の比較により行う。用いた GA パラメータは表 8 と同様である。また提案メカニズムの適用回数は 10 回とし、30 試行を行った。まず、探索過程の ACR の変化の結果を図 18 に示す。

図 18 の結果より、多様性維持手法は多目的 GA のみの探索に比べて平均して高い多様性を維持した探索を行っていることが確認できる。次に、メカニズムの繰返しによる探索性能への影響を、導出解のプロット図により調査する。両手法 30 試行によって得られたすべての非劣解集合を、図 19 に示す。

図 19 より、提案メカニズムと多目的 GA により得られる非劣解集合は、ほぼ同等の精度を持っており大きな精度の差は存在しないことが分かる。以上の結果から、提案メカニズム

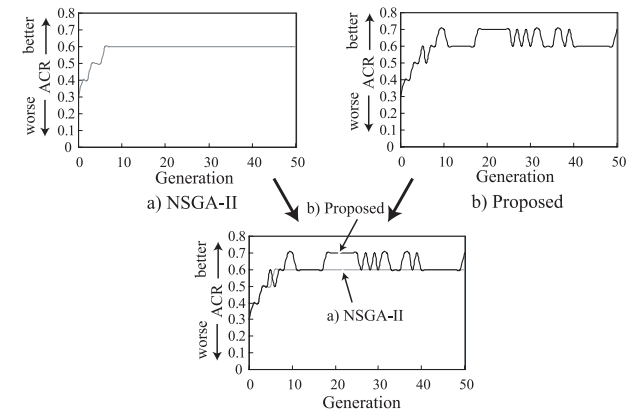


図 18 ディーゼル問題における ACR の変化

Fig. 18 Transition of ACR in diesel problem.

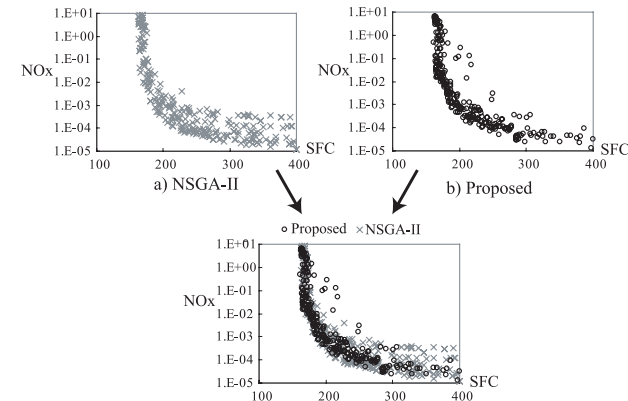


図 19 ディーゼル問題で得られた非劣解集合

Fig. 19 Non-dominated solutions in diesel problem.

はディーゼルエンジン燃料噴射スケジューリング問題においても、探索精度に大きな損失を与えることなく多様性を維持した探索が可能であることが分かる。

7. 終わりに

本論文では、実問題に多目的 GA を適用した際にしばしば問題となる高い計算コストに対する対応策として、少数個体の多目的 GA と NI による多様性復元処理を併用した、新しい多様性維持メカニズムを提案した。本メカニズムは、多目的 GA による探索、クラスタリング、ANN の学習、再配置の 4 つの処理からなっている。多目的 GA 部には様々な多目的 GA 手法が適用可能であり、残りのプロセスで多様性の向上を行う。クラスタリングは、多目的 GA によって得られた非劣解集合を、目的関数空間と設計変数空間における解の隣接関係を考慮した集合に分割するものである。ANN の学習では、クラスタリングによって得た非劣解集合の部分集合を用いて、近似関数の作成を行う。最後に、偏った分布を持つ解集合を、目的関数空間で均等な分布を持つ目標解群に置き換えることで多様性の復元を行う。目標解の設計変数値の逆推定は、学習済みの ANN を用いた NI により行っている。NI は目的関数と同じ構造（設計変数値をもとに目的関数値を導出）の学習済み ANN を用いて、出力から入力を予測することができるため、高次元の問題にも対処可能という特徴がある。なお、ここでは目標解の設定の簡易化のため 2 目的問題を対象としている。以上 4 プロセスを繰り返すことで、少数個体での多目的 GA の探索においても、多様性を維持した探索を実現する。

提案メカニズムの有効性の検証を行うため、代表的な多目的 GA 手法である NSGA-II に提案メカニズムを組み込み、テスト関数へ適用した。数値実験の結果、多様性復元処理を含む提案メカニズムを組み込んだ多目的 GA は、多目的 GA のみを行う場合に比べて、高い多様性を維持した探索が可能であることを確認した。また、高次元においても同様の結果を得ることができることを確認した。次に、多目的最適化実問題であるディーゼルエンジン燃料噴射スケジューリング問題でも同様の実験を行ったところ、本問題においても多様性を維持した探索が可能であることを確認した。これらのことから、提案メカニズムは少数個体における多目的 GA の探索において、多様性維持のための有効なメカニズムであるといえる。今後は、多目的 GA に用いる適切な探索個体数、および提案メカニズムの 3 目的以上の問題への対応について検討を行う予定である。

参 考 文 献

- 1) 坂和正敏：離散システムの最適化，森北出版（2000）。
- 2) Goldberg, D.E.: *Genetic Algorithms in search, optimization and machine learning*,

Addison-Wesley (1989).

- 3) Chiba, K. and Obayashi, S.: High-fidelity multidisciplinary design optimization of aerostructural wing shape for regional jet, *23rd Applied Aerodynamics Conference* (2005).
- 4) Hiroyasu, T., Miki, M., Kamiura, J., Watanabe, S. and Hiroyasu, H.: Multi-objective optimization of diesel engine emissions and fuel economy using genetic algorithms and phenomenological model, *SAE 2002 Powertrain and Fluid Systems Conference* (2002).
- 5) Deb, K., Zope, P. and Jain, A.: Distributed computing of pareto-optimal solutions with evolutionary algorithms, *EMO*, pp.534–549 (2003).
- 6) van Veldhuizen, D.A., Zydallis, J.B. and Lamont, G.B.: Considerations in engineering parallel multiobjective evolutionary algorithms, *IEEE Trans. Evolutionary Computation*, Vol.7, No.2, pp.144–173 (2003).
- 7) Streichert, F., Ulmer, H. and Zell, A.: Parallelization of multi-objective evolutionary algorithms using clustering algorithms, Coello, C.A., Aguirre, A.H. and Zitzler, E. (Eds), *Conference on Evolutionary Multi-Criterion Optimization (EMO 2005)*, Guanajuato, Mexico, 9-11 March 2005, Vol.3410 of *LNCS*, pp.92–107 (2005).
- 8) de Toro Negro, F., Ortega, J., Ros, E., Mota, S., Paechter, B. and Mart, J.M.: Parallel processing and evolutionary computation for multiobjective optimisation, *Parallel Comput.*, Vol.30, No.5-6, pp.721–739 (2004).
- 9) Coello, C.A., Lamont, G.B. and Van Veldhuizen, D.A.: *Evolutionary Algorithms for Solving Multi-Objective Problems*, pp.293–316 (2002).
- 10) Branke, J., Schmeck, H., Deb, K. and Reddy, M.: Parallelizing multi-objective evolutionary algorithms: cone separation, *Congress on Evolutionary Computation*, Vol.2, pp.1952–1957, IEEE (June 2004).
- 11) Kobayashi, K., Hiroyasu, T. and Miki, M.: Mechanism of multi-objective genetic algorithm for maintaining the solution diversity using neural network, *Lecture Notes in Computer Science*, Vol.4403, pp.216–226, Springer (2007).
- 12) Zitzler, E., Laumanns, M. and Thiele, L.: Spea2: Improving the strength pareto evolutionary algorithm for multiobjective optimization, Technical Report 103, Computer Engineering and Communication Networks Lab (TIK), Swiss Federal Institute of Technology (ETH), Zurich (2001).
- 13) Deb, K., Agrawal, S., Pratap, A. and Meyarivan, T.: A fast elitist non-dominated sorting genetic algorithm for multi-objective optimization: Nsga-ii, *KanGAL report 200001*, Indian Institute of Technology, Kanpur, India (2000).
- 14) 轟 章：応答曲面法．<http://florida.mes.titech.ac.jp/responsesurface.pdf>
- 15) 白井隆春, 荒川雅生, 中山弘隆：Rbf ネットワークを利用した多目的近似最適化手法の開発，日本機械学会・計算力学講演論文集，Vol.18, pp.759–760 (2005).

- 16) Julio, L.: hierarchical variable selection in polynomial regression models. <http://www.jstor.org/view/00031305/di020596/02p0164o/0>
- 17) Bishop, C.: *Neural networks for pattern recognition*, Oxford University Press (1997).
- 18) Henseler, J.: Back propagation, *Lecture Notes in Computer Science*, Vol.931, pp.37–66 (1999).
- 19) Hayman, S.: The mcculloch-pitts model, *Proc. IEEE Int. Conf. Neural Netw.*, Vol.6, pp.4438–4439 (1999).
- 20) Sacks, J., et al.: *Statistical Science*, Vol.4, pp.409–435 (1989).
- 21) Kounoe, Y. and Fujita, K.: Third-order polynomial response surface with optimal selection of interaction terms for global approximation, *Design and Systems*, Vol.15, pp.31–34 (2005).
- 22) Gaspar-Cunha, A. and Vieira, A.: A hybrid multi-objective evolutionary algorithm using an inverse neural network, *Hybrid Metaheuristics*, pp.25–30 (2004).
- 23) Adra, S.F., Hamody, I., Griffin, I. and Fleming, P.J.: A hybrid multi-objective evolutionary algorithm using an inverse neural network for aircraft control system design, *2005 IEEE Congress on Evolutionary Computation (CEC'2005)*, Vol.1, pp.1–8 (2005).
- 24) Linden, A. and Kindermann, J.: Inversion of multilayer nets, *Proc. Int. Joint conf. on Neural Networks*, pp.425–430 (1989).
- 25) 小川毅彦, 金田 一: 複素逆問題解法のための複素ネットワークインバージョン, 拓殖大学理工学研究報告, Vol.9, No.4, pp.83–84 (2006).
- 26) Deb, K. and Meyarivan, T.: Constrained test problems for multi-objective evolutionary optimization, *KanGAL report 200005*, Indian Institute of Technology, Kanpur, India (2000).
- 27) Deb, K.: *Multi-objective optimization using evolutionary algorithms*, pp.326–327, John Wiley and Sons, Chichester, England.
- 28) Cortes, N.C. and Coello, C.A.: Multiobjective optimization using ideas from the clonal selection principle, *Genetic and Evolutionary Computation GECCO 2003*, Lecture Notes in Computer Science, pp.158–170, Springer (2003).
- 29) Obayashi, S., Sasaki, D. and Oyama, A.: Finding tradeoffs by using multiobjective optimization algorithms, *Trans. JSASS*, Vol.47, No.155, pp.51–58 (2004).
- 30) 野田 明: エミッションクリーン化技術の現状と展望(ガソリン), *自動車技術*, Vol.55, No.9, pp.17–22 (2001).
- 31) 青柳友三: エミッションクリーン化技術の現状と展望(ディーゼル), *自動車技術*, Vol.55, No.9, pp.10–16 (2001).
- 32) 木村修二, 白河 暁: 超クリーンディーゼルへの挑戦, *自動車技術*, Vol.55, No.9, pp.41–45 (2001).
- 33) 伊藤昇平, 中村兼仁: コモンレールによるディーゼル排気ガスの浄化, *自動車技術*, Vol.55, No.9, pp.46–52 (2001).
- 34) Hiroyasu, H., Kadota, T. and Arai, M.: Development and Use of a Spray Combustion Modeling to Predict Diesel Engine Efficiency and Pollutant Emissions (Part 1 Combustion Modeling), *Bulletin of the JSME*, Vol.26, No.214, pp.569–575 (1983).
- 35) Hiroyasu, H., Kadota, T. and Arai, M.: Development and Use of a Spray Combustion Modeling to Predict Diesel Engine Efficiency and Pollutant Emissions (Part 2 Computational Procedure and Parametric Study), *Bulletin of the JSME*, Vol.26, No.214, pp.576–583 (1983).

(平成 19 年 11 月 24 日受付)

(平成 20 年 1 月 11 日再受付)

(平成 20 年 1 月 16 日再受付 (2))

(平成 20 年 1 月 28 日採録)



小林 賢二 (学生会員)

2006 年同志社大学工学部知識工学科卒業。2008 年同大学院工学研究科知識工学専攻修士課程修了。進化的計算, 多目的最適化, 機械学習等に従事。



廣安 知之 (正会員)

1997 年早稲田大学大学院理工学研究科後期博士課程修了。早稲田大学理工学部助手, 同志社大学工学部助手。知識工学科専任講師, インテリジェント情報工学科准教授を経て 2008 年から生命医科学部教授。進化的計算, 最適設計, 並列処理, 設計工学, 医療画像工学等の研究に従事。IEEE, 電子情報通信学会, 計測自動制御学会, 日本機械学会, 超並列計算研究会, 日本計算工学会各会員。



三木 光範 (正会員)

1950年生。1978年大阪市立大学大学院工学研究科博士課程修了，工学博士。大阪市立工業研究所研究員，金沢工業大学助教授を経て，1987年大阪府立大学工学部航空宇宙工学科助教授，1994年同志社大学工学部教授。進化的計算手法とその並列化，および知的なシステムの設計に関する研究に従事。著書は『工学問題を解決する適応化・知能化・最適化法』（技法堂出版）等多数。IEEE，米国航空宇宙学会，人工知能学会，日本機械学会，計算工学会，日本航空宇宙学会等各会員。通産省産業技術審議会委員等歴任。超並列計算研究会代表。
