

Mechanism of Multi-Objective Genetic Algorithm for Maintaining the Solution Diversity Using Neural Network

Kenji KOBAYASHI* Tomoyuki HIROYASU** and Mitsunori MIKI**

(Received April 20, 2007)

When multi-objective genetic algorithm is applied to real world problems for deriving Pareto optimum solutions, high calculation cost becomes a problem. One of solutions of this problem is using small number of population size. With this solution, however, it often happens that the diversity of the solutions is lost. Then the solutions which have the sufficient precisions cannot be derived. For overcoming this difficulty, the solutions should be re-placed when the solutions are concentrated on a certain point. To perform this re-placement, inverse analyze to derive the design variables from objects since the solutions are located in the objective space. For this purpose, in this paper, the Artificial Neural Network (ANN) is applied. Using ANN, the solutions which are concentrated on certain points are re-placed and the diversity of the solutions is maintained. In this paper, the new mechanism using ANN to keep the diversity of the solutions is proposed. The proposed mechanism is introduced into NSGA-II and applied for the test functions. It is discussed that in some test functions the proposed mechanism is useful compared to the conventional method. At the same time, it is also discussed that in other functions the proposed mechanism is not useful. In other numerical experiments, the results of the proposed algorithm with plentifully population are discussed and the affection of the proposed mechanism is also described.

Key words : multi-objective optimization , inverse problem, neural network, diversity, approximation
キーワード : 多目的最適化 , 逆問題, ニューラルネットワーク, 多様性, 近似

ニューラルネットワークの利用による 多様性維持メカニズムを有する多目的遺伝的アルゴリズム

小林 賢二・廣安 知之・三木 光範

1. はじめに

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¹⁾. 多目的最適化問題では、複数の評価基準は互いに競合する場合が多く、全ての評価基準が同時に最適となる解は存在しないため、他の解に劣らない解であるパレート最適解の集合

を求めることが目標の一つとなる。それに対して多目的最適化問題では、多点探索が可能な遺伝的アルゴリズム (Genetic Algorithm:GA)²⁾ が用いられることが多い。しかし、GA を用いた探索ではパレート最適解を求めるまでに多くの評価計算回数を必要とする。そのため、関数としては複雑ではなくても、一度の評価

* Graduate Student, Department of Knowledge Engineering and Computer Sciences, Doshisha University, Kyoto
Telephone:+81-774-65-6924, Fax:+81-774-65-6924, E-mail:kkobayashi@mikilab.doshisha.ac.jp

** Department of Knowledge Engineering and Computer Sciences, Doshisha University, Kyoto
Telephone:+81-774-65-6930, Fax:+81-774-65-6930, E-mail:tomo@is.doshisha.ac.jp, mmiki@mail.doshisha.ac.jp

計算に時間を要するような実問題においては、大きな問題となる。これを解決する方法としては、応答曲面³⁾などの近似を用いる方法や、多目的GAの解探索に用いる個体数を減らす、もしくは世代数を減らす方法などが考えられる。前者の方法は、対象問題の目的関数値を求める際に、目的関数の近似式を作成し、その近似式に対して多目的GAを行うことで、一度の評価計算にかかる計算コストを削減するというものである。応答曲面近似のモデルとしては、二次多項式モデル、ニューラルネットワークモデル、Krigingモデルなどがある。二次多項式モデルは最も単純なモデルであり、近似モデル作成にかかる計算コストが少なく扱いやすいという特徴からよく用いられる³⁾。ニューラルネットワークモデルやKrigingモデルは二次多項式モデルと比べて近似モデル作成にコストはかかるものの、より複雑な目的関数を近似することが可能である⁴⁾。

一方、本論文で検討するのは後者の少数個体での探索の場合である。少数個体で解探索を行う場合、探索過程において個体が集中し、探索個体の解の多様性が失われるという問題点がある。そこで、本論文では、多目的GAを少数個体で行う際に、探索過程で生じる解の多様性の低下を、人工ニューラルネットワーク(Artificial Neural Network:ANN)を利用することにより軽減し、多様性を維持しながら探索を行うことで、少ない評価計算回数で良好な精度を持ったパレート最適解を導出するメカニズムを提案する。この際ANNに要する計算コストを考慮する必要があるが、本論文で想定している問題は、GAの評価部に必要な計算コストが莫大で相対的にANNに要する計算コストが小さな問題である。航空機などの丸ごと設計や自動車の衝突解析がこれにあたる。そのため、ANNの導入による計算コストの議論は本論文では行わない。

本論文では、まず多目的最適化について触れ、その後、多様性の低下を軽減するANNを用いたメカニズムを詳しく述べる。その後、提案するメカニズムを代表的な多目的GA手法であるNSGA-IIに組み込み、テスト関数を用いてその効果と探索の影響について検討を行う。

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元で最小化、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 $\vec{f}(\vec{x})$ 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⁾。

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

上式における $\vec{x} = (x_1, x_2, \dots, x_n)^T$ は n 次元の変数のベクトルであり、目的関数 $\vec{f}(\vec{x})$ と制約条件 $\vec{g}(\vec{x})$ 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、全ての目的関数値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。ただし全て最小化であるとする。

定義（優越関係） : $x^1, x^2 \in R^n$ とする。

$f_i(x^1) \leq f_i(x^2)$ ($\forall i = 1, \dots, k$) のとき、 x^1 は x^2 に優越するという。

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。

一般にパレート最適解は複数存在するため、一度の探索で複数のパレート最適解を導出する方法の一つとして、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は多点探索であるため、複数のパレート最適解を一度に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は、精度と多様性を有していることが望ましいため、その探索方法として、精度と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Strength Pareto Evolutionary Algorithm(SPEA2⁵⁾)や、DebらのElitist Non-Dominated Sorting Genetic Algorithm(NSGA-I

I⁶⁾) 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、良好な解を得ることができると報告されている。

2.4 多目的遺伝的アルゴリズムの問題点

多目的 GA を用いた多目的最適化は、複数のパレート最適解を一度に導出できるという利点があるが、パレート最適解を求めるまでに多くの評価計算回数を必要とする。少數個体、もしくは少ない世代数での探索を行った場合、計算コストは削減できる。しかしながら、多目的 GA において少數個体で探索を行った場合、Fig. 1 の左図のように探索過程において探索個体の解の多様性が失われ、探索の進行を妨げられる場合が少なくない。これにより、精度の高い解が得られなくなる。これに対して、Fig. 1 の左図のように解が偏ってしまった場合に、Fig. 1 の右図のように解を均等に配置することができれば、少數個体においても、精度の高いパレート解を得ることが可能である。

しかしながら、ここで大きな問題となるのは、解の設計変数値の決定方法である。Fig. 1 の右図のように配置したい解の既値は目的関数値であり、設計変数値は未知である。そのため、逆解析を行い設計変数値を決定する必要が生じる。本論文では、この逆解析の際に ANN を利用する。

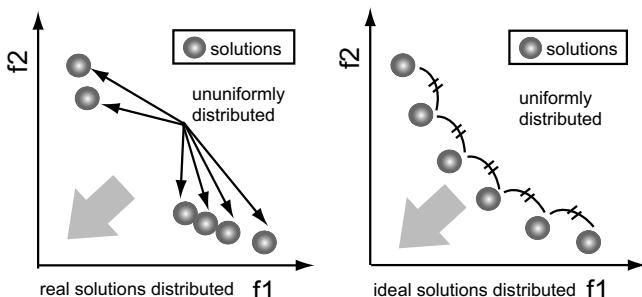


Fig. 1. 探索個体の多様性。

3. ANN による逆解析

3.1 Artificial Neural Network

ANN は、既知の複数個の入出力パターンを元に、未知のシステムの入出力関係を推測した近似関数の作成が可能なモデルであり、近年、ANN を用いた多目的最適化の研究も盛んに行われている。ANN を用いた多目的最適化手法としては主に 2 通りの方法がある。1 つめは、目的関数の近似関数を求ることにより、1 評価あたりの計算コストを削減するものである⁷⁾。2 つめは、目的関数の逆関数の近似関数を求ることによ

り局所探索に用いるものである^{8, 9)}。一方、本研究では、ANN を多目的 GA の目的関数の逆関数の近似関数を求め、探索過程における多様性維持に用いている。ANN には、誤差逆伝播法^{10, 11, 12)}を用いた、フィードフォワード型のニューラルネットワークである多層ペーセプトロン (Multi Layer Perceptron:MLP) がよく用いられている。

3.2 ANN による多様性維持メカニズム

多目的 GA により求められるパレート最適解集合が Fig. 2 の左図のように偏った場合、破線の丸で示されたような解を新たに導出することで多様性の復元を行う方法について考える。しかし、破線の丸で示された解を求めるためには、この解が持つ目的関数値を求められる設計変数値を導出する必要がある。これは、一般に目的関数の逆関数を求ることにより実現が可能であり、これに ANN を利用する。

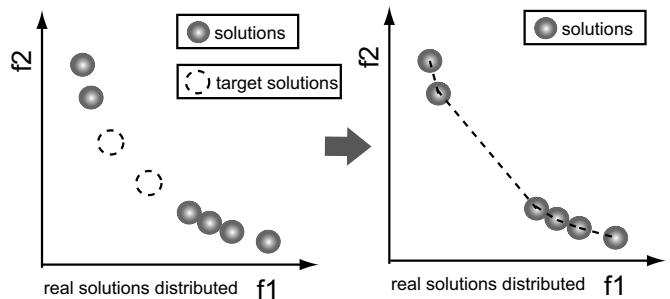


Fig. 2. ANN による多様性維持メカニズム。

本論文では、目的関数の逆関数すべてを求めるのではなく、Fig. 2 の右図の破線で示すような、非劣解を通る部分のみの逆関数を求める方法について提案を行う。この逆関数の作成は、多目的 GA によって導出された非劣解集合を元に学習を行うことによって行う。ANN の学習により計算コストが増加するが、本論文で想定している問題は評価計算が非常に大きなものであり、ANN の学習コストは無視できるものとする。学習のために用いるデータには、正確な入出力関係を表しているデータが必要なため、多目的 GA によって実際に導出されたデータを用いる。ただし、このデータを用いた ANN での学習は、多目的 GA での設計変数値から目的関数値を導出する方法ではなく、目的関数値を入力、設計変数値を出力として学習を行う。これにより、目的関数値を元にこれに対応する設計変数値の導出を行う。

このようにして作成された ANN に対し、Fig. 1 の右図に示したような、目標となる偏りのない個体の目

的関数値を入力として与えることで、これに対応する設計変数値を得ることが可能となる。

4. 提案手法

4.1 概要

本論文で提案する多目的GAとANNを併用するメカニズムは、少数個体での探索においても多様性を維持しながら解探索を行うことで、少ない評価計算回数により真のパレート最適解に近い解を導出することを目的としている。提案手法のアルゴリズムを以下に示す。

N : ANN 実行回数

t_{max} : 多目的GA の総実行世代数

t : 世代数 k : 非劣解の数

Step1: NSGA-II を $i \times t_{max}/N$ 世代まで行う。
($i = 1$)

Step2-1: 非劣解集合を求め、非劣解集合を通る直線を補間により求める。

Step2-2: 非劣解集合を学習データとして ANN で学習し、予測関数を作成する。

(入力: 目的関数値、出力: 設計変数値)

Step2-3: 非劣解の中で端以外になる個体を取り除き、ある目的関数において、隣接個体の距離が均等な $n - 2$ 個の目標個体を生成する。(n は非劣解の個数)

Step2-4: ANN により作成された予測関数を用いて、目標個体の目的関数値を導く設計変数値を求める。

Step2-5: ANN により得られた設計変数値を元に、真の目的関数で評価計算を行う。

Step2-6: ANN により得られた個体とアーカイブを合わせ、NSGA-II のアーカイブ更新メカニズムを適用する。この際のアーカイブサイズは、探索個体数とする。

Step2-7: 全体の終了条件を満たしていれば終了。満たしていないければ Step1 へ ($i = i + 1$)。

Step2-3 から **Step2-5** の補間による処理については、次節で述べる。

4.2 補間による個体の再配置

多目的GAによって導出された個体データを元に、ANNを用い学習を行うことで、目的関数の逆関数の近似関数を作成する。また、ANNの入力となる目標

個体の目的関数値の設定は、学習データに対する補間を用いて行う。この際に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。また、3 目的以上の問題に対しては、補間での目標個体の設定が難しいため、これは今後の課題とし、本論文では 2 目的問題を対象とする。補間処理の手順を以下に示す。

1. 多目的GAによって導出された個体の中で非劣解となるものののみを抜き出す。
2. 目的関数空間において、隣接する非劣解どうしを結ぶ直線を求める。(線形補間)
3. 目的関数 f_1 において、各個体間の距離が均等になるような f_1 値を各個体それぞれ求める
4. 求められた f_1 値に対応する f_2 値を、線形補間により求められた直線から求め、目標個体を定める。

処理のイメージを Fig. 3 に示す。Fig. 3 の左図では、GA により得られたパレート解が示されている。これを基に線形補間を行い、1 つの目的関数値が等間隔となるように目標個体が決定される。これが Fig. 3 の右図に示されている。

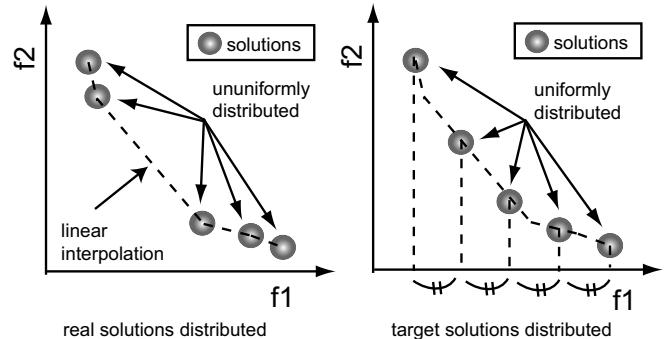


Fig. 3. 線形補間。

補間により求められた目標個体の目的関数値を、ANN の入力値として与えることで、これに対応する設計変数値を導出することができる。ただし、導出される設計変数値は、ANN で作成された近似関数を元に求められたものなので、近似誤差を含んでいる可能性がある。そこで、**Step2-5** でこの設計変数値を実際の目的関数で評価することで、真の目的関数値を得ることができる。つまり、近似を正確に行うことができていれば、目標個体に近い目的関数値を持った個体を導出できることになり、少数個体での探索においても多様性を維持した探索を実現することができる。

5. ANNによる多様性維持メカニズムの有効性

提案手法の有効性を検討するために、数値実験を行い議論する。

5.1 対象問題と評価手法

提案する多目的GAとANNを併用する手法は、1評価に時間を要するが関数としては比較的容易な実問題での利用を想定している。

そこで本実験では、提案手法の効果について検討を行うために、Debの考案した単峰性で、非凸のパレートフロントを持つ問題であるZDT6¹³⁾をテスト関数として用いた。テスト問題の式をTable 1に示す。

Table 1. テスト問題(ZDT6).

Problem	Functions
ZDT6	$\min f_1 = 1 - \exp(-4x_1) \sin^6(6\pi x_1)$ $\min f_2 = g \times h$ $g = 1 + 9[(\sum_{i=2}^n x_i)/9]^{0.25}$ $h = 1 - (f_1/g)^2$ $x_i \in [0, 1], n=2$

本実験では、各手法で求めた非劣解集合を評価する方法として目的関数空間における精度：優越個体割合(Ratio of Non-dominated Individuals)： I_{RNI})¹⁴⁾を用いる。

I_{RNI} は、2つの非劣解集合を比較し、相手に対して非劣である解の数を求める比較手法である。この手法では、精度に関する評価を行う。この手法は、Tanらによって用いられていた手法¹⁵⁾を2つの非劣解集合の比較へと拡張したものである。本手法の比較手順を以下に示す。

まず、2つの手法で得られた解集合 X と Y の和集合をとり S^U とする。次に、 S^U の中から、どの解にも優越されない解のみを選び出し、選ばれた解集合を S^P とする。そして、 S^P の各手法の割合を $I_{RNI(X,Y)}$ として導き出すというものである。Fig. 4に $I_{RNI(X,Y)}$ の例を示す。

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

5.2 アーカイブサイズの検討

多目的GAにおいて探索個体数が少數の場合、アーカイブサイズを探索個体数と同数とすると、良好な個

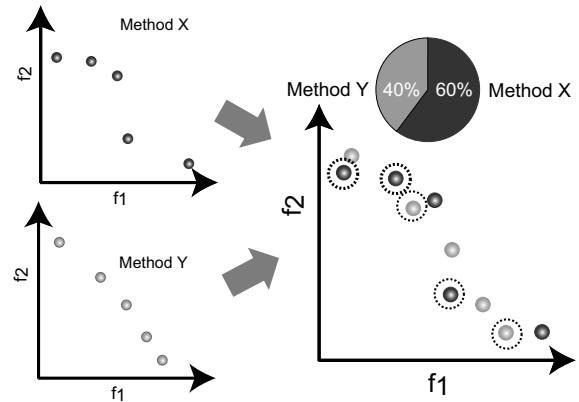


Fig. 4. 優越個体割合.

体が有効に活用されず破棄される恐れがある。そのため、予備実験として良好なアーカイブサイズについて検討を行う必要があると考えられる。そこで、6個体探索、アーカイブサイズ10のNSGA-IIに対する、アーカイブサイズ6, 20, 30, 50, 100としたNSGA-IIの性能の検証を行った。用いたパラメータをTable 2に示す。

Table 2. 5.2節検証実験におけるパラメータ.

母集団サイズ	6
最大世代数	60
アーカイブサイズ	6,10,20,30,50,100
トーナメントサイズ	2
次元数	2
交叉率	1.0
交叉方法	1点交叉
染色体長	20 × 次元数
突然変異率	1/染色体長
試行回数	30

5.1節で述べた評価手法を用いて、NSGA-IIの各アーカイブサイズについての探索結果を評価した。Fig. 5にRNIの結果を示す。

Fig. 5より、アーカイブサイズを探索個体数より大きい10とすることにより、RNIを向上させられていることを確認できる。しかし、アーカイブサイズ30以上においては、アーカイブサイズ10に対しては、同等もしくは劣る結果が得られた。これは、探索個体数に対しアーカイブサイズが大きすぎると、トーナメント選択を行う際に悪いランクのものが選ばれやすくなる

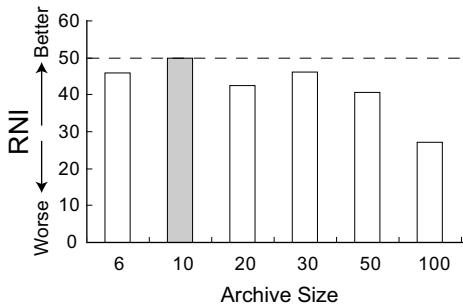


Fig. 5. アーカイブサイズ 10 に対する RNI.

ため、探索の進行に悪影響を与えていたからであると考えられる。このことより、探索個体数に対するアーカイブサイズは、2,3 倍程度を用いることが適切であるといえる。本実験では、Fig. 5 の結果より、アーカイブサイズ 10 のときが最も良好な結果を得られたため、これ以後の実験はアーカイブサイズ 10 として実験を進める。

5.3 ANN による多様性の向上の検討

ANN による多様性維持メカニズムを組み込んだ NSGA-II と従来の NSGA-II を比較し、その有効性について検証を行った。本節では、これらの実験結果を示す。用いた GA パラメータを Table 3 に、ANN パラメータを Table 4 に示す。

Table 3. 5.3 節検証実験における GA パラメータ.

母集団サイズ	6
アーカイブサイズ	10
最大世代数	60
次元数	2
ANN 導入回数	2
ANN 導入世代	20,40
試行回数	30

Fig. 6 の (a) に NSGA-II を実行した結果導出された非劣解を、Fig. 6 の (b) にそれらの非劣解を元に設定される目標個体を示す。そして、(b) の目標個体を元に ANN で導出された設計変数値を、実際に評価した結果得られた個体と、(a) のアーカイブ個体をあわせたものを、4.1 節に示した提案手法のアルゴリズムの **Step2-6** で処理を行う。その結果得られたアーカイブ個体を Fig. 6 の (c) に示す。

Fig. 6 の (a) と (c) を比較すると分かるように、ANN による多様性維持メカニズム適用後で、解の均等配置

Table 4. 5.3 節検証実験における ANN パラメータ.

入力層のニューロン数	2
出力層のニューロン数	2
中間層のニューロン数	30
中間層の層の数	1
最大学習回数	50000
学習係数	0.7
安定化係数	0.6
許容誤差	1.0e-04

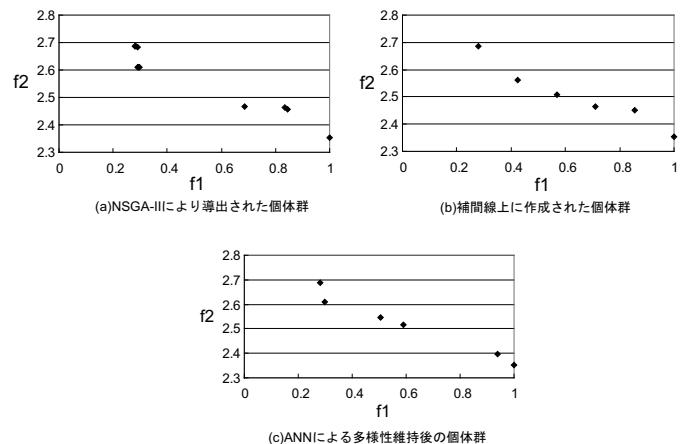


Fig. 6. ANN の学習データと目標個体群.

が実現できていることが確認できる。

次に、ANN と NSGA-II を併用して最終世代まで実行した結果得られた非劣解と、従来の NSGA-II を最終世代まで実行した結果得られた非劣解を比較して得られた RNI と 30 試行の各試行の非劣解の全プロット図を Fig. 7 に示す。また Hybrid と示されているのが提案手法、NSGA-II が NSGA-II のみで探索を行ったものである。用いたパラメータを Table 5 に示す。

Fig. 7 の結果から、ANN による多様性維持メカニズムを組み込んだ NSGA-II は従来の NSGA-II と比較して RNI が高いことが確認できる。また、ANN を用い多目的 GA における探索過程の多様性を維持することで、従来の NSGA-II に比べ、30 試行を行ったうちの多くの試行がパレート最適解領域に近い解を導出できているのが確認できる。

これらのことにより、少数個体での多目的 GA の探索過程に生じる多様性の低下を、提案メカニズムを用いることで解消し、多様性を維持した探索を行うことで、より少ない評価計算回数で真の最適解に近づくこ

Table 5. 5.3 節検証実験における各手法のパラメータ.

探索手法	Hybrid	NSGA-II
母集団サイズ	6	
最大世代数	60	61
評価計算回数	368	366
アーカイブサイズ	10	
次元数	2	
ANN 導入回数	2	なし
ANN 導入世代	20,40	なし
試行回数	30	

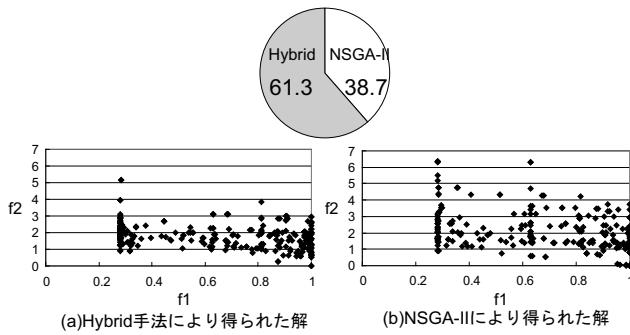


Fig. 7. 最終世代で得られた解(30 試行)と RNI.

とが可能であることが分かった。

5.4 多数個体探索との比較

これまで少數個体での探索についての検討を行ってきたが、従来の目標である、提案手法の多数個体探索に対する性能について検討を行う。

本実験では、ANNによる多様性の維持メカニズムを NSGA-II に組み込んだ手法を少數個体で探索を行う場合と、NSGA-II を従来の多数個体で探索を行う 2つの場合で比較を行った。なお、実験に用いたパラメータを Table 6 に示す。

得られた RNI と 30 試行の各試行の非劣解の全プロット図を Fig. 8 に示す。

Fig. 8 より、提案手法は少ない評価計算回数で、多数個体探索の NSGA-II と同等の性能を得られていることが確認できる。以上より、多目的 GA を少數個体で行う場合に、ANN を用いて多様性を維持しながら探索を行うことにより、多目的 GA の多数個体探索に対しても、少ない評価計算回数で良好な解を導出できることが分かった。

Table 6. 5.4 節検証実験における各手法のパラメータ.

探索手法	Hybrid	NSGA-II
母集団サイズ	6	100
最大世代数	60	8
評価計算回数	368	800
アーカイブサイズ	10	100
次元数	2	
ANN 導入回数	2	なし
ANN 導入世代	20,40	なし
試行回数	30	

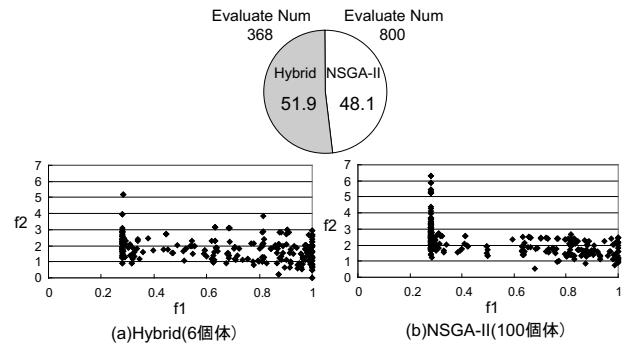


Fig. 8. 提案手法と多数個体探索の RNI.

6. ANN の近似と多峰性関数の検討

ANN による多様性維持メカニズムは、少數個体で多目的 GA を用いて探索を行った場合に、探索過程で低下する多様性を、多様性が向上するような目標個体を設定し、これを ANN によって導出することで復元するというメカニズムである。ただし、ANN による多様性維持メカニズムが有効に作用しない場合も考えられる。このメカニズムが、有効に働くない状況として以下の 2 つの場合が考えられる。

1. ANN による近似が適切に行われない場合
2. 多峰性の問題

本章では、この 2 つの状況についての検討を行う。

6.1 ANN による近似

ANN は多目的 GA によって導出された個体データを元に学習を行い、目的関数の逆関数の近似関数を作成する。そしてこの関数により、目標個体を導出するための設計変数を導出するという操作を行う。つまり目標個体を導出するためには、適切な近似関数が作成

されている必要があるが、その近似関数の精度は、多目的GAにより導出される個体データ（学習データ）に依存することになる。そのため学習データによっては、近似が適切に行われず目標個体と大きくずれた個体を導出してしまった場合があると考えられる。そこで、対象問題をZDT6、アーカイブサイズを6、他のパラメータをTable 3とし探索を行った。Fig. 9にその結果を示す。Fig. 9はFig. 6と同様に、a)がANN導入世代におけるNSGA-IIにより得られた非劣解であり、b)がa)を元に線形補間で定めた目標解、c)がANNにより実際に導出された解である。

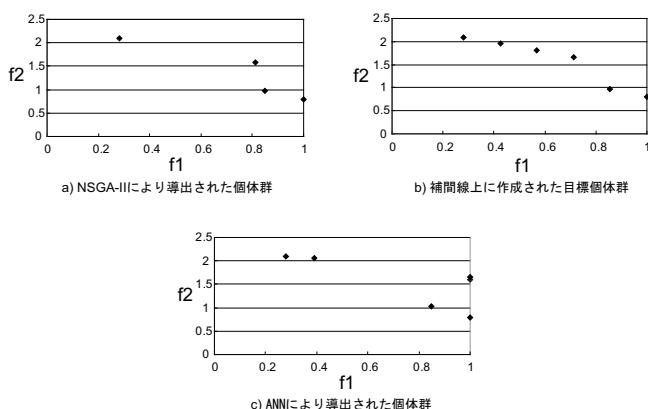


Fig. 9. 近似が適切に行われない例。

Fig. 9を見てもわかる通り、c)の実際に導出された解は目標解とは大きく外れた解となっている。これは、近似を行う対象となる面が比較的複雑な形状をしているにも関わらず、個体数が少なかったため近似が適切に行われなかつたからであると考えられる。前節では、アーカイブサイズを10~20とすることでこの問題を回避している。

6.2 多峰性の関数

多目的最適化問題の中には多くの多峰性の問題が存在する。多峰性の問題では、探索過程において局所解にはまることが多く、探索を滞りなく進めることは困難である。一方、本論文で提案する手法は、少数個体での多目的GAの探索過程において生じる多様性の低下をANNを用いることによって復元し、多様性を維持しながら解探索を進めるというものである。ここでの多様性とはパレートフロントに対する多様性を示しており、真のパレート解方向への多様性は考慮していない。しかし、多峰性の問題においては、少数個体探索に比べて多様性の維持がなされているにも関わらず、多数個体での探索においても真のパレート解方向

への多様性の欠如により、局所解にはまり探索が滞ることが少なくない。つまり、多峰性の問題においては、局所解と局所解の間の山を越えるメカニズムが重要になると考えられる。これは、今回提案する手法のメカニズムとは異なるものであるため、多様性の維持だけでは探索効率を向上させることは困難であると考えられる。これについて検討を行うために、Debの考案した多峰性で、非凸のパレートフロントを持つ問題であるZDT4¹³⁾をテスト問題として用いた。テスト問題の式をTable 7に示す。

Table 7. テスト問題 (ZDT4).

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

本実験では提案するANNによる多様性の維持メカニズムをNSGA-IIに組み込んだ手法を、Table 8に示すパラメータのもとで30回試行の数値実験を行った。

Table 8. 6.2節検証実験における各手法のパラメータ。

探索手法	Hybrid	NSGA-II
母集団サイズ		6
最大世代数		240
アーカイブサイズ	6,10,20,50,100	6
次元数		10
ANN導入回数	2	なし
ANN導入世代	80,160	なし

数値実験の結果のRNIをFig. 10に示す。また、 I_{cover} をFig. 11に示す。

Fig. 10とFig. 11より、アーカイブサイズが10や20のときは、アーカイブサイズが6のNSGA-IIに比べて被覆率が高いにも関わらず、RNIにおいては性能差が見られないことが確認できる。

以上より、本論文で提案する多目的GAに、ANNによる多様性維持を行うメカニズムを組み込んだ手法は、多峰性の問題であるZDT4においては解探索の進行を向上させる点においては、有効に作用しないことが分かった。これらのことから、以上の2つの状況下

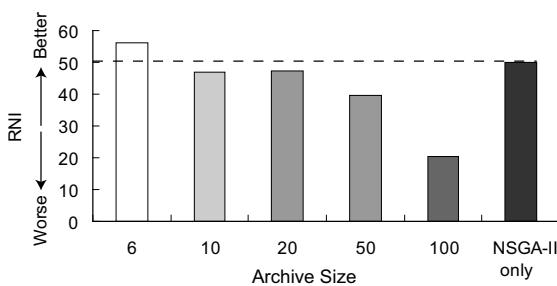
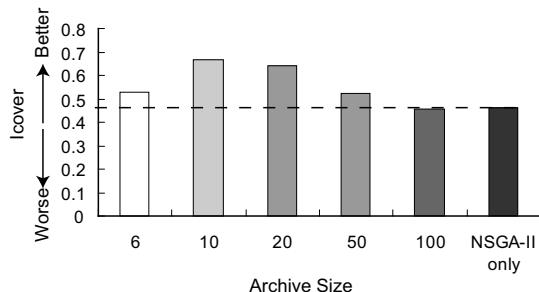


Fig. 10. RNI(ZDT4).

Fig. 11. I_{cover} (ZDT4).

においては、本論文で提案する、ANNによる多様性維持メカニズムが効果を発揮しないことがあるといえる。しかし、本論文で対象とする、関数としては複雑な問題ではないが、評価に時間を要するような問題に対しては、5.章で扱った単峰性の問題であるZDT6において良好な結果が得られていることから、提案メカニズムはこのような問題においては有効なメカニズムであると考えられる。

7. 終わりに

本論文では、少数個体で多目的GAを行う場合に、探索過程において低下する多様性を、ANNを用いることによって復元することで、多様性を維持した探索を実現するメカニズムを提案した。ANNによる多様性維持メカニズムは、多目的GAによって探索過程で得られる非劣解を元に、目的関数値から設計変数値を求める近似関数を作成することで、補間により求められる多様性がある目標個体を導出するという仕組みである。本論文で想定している問題は航空機を丸ごと設計するような問題や、自動車の衝突解析など評価に非常に多くの時間要有する問題である。そのため、ANNによる計算コストは評価時間に対して非常に小さいものとみなせるため、有効な手法であると言える。

本論文で対象としている関数としては複雑ではないが、評価計算に時間を要するような問題においては、非常に小さいものとみなせるため、計算コストをかけずに多様性維持を行う。

本論文では、まず予備実験として提案手法を用いる際のアーカイブサイズについての検討を行った。アーカイブサイズの検討においては、少数個体探索の場合は、アーカイブサイズを探索個体数より大きくとることにより、探索効率を向上させられるが、過大にアーカイブサイズを大きくすると、探索に悪影響を及ぼすことが分かった。このことより、少数個体で多目的GAの探索を行う場合において、アーカイブサイズは探索個体数の2,3倍程度大きくとった状況下で用いることが最も探索を進める有効な方法であると考えられる。また、予備実験により得られたアーカイブサイズを用い、ANNによる多様性維持メカニズムを、代表的な多目的GA手法であるNSGA-IIに組み込み、テスト関数を用いてその有効性について検討を行った。数値実験の結果、ANNを用いた提案手法は、従来手法に劣らない探索性能を示し、多数個体で従来手法での探索に対しては、少ない評価計算回数で優れた解を導出することができることを確認した。

なお、ANNによる多様性維持メカニズムは、近似が適切になされないときや、多峰性の問題においては有効性を確認できていないため、今後これらの課題について取り組んでいく必要がある。また、2次元以上の場合の補間の検討、提案手法を実問題に適用し検討することも今後の課題とする。

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) D. E. Goldberg. *Genetic Algorithms in search, optimization and machine learning*. Addison-Wesley, 1989.
- 3) A. Todoroki. Response surface method, <http://florida.mes.titech.ac.jp/responsesurface.pdf>.
- 4) Y. Kounoe and K. Fujita. Third-order polynomial response surface with optimal selection of interaction terms for global approximation. In *Design and Systems*, Vol. 15, pp. 31–34.
- 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, S. Agrawal, A. Pratab, 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.
- 7) T.Sirai, M.Arakawa, and H.Nakayama. Application of rbf network in approximate optimization in satis-ficing method. In *Design and Systems*, pp. Vol14th page85–86, 2004.
 - 8) S.F.Adra, I.Hamody, I.Griffin, and P.J.Fleming. A hybrid multi-objective evolutionary algorithm using an inverse neural network for aircraft control system designa. *2005 IEEE Congress on Evolutionary Computation (CEC'2005)*, Vol. 1, pp. 1–8, 2005.
 - 9) A.G.Cunha and A.Vieira. A hybrid multi-objective evolutionary algorithm using an inverse neural net-work. 2004.
 - 10) J.Henseler. Back propagation. *Lect Notes Comput Sci*, Vol. 931, pp. 37–66, 1999.
 - 11) C.Bishop. Neural networks for pattern recognition. *Oxford University Press*, 1997.
 - 12) L.Bull. On modelbased evolutionary computation. 1999.
 - 13) K. Deb and T. Meyarivan. Constrained test prob-lems for multi-objective evolutionary optimization. In *KanGAL report 200005, Indian Institute of Tech-nology, Kanpur, India*, 2000.
 - 14) J. D. Knowles and D. W. Corne. Approximating the nondominated front using the pareto archived evolution strategy. Vol. 8, pp. 149–172, 2000.
 - 15) K.C.Tan, T.H.Lee, and E.F.Khor. Increament-ing multi-objective evolutionary algorithms: Perfor-mance studies and comparisons. In *First Interna-tional Conference on Evolutionary Multi-Criterion Optimization*, pp. 111–125, 2001.