

# 区間入出力ニューラルネットの進化的学習

## Evolving Feedforward Neural Networks with Interval Inputs and Interval Outputs

成田 圭我 岡田 英彦  
Keiga Narita Hidehiko Okada

### 1. はじめに

これまでに、3 層階層型ニューラルネット(NN)の学習用データとして実数データではなく区間データが与えられた場合の学習方法として、バックプロパゲーション法(BP)[1]を拡張した方法が提案されている[2]。一方、ニューラルネットの学習に進化計算アルゴリズム(EA)[3]を用いる「ニューロエボリューション(NE)」[4]の研究も進んでおり、NE が BP より優れることを示した研究も報告されている[4]。しかし、従来の NE の研究では、区間入出力データの学習は試みられていなかった。

そこで本研究では、学習用データが区間入出力データであっても NN を進化的に学習させることができるのか、実験によって評価する。さらに、区間入出力データを用いた NN 学習の有用性を期待できる応用の例として、ビッグデータ解析への応用を想定した実験を行う。

### 2. 区間データを用いた NE

#### 2.1 実験で用いる区間入出力データおよび NN

学習用データの例として、図 1 に示すような区間入出力データが与えられたとする。このデータの次元数は入力・出力ともに 1 であり、データの個数は 5 である。




図 1: 実験で用いる区間入出力データの例

学習用データの入力・出力がともに 1 次元のため、本実験で用いる NN のユニット数は、入力層・出力層ともに 1 個とする。また、中間層ユニット数は 10 個とした。

#### 2.2 NE の方法および結果

本実験では、EA のなかで代表的な遺伝的アルゴリズム(GA)[5]および進化戦略(ES)[6]を用いて NE を試みた。GA は、個体数：10，世代数：100,000，エリート保存数：1，トーナメントサイズ：4，交叉手法：ブレンド交叉[7] (=1.0)，突然変異率：1%とした。また ES は、個体数および戦略：(10+10)-ES，世代数：100,000，摂動量：[-0.1, 0.1] 一様乱数とした。つまり、GA・ES いずれにおいても 1 回の試行で合計 1,000,000 個の NN が生成される。また、解の

定義域はすべての結合強度・しきい値において[-10.0, 10.0]とし、それらの初期値(解の初期集団における結合強度およびしきい値)は[-0.5, 0.5]の一様乱数によって決定した。

進的に生成された 1,000,000 個の NN のうち誤差最小の NN が、学習用データの区間入力に対して出力した区間を図 2 に示す。5 個の学習用データのうちの中央のデータにおいて誤差が相対的に大きいが、いずれのデータにおいても NN の出力区間は学習用データが示す目標区間と類似していることがわかる。なお、図 2 は GA の結果であるが、ES の結果も概ね同様であり、誤差の値は GA： $2.0 \times 10^{-3}$ ，ES： $2.8 \times 10^{-3}$ であった。




図 2: GA で進的に学習させた NN の区間出力

また、図 2 の出力に用いた誤差最小の NN の、実数入力値 0.0 ~ 1.0 に対する実数出力値を図 3 に示す。学習後の NN は、学習用データが存在する領域を滑らかに通過するような関数となったことがわかる。




図 3: GA で進的に学習させた NN の実数入出力関数

### 3. ビッグデータ解析への応用を想定した実験

近年、ビッグデータを対象としたデータマイニング技術の研究開発が盛んに行われている。ここで、そのデータマイニング手法として NN を応用する場合、学習用データの数が多くなるほど NN 学習のコストも増大する。そこでこ

のコストを低下させるために、学習に用いるデータの数を減らすことが考えられる。

簡単な例として、図 4 に示すようなデータが得られているとする。入力・出力の値はいずれも実数で、次元数はともに 1 である。ここで、NN を用いてこれらのデータの背後にある入出力関数をモデル化したいが、すべてのデータを学習に用いるのは困難であると仮定する。そこで、学習に用いるデータの数を減らすために、入力値の定義域を  $N$  等分し、

(方法 A)  $N$  等分されたそれぞれの範囲に存在するデータを 1 件ずつランダムにサンプリングして学習に用いる、

(方法 B)  $N$  等分されたそれぞれの範囲に存在するデータすべてを 1 つの区間入出力データに「群化」して学習に用いる、

という 2 つの方法を考える。ここで方法 B の場合、 $N$  等分された個々の範囲に含まれるデータの入力値の最小・最大値を  $input^L, input^U$ 、出力値の最小・最大値を  $output^L, output^U$  とすると、当該の範囲に含まれるデータを群化した区間データは、入力区間が  $[input^L, input^U]$ 、出力区間が  $[output^L, output^U]$  のデータとする。方法 A・B いずれの場合も、学習に用いるデータの数は  $N$  個で共通となるが、方法 A の場合はそれらが元のデータと同じ実数入出力データであるのに対して、方法 B の場合は区間入出力データである。

$N=4$  とし、GA を用いた場合の結果を以下に示す。GA のパラメータ設計は前章と同一である。方法 A・B の結果をそれぞれ図 5・6 に示す。各図の(a)は学習用データに対する NN の適合度（つまり学習誤差）を、(b)は元のデータに対する NN の適合度（つまり汎化能力）を表している。図 5・6 の(a)から、方法 A・B いずれの場合も学習用データに対する NN の出力の誤差は十分に小さく、よく学習できていることがわかる。一方、図 5・6 の(b)から、方法 B の場合は元データの出力軸方向のばらつきの影響を大きくうけずに背後の関数をモデル化できており、汎化能力の高い NN が得られたが、方法 A の場合はサンプリングされたデータに強く依存して学習が進み、元データの出力軸方向のばらつきの影響を大きくうけたために汎化能力の低い NN が得られたことがわかる。方法 B の場合に汎化能力の高い NN が得られた理由は、1 つに群化された区間入出力データが群化前のデータの存在する範囲をおおまかに表現しているため、データ数を 1 つに減らしつつも元データの分布の特徴をある程度保持した状態で NN を学習できたためと考えられる。この実験結果は、本例と似たような状況のビッグデータ解析において、実数データを区間データに群化して学習させるという方法の有用性を示唆している。ただし、適切な分割数  $N$  の値は元データの分布に依存するため、その決定方法は今後の課題の 1 つである。また、より現実の問題に即した、多次元入力データの場合の分割方法や有効性評価実験も今後の課題と言える。

#### 4. まとめ

本稿では、学習用データとして区間入出力データが与えられた場合の階層型ニューラルネットの進化的学習を試みた。簡単な数値データ例を用いた実験の結果、遺伝的アルゴリズム、進化戦略のいずれを用いた場合でも、概ね学習誤差の小さいニューラルネットを得ることができた。また、ビッグデータ解析への応用を想定した実験を行い、実数デ

ータを区間データに群化して学習に用いることで、学習コストを抑えつつ汎化能力の高いモデルを得られると期待できることを示した。今後は前章に記載の課題に取り組んでゆく。






図 4: 多数の実数入出力データの例



(a) 学習用データとの比較 (b) 元データとの比較

図 5: 方法 A によるデータを学習した NN の出力



(a) 学習用データとの比較 (b) 元データとの比較

図 6: 方法 B によるデータを学習した NN の出力

#### 参考文献

- [1] D.E. Rumelhart, J.L. McClelland and the PDP Research Group, *Parallel Distributed Processing*, Vol.1, MIT Press, 1986.
- [2] H. Ishibuchi and H. Tanaka, An extension of the BP-algorithm to interval input vectors, *Proc. of IEEE International Joint Conference on Neural Networks*, pp.1588-1593, 1991.
- [3] A.E. Eiben and J.E. Smith, *Introduction to Evolutionary Computing*, Springer, 2003.
- [4] X. Yao, Evolving artificial neural networks, *Proc. of the IEEE*, 87(9), pp.1423-1447, 1999.
- [5] D. Goldberg, *Genetic Algorithms in Search, Optimization and Machine Learning*, Addison-Wesley Professional, 1989.
- [6] H.-P. Schwefel, *Evolution and Optimum Seeking*, Wiley & Sons, 1995.
- [7] L.J. Eshelman and J.D. Schaffer, Real-coded genetic algorithms and interval-schemata, in D.L. Whitley (ed), *Foundation of Genetic Algorithms 2*, pp.187-202, 1993.