

遺伝的アルゴリズムにおけるランドスケープによる問題のクラス分類

Classed Problems by Landscape of Genetic Algorithms

正 廣安 知之 (同志社大工) 正 三木 光範 (同志社大工)
学 赤塚 浩太 (同志社大院)

Tomoyuki HIROYASU, Doshisha University, tomo@is.doshisha.ac.jp
Mitsunori MIKI, Doshisha University, Tatara Miyakodani 1-3, Kyo-Tanabe, Kyoto
Kouta AKATSUKA, Graduate School of Engineering, Doshisha University

In Genetic Algorithms (GAs), design variables of candidate solutions are encoded to binary strings. Therefore, the landscape where GAs are searching may be different from the landscape that we recognize. In this paper, we propose a method that help us to understand the landscape of the problems that GAs are searching. In this method, the landscape is shown with hamming distance, fitness values and frequency. This method can apply to continuous optimization problems. By applying the proposed methods to some test functions and designing truss structure problems, it was found that we can recognize the difficulty and the characteristics of the problems by this method.

Key word: Genetic Algorithms, Landscape, Hamming Distance, Hardness, Fitness

1 はじめに

最適化問題を遺伝的アルゴリズム (Genetic Algorithms: GA) で探索する際, その問題の最適解を GA によって求めやすいか否かということは非常に重要な問題である. しかし, GA では通常設計変数の値をコード化して探索を行うため, 我々が把握している対象問題の解空間とはまったく異なった空間を探索していると考えられる. それに対して, GA が探索している解空間を把握するための試みとして, 内藤¹⁾の研究などがあげられる. しかし, これらの研究は離散問題を主にその対象としているため, 解の精度が大きく影響する連続問題には不向きである. そこで本研究では連続問題を対象とする手法を検討する.

2 ハミング距離, 適合度, 頻度によるランドスケープの表示

GA が現在探索を行っている空間を把握するため, ハミング距離, 適合度, 頻度によりランドスケープを表示する手法を提案する. また, 対象問題全体のランドスケープでは精度が粗くなり探索状況の把握ができないため, その世代における GA のエリートと真の解の間の空間を表示するに個体を生成しその分布を観察する. ただし, コード化された空間を把握するため, エリートのビットを 1 ビットづつ真の解に近づける方法で, 個体を生成する. 具体的な手順を以下に示す.

1. エリート個体中, 全長の L ビットのうち最適解と値が異なる m ビットを抽出し, m ビット中ラ

ンダムに n ビットを最適解と同じにする.

2. 1 の操作を 400 回行い, 400 個体生成する. その際同じ個体の生成も許す.
3. エリート個体の適合度と最適解の適合度の間を等間隔に 10 分割する.
4. 2 で生成した 400 個体の適合度が, 3 で分割した適合度中どこに当てはまるかを計算する.
5. 10 分割された適合度のそれぞれに何個体存在するかを頻度とする.
6. n を 1 からエリート個体と最適解のハミング距離として, 以上の操作を繰り返す.
7. x 軸に適合度, y 軸に n , z 軸に頻度を用いてグラフ化する.

GA では, ハミング距離が現在のエリートと近い点から徐々に真の解と近い点に個体が生成されると考えられるが, この際適合度値が現在のエリートより悪い個体は生き残る可能性が少ない. そのため, 現在のエリートと真の解の間に谷がある問題では, GA による探索では真の解に到達しにくいといえる.

3 数値実験

提案手法の性能を検証するため, 数値実験を Rastigrin 関数, Rosenbrock 関数で行った.

$$f(x_1, \dots, x_n) = 10n + \sum_{i=1}^n [x_i^2 - 10\cos(2\pi x_i)] \quad (1)$$

$$-5.12 \leq x_i < 5.12$$

$$f(x_1, \dots, x_n) = 100 \sum_{i=2}^n (x_{i-1} - x_i^2)^2 + (1 - x_i)^2 \quad (2)$$

$$-2.048 \leq x_i < 2.048$$

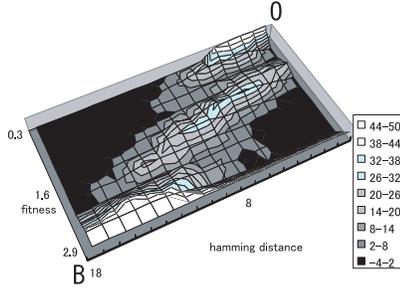


Fig.2 Rastrigin

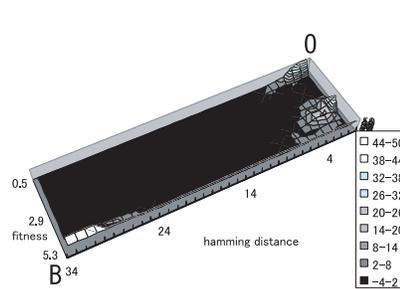


Fig.3 Rosenbrock

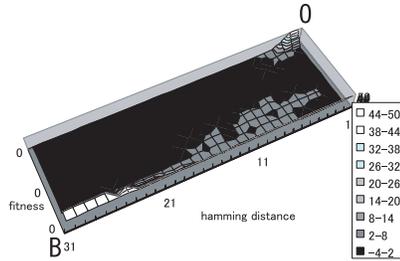


Fig.4 Truss structure (Type1)

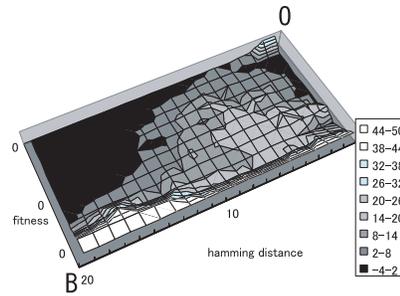


Fig.5 Truss structure (Type2)

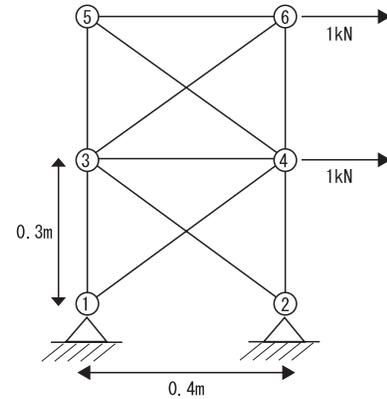


Fig.6 10-member truss structure

Rastrigin 関数は式 (1) で表される関数で、GA 向きの関数とされ比較的簡単に解を求めることができるとされている。一方、Rosenbrock 関数は式 (2) で表される関数で、GA で解くのは非常に困難とされている。Fig.2, Fig.3. に GA で 100 世代探索を行った後に提案手法を適用した結果を示す。なお、グラフ中 x 軸に真の解からの Hamming 距離を、y 軸に適合度を、z 軸に頻度を用いている。また、左手前 B 点が各世代でのエリート個体、右奥 O 点が真の解となる。Rastrigin 関数ではエリートから真の解まで個体が連続して分布しているのに対し、Rosenbrock 関数ではエリートと真の解の間に個体が分布していない領域がある。つまり、Rastrigin 関数は GA による探索が比較的容易であり、Rosenbrock 関数は探索が困難であると考えられる結果が得られた。

4 トラス構造物最適化問題

提案手法が有効であることをさらに確認するために、トラス構造物の総体積を、複数の制約条件下で最小にするトラス構造物最適化問題に適用した。対象問題は Fig.6 に示す 6 接点 10 部材のトラスであり、制約条件として 6 番接点の x 方向変位が 0.006m 以下であること、各部材の引張応力が 40MPa 以下であること、圧縮座屈が生じないことを用いた。設計変数は各部材の断面積である。Fig.4 が GA で 100 世代探索を行った後に提案手法を適用した結果である (Type1 と表示)。また、Fig.5 は問題を簡単にするために、制約条件を変位制約のみとした場合の結果である (Type2 と表示)。なお、トラス構造物最適化問

題では真の解が未知である為、予備実験によって求められた準最適解を真の解として、提案手法を適用している。これらを見ると、制約条件が 3 つある通常の問題では、Rosenbrock 関数のように真の解とエリート個体の間に大きな谷があり、GA による探索は比較的困難であると思われる結果が得られた。一方、簡単にするために制約条件を 1 つにした問題では、エリートと真の解の間の領域に個体が多く分布し、探索が比較的容易であると思われる結果が得られた。

5 おわりに

GA の探索空間を把握するための手法を提案し、Rastrigin 関数と Rosenbrock 関数で数値実験を行った。その結果、GA が得意な問題とされる Rastrigin 関数では探索が容易と考えられる結果が得られ、GA が不得意な問題とされる Rosenbrock 関数には探索が困難と考えられる結果が得られた。さらに、実問題への適用例として難易度の異なるトラス構造物最適化問題を対象に実験を行ったところ、それぞれの難易度に応じた結果が得られ、提案手法の有効性が示された。今後は本手法を基に、対象問題に応じた最適な GA アルゴリズムやパラメータを決定するシステムを構築する。

参考文献

- 1) Ken NAITOU. Four-group equation of genetic algorithm. *JSME International Journal*, Vol. 38, No. 2, 1995.