

誤差逆伝播法を用いたニューラルネットワークにおける NK ランドスケープの近似

大島 直人[†] 片田 喜章 (摂南大学)

Approximation of NK Fitness Landscape by Neural Networks with Back Propagation

Naoto Ohshima[†], Yoshiaki Katada (Setsunan University)

Abstract: One of the advantages of evolutionary computations over other approaches in metaheuristics would be its parallel population search. Due to the population search, it takes a long time to evaluate an entire population in certain problems. Thus, such techniques as to shorten the time have been required. In this study, we conduct a series of computer simulations with the NK fitness functions, tunably rugged landscapes, in order to investigate whether neural networks with back propagation can approximate those functions according to the degree of ruggedness.

キーワード：関数近似，適応度関数，遺伝的アルゴリズム，誤差逆伝播法

(Function approximation, Fitness function, Genetic algorithm, Back propagation)

1. はじめに

遺伝アルゴリズム (GA) などの進化計算で個体の適応度を計算するためには、膨大な計算時間が必要となる。この問題に対し、RBF ネットワークと応答曲面法を用いて適応度関数を推定し、近似モデル上での近似最適解の探索を効率よく行う研究が多く行われている[1][2][3]。RBF ネットワークでは、入力値として連続的な変数を扱い、ガウス関数の重ね合わせとして出力を得る。しかし、ビットストリングを用いる GA では設計変数は 0 または 1 の 2 値をとるため、RBF ネットワークは GA の適応度推定に適さないと考えられる。

本研究では、近年さまざまな分野で応用されているシグモイド関数と誤差逆伝播法[4]を用いたニューラルネットワークの関数近似能力に着目する。誤差逆伝播法を用いて、あらかじめ入力データ(設計変数)とそれに対応する教師データ(適応度)を用意

し、最急降下法により出力値と教師データとの誤差が小さくなるように結合荷重を繰り返し修正し近似を行う。これにより、GA における個体の適応度を推定することが可能になる。しかしながら、適応度景観の形状が進化計算のパフォーマンスに影響を与えるように、誤差逆伝播法による適応度関数の近似能力および汎化能力にも影響を与えると予想される。そこで本研究では、進化計算分野で適応度景観の形状を調節できるテスト関数として広く利用されている NK ランドスケープ[5]の適応度近似を行う。そして景観の形状がどのように近似能力に影響を与えるかを調べる。

2. NK ランドスケープ

NK ランドスケープ[5]は適応度景観の特徴量である凹凸を調節できるという特徴をもつテスト関数である。景観パラメータとして遺伝子長 N およ

び遺伝子間のエピスタシス(連関)数 $K (< N)$ をもつ. K が大きくなると適応度地形を表す凹凸が増し, $K = N - 1$ のとき, 凹凸が最大となる.

適応度はビットストリングで表わされた遺伝子型に対して以下のように計算される. i 番目の遺伝子座の適応度に対する貢献値 v_i は $0 \leq v_i < 1$, $i = 1, \dots, N$ の範囲の実数としてランダムに生成される. 1 つの遺伝子型の適応度 V は各遺伝子座の貢献値を平均してつぎのように得られる.

$$V = \frac{1}{N} \sum_{i=1}^N v_i \quad (1)$$

3. 誤差逆伝播法を用いた適応度関数近似

3.1 計算機実験設定

景観パラメータは $N=10$, $K=\{0,1,3,5,7,9\}$ と設定する. この場合, 遺伝子型空間(設計変数空間)のサイズは $2^{10}=1024$ となる. したがって, 10 ビットの遺伝子を入力データとし, その適応度((1)式により計算)を教師データとする.

上述の 1024 個のデータのうち, 900 個を入力データとする. 学習上限回数 5000 回, BP の学習係数を 0.6, 中間層数 1 とする. 逐次修正方式を用いて, 隠れ層ユニット数を $N_h=\{1,2,3,4,5\}$ と変化させて実験を行う. ただし, 各 N_h に対し, 入力データ

(900 個)の組み合わせを変更したものを 10 セット用意する. このデータセットおよび N_h のそれぞれに対し, 初期結合荷重値を変えた BP の試行を 10 回行う.

3.2 計算機実験結果

図 1-5 に K を 0 から 9 まで変化させた場合の学習回数に対する 2 乗誤差の推移を示す. どの N_h においても学習回数 2000 回以内で誤差がある程度に収束している. さらに最終学習回数での各 K による誤差を比較すると, K が増加するにつれて誤差が増加することが確認できる. これは K の増加に対応して BP による探索において局所解に陥る傾向が増すことによると考えられる. しかし, $N_h=\{1,2\}$ では $K=5$ の場合は $K=7$ の場合よりも誤差が大きくなるという例外も存在する.

つぎに, 図 6-11 に各 K に対して N_h を変化させた場合の 2 乗誤差の推移を示す (ただし, 各 N_h に対して誤差の推移を明確にするため, 図 1-5 よりも縦軸のスケールを拡大している). 各 K における近似誤差は, N_h が増えると減少していることが確認できる. また図 1-5 では, 誤差は収束しているように見えるが, 詳細に調べると, K が大きくなるほど ($K \geq 3$), または, N_h が増えるほど ($N \geq 4$), 誤差は徐々に減少していることがわかる.




図 1 各 K に関する 2 乗誤差の推移 ($N_h=1$)




図 2 各 K に関する 2 乗誤差の推移 ($N_h=2$)




図 3 各 K に関する 2 乗誤差の推移 ($N_h = 3$)




図 4 各 K に関する 2 乗誤差の推移 ($N_h = 4$)




図 5 各 K に関する 2 乗誤差の推移 ($N_h = 5$)




図 6 各 N_h に関する 2 乗誤差の推移 ($K = 0$)




図 7 各 N_h に関する 2 乗誤差の推移 ($K = 1$)




図 8 各 N_h に関する 2 乗誤差の推移 ($K = 3$)




図 9 各 N_h に関する 2 乗誤差の推移 ($K = 5$)




図 10 各 N_h に関する 2 乗誤差の推移 ($K = 7$)




図 11 各 N_h に関する 2 乗誤差の推移 ($K = 9$)

4. おわりに

本研究では、BP を用いたニューラルネットワークにより NK ランドスケープを近似し、エピスタシス数の増加による適応度を計算機実験によって調べた。その結果、エピスタシス数の増加により誤差が増加する傾向を確認した。これはエピスタシス数の増加に対して BP の探索が局所解に陥ることを示す。また、 N_h を増やすと近似誤差は減少することを確認した。

今後、本実験で得られたニューラルネットワークの汎化能力を検証する。また、NK ランドスケープにおける次元(N の値)や、中間層数とそのユニット数を増やして実験を行いたい。さらに、GA による探索中にどのように教師データを随時追加していくかについて検討していく。

参考文献

- [1] 小野, 岡本, 小塚, 平田: 半径の最適化をとまなうラジアル基底関数ネットワークを用いた最適化, 第 20 回インテリジェント・システム・シンポジウム講演論文集, No.87 (2010)
- [2] 苗村, 下山, 鄭, 大林: 強非線形関数のための Kiring/RBF ハイブリッド応答曲面の提案法, 第 6 回進化計算フロンティア研究会資料集, pp. 142-147 (2011)
- [3] 北山, 安田, 山崎: RBF ネットワークと Particle Swarm Optimization による統合的最適化, 電気学会論文誌 C, Vol.128, No.4, pp. 636-645 (2008)
- [4] D. E. Rumelhart: *Backpropagation: Theory, Architectures, and Applications*, Lawrence Erlbaum Associate Publishers (1995)
- [5] S. A. Kauffman: *The Origins of Order*, Oxford University Press (1993)