

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遺伝的アルゴリズム

廣安 知之^{††}, 小林 賢二[†], 三木 光範^{††}

[†] 同志社大学大学院 ^{††} 同志社大学工学部

近年多目的 GA の実問題への適用が盛んに行われている。しかし、実問題のような複雑な問題では、GA の高い評価計算コストが問題となる。そこで、評価計算コストを軽減する方法として少数個体での探索がある。しかし少数個体での探索は、探索過程において多様性の縮小が起きるといった問題が存在する。そこで本論文では、ニューラルネットワーク (Neural Network:NN) を利用することにより、探索過程における多様性の縮小を軽減し良好な精度を持ったパレート最適解を導出するアルゴリズムを提案する。提案手法を代表的な多目的 GA 手法である NSGA-II に組み込み、テスト関数を用いて探索に及ぼす影響について検討を行った。数値実験の結果、提案手法は NSGA-II に劣らない探索性能を示した。また、多数の探索個体を用いた探索と比べた場合においても、同様に良好な解精度を持った非劣解集合を得ることができた。

Mechanism of Genetic Algorithm for maintaining the solution diversity using Neural Network

Tomoyuki HIROYASU^{††}, Kenji KOBAYASHI[†], and Mitsunori MIKI^{††}

[†] Graduate School of Knowledge Engineering, Doshisha University

^{††} Faculty of Engineering, Doshisha University

In recent years, multi objective Genetic Algorithms is applied to many real-world problems. One of the defects of GAs is high calculation cost for evaluation values of objective functions such as in solving complex problem. One of the effective method which is to decrease the computational cost is to search solutions using small number of individuals. However, in this approach, there is problem that while searching the most optimization solutions, the diversity is shrunked. In this thesis, algorithm which is to generate pareto solutions that have better evaluation values of objective functions than using ordinary multi objective GA is proposed by restraining the diversity shrunked using Neural Network. The effectiveness of this algorithm is examined through the test functions where this algorithm is applied to NSGA-II. The result showed that NSGA-II with NN has the same searching ability as NSGA-II and NSGA-II with NN found the solutions that have better evaluations values of objective functions.

1 はじめに

世の中に存在する最適化問題の中には、複数の評価基準を有する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手法が一般的に用いられる。そのため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) が用いられることが多い。しかし GA は多くの評価計算回数を必要とするため、一度の評価計算に

時間を要するような問題においては、数多くの個体を探索に用いることは実用であるとはいえない。そこで、少数個体での探索方法が必要となる。本論文では、多目的 GA で探索を行う際に探索過程で生じる多様性の縮小を、ニューラルネットワーク (Neural Network:NN) を利用することにより軽減し、良好な精度を持ったパレート最適解を導出するアルゴリズムを提案する。また、多目的 GA の代表的な手法である NSGA-II に組み込むことによって、その効果と探索への影響について検討を行う。

2 多目的最適化

2.1 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。代表的な多目的 GA の手法である NSGA-II¹⁾ は、良好な精度と多様性を持ったパレート最適解を導出できると報告されている。

2.2 多目的遺伝的アルゴリズムの問題点

多目的 GA は、一度に良好なパレート最適解を求めることができるが、評価計算コストが高いという問題点も存在する。これは、1 回の評価計算に時間を要する実問題のような最適化問題においては、大きな問題となる。そこで評価計算コストを削減する方法として、少数個体による探索が考えられる。しかし従来の多目的 GA 手法での少数個体探索は、探索過程において多様性の縮小が起こり、適切な探索が行われないという問題がある。本論文では、多目的 GA の探索過程において生じる多様性の縮小を、NN を利用することにより改善し、良好な精度と多様性を持ったパレート最適解を導出することを目指す。

3 提案手法

3.1 概要

多目的 GA の少数個体探索の際に生じる、探索個体の多様性の縮小を軽減するためには、偏りを生じた探索個体を偏りの少ない状態に再配置し、配置された目標個体集合を導出できればよい。また、精度を向上させるために、探索個体の再配置は非劣解集合を元に作成した補間曲線上に探索個体を並びかえることにより行う。上記の処理のイメージを図 1 に示す。




図 1: 探索個体の再配置

配置された目標個体を導出するためには、目標

個体が有する目的関数値を導出することが必要となる。しかし、従来の手法は設計変数値を元に目的関数値を求めるものであり、目標とする目的関数値の導出することは困難である。そこで本手法では、NN を用いることにより目的関数値を元に設計変数値の導出を行う。

3.2 NN による目標個体の導出

NN は、既知の数点のデータを元に関数の近似を可能とする情報処理システムである。NN は、ある入力とその入力に対する出力が既知である数パターンのデータを元に学習を行うことで、未知の入力に対する出力の推測を行う。学習のイメージを図 2 に示す。




図 2: NN による未知関数の推測

本手法では、NSGA-II などの多目的 GA によって求められる非劣解集合を持つ、設計変数値を入力、目的関数値を出力として学習を行うことにより、目的関数の逆関数の近似を行う。これにより、多目的 GA の後に、偏りが少ない状態に再配置された図 1 のような個体の目的関数値を出力する設計変数値を求める。学習のイメージを図 3 に示す。




図 3: NN による再配置個体の導出

3.3 提案手法のアルゴリズム

本論文では、NN を利用することにより探索過程において生じる多様性の縮小を軽減するアルゴリズムの提案を行う。以下に、提案手法のアルゴリズムの流れを示す。

N_A : 探索個体数

NN_A : ニューラルネットワーク実行回数

t_{max} : 総実行世代数

t : 世代数 k : 非劣解の数 $i = 1$

Step1: NSGA-II を $i \times t_{max}/NN_A$ 世代行う。

Step2: 非劣解集合を求め、非劣解集合を通る補間曲線を作成する。

Step3: 非劣解集合を学習データとして NN 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)

Step4: 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。

Step5: NN 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。

Step6: NN 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。

Step7: 全体の終了条件を満たしていれば終了。NN 終了条件を満たしていれば Step1 ($i = i + 1$)。満たしていなければ Step2 へ。

NN により作成される予測関数の正確性は学習データ数に依存するため、常に正確な予測関数は困難である。そのため、Step6 において NN で得られた設計変数値を元に目的関数値の計算を行うことにより、真の目的関数値を導出する必要がある。

4 数値実験

4.1 実験概要

本実験では、多目的 GA の探索過程において NN 処理を組み込んだ本手法の効果について検討を行う。対象問題には、Zitzler らの数値実験に使用された 2 目的最適化問題である ZDT-4 を取り扱った。なお、用いた GA パラメータを表 1, NN パラメータを表 2 に示す。

また得られた非劣解集合を評価する方法には様々なものが存在するが、本研究では以下に示す評価方法を用いる。

1. 被覆率 (cover rate: I_{cover})²⁾
2. 優越個体割合 (Ratio of Non-dominated Individuals: RNI)³⁾

表 1: GAPParameters

母集団サイズ	10
最大世代数	240
交叉率	1.0
交叉方法	一点交叉
染色体長	20 × 次元数
突然変異率	1/染色体長

表 2: NNParameters

NN 実行回数	3
最大学習回数	50000
許容誤差	0.01

4.2 実験結果

NN 処理を組み込んだ NSGA-II と従来の NSGA-II の比較を行い、その結果得られる個体群の多様性や精度について検討を行った。

まず、探索個体数を 10 個体として、得られた I_{cover} の値を図 4 に示す。左は提案手法における NN 適用前、右は提案手法における NN 適用後である。




図 4: 提案手法による I_{cover} の変化

図 4 の結果から、提案手法では NN を用いての探索個体の再配置が適切に行われず、再配置前の探索個体と比べると、同等の性能もしくは劣る性能を示すことがわかった。また、この際の RNI の値を図 5 に示す。左が提案手法で右が通常の NSGA-II である。




図 5: 提案手法の RNI と NSGA-II の比較

図 5 の結果より、提案手法のアルゴリズムでは

従来手法と比較して良好な結果を得られないことがわかった。しかし、これは図 4 の I_{cover} の結果からも分かるとおり、NN により偏りの少ない適切な個体の導出を行うことができていないことによるものであると考えられる。この場合 NSGA-II で処理を終了する場合と比較して、最終的な処理に NN を入れることにより導出される解にパレート最適解ではない劣解が含まれる可能性が高くなる。よって、3.3 節で提案したアルゴリズムにおいて終了世代においてのみ NN 処理を行わないという制約を設けることで、最終処理を NSGA-II で終了するようにし、同様の実験を行った。

まず、改良版提案手法と従来の NSGA-II の I_{cover} の比較を図 6 に示す。左が改良版提案手法、右が従来の NSGA-II である。




図 6: 改良版提案手法と NSGA-II の I_{cover} 比較

図 6 の結果より、改良版提案手法のアルゴリズムでは最終世代において NN 処理を行わないため、共に最終処理は NSGA-II となり I_{cover} の値は、ほぼ同等の値を示したことが分かる。また、この際の RNI の値を図 7 に示す。左が改良版提案手法で右が通常の NSGA-II である。




図 7: 新提案手法の RNI と NSGA-II の比較

図 7 の結果より、改良版提案手法は従来の NSGA-II に比べて RNI に優れていることが分かる。これは、NN 処理を行う前と行う後で多様性を有した非劣解を数多く得られるわけではないが、局所解に収束した個体群を局所解から脱出させる点において一定の効果が得られることが分かった。

次に、改良版提案手法の探索個体数を 10 個体、NSGA-II を 10 個体として RNI の比較を行った。図 8 に比較した RNI を示す。また、評価計算回数は前者が 2448 回、後者が 3500 回である。

図 8 の結果より、本手法は NN を最終処理に用




図 8: 新提案手法 (10 個体) と NSGA-II(100 個体) の比較

いない場合、多数個体探索の場合と比べても良好な解探索精度を持った個体を導出できることが確認された。

5 今後の課題

現在のアルゴリズムでは、図 4 の結果のように、NN 処理を行うことによる被覆率の向上が行われていないため、NN 処理が十分に作用しているとはいえない。よって今後、NN 処理により被覆率が向上するような改良を本手法に行う必要がある。また、NN 実行回数や探索個体数に関する検討についても進めていく必要がある。

6 終わりに

本論文では、多目的 GA で探索を行う際に探索過程で生じる多様性の縮小を、NN を利用することにより軽減し、良好な精度を持ったパレート最適解を導出するアルゴリズムを提案した。数値実験の結果、多目的 GA の全探索終了後に NN 処理を導入した場合は、多目的 GA のみを用いて探索を行った場合に比べて解探索精度は悪化することが分かった。しかし、解探索途中においてのみ NN 処理を導入することによって、多目的 GA のみを行った場合より解精度を向上させることができた。また評価計算回数が少ない場合は、多数個体で探索を行った場合と比べても良好な解精度を持った個体を得ることができた。

参考文献

- 1) Amrit Pratab Kalyanmoy Deb, Samir Agrawal 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.
- 2) 比屋根. 並列遺伝的アルゴリズムによる多目的最適化問題のパレート最適解集合の生成法と定量的評価法. 第 9 回自律分散システムシンポジウム, pp. 295-300, 1997.
- 3) K.C.Tan, T.H.Lee, and E.F.Khor. Incrementing multi-objective evolutionary algorithms: Performance studies and comparisons. In *First International Conference on Evolutionary Multi-Criterion Optimization*, pp. 111-125, 2001.