

ファジィ差分進化手法によるファジィニューラルネットの進化的学習

Evolving Fuzzy Neural Networks by means of Fuzzy Differential Evolution

岡田 英彦
Hidehiko Okada

1. はじめに

著者はこれまでに、解の遺伝子表現形（genotype）の値としてファジィ数を利用できるように進化的アルゴリズムのプロセスを拡張する方法を提案している[1]。本論文では、提案手法の1つであるファジィ差分進化手法（Fuzzy Differential Evolution: FDE）を用いて、ファジィ数結合強度を持つファジィニューラルネット(FNN)[2]の進化的学習を試みる。

2. ファジィ数結合強度を持つニューラルネット

本研究で用いるニューラルネットは、著者の先の研究[3]と同様に、文献[2]で提案されたFNNである。このFNNは、3階層のフィードフォワード型であり、結合強度としきい値がファジィ数の値をとる。FNNの構造を図1に示す。簡単化のため、FNNの出力層ユニット数は1とする。

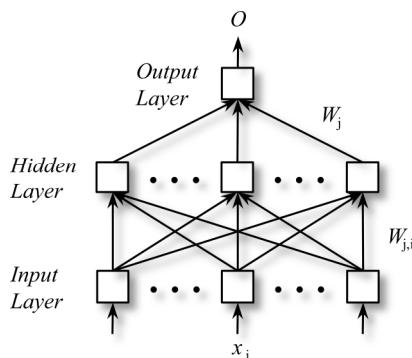


図1: ファジィニューラルネットの構造[2]

このFNNは、実数入力ベクトル \mathbf{x} を受け取り、ファジィ数出力値 O を、式(1)-(5)に基づいて計算する。

入力層 :

$$o_i = x_i. \quad (1)$$

中間層 :

$$Net_j = \sum_i W_{j,i} o_i + \theta_j, \quad (2)$$

$$O_j = f(Net_j). \quad (3)$$

出力層 :

$$Net = \sum_j W_j O_j + \theta, \quad (4)$$

$$O = f(Net). \quad (5)$$

式(1)-(5)において、 x_i, o_i は実数であり、 $Net_j, Net, W_{j,i}, W_j, \theta_j, \theta, O_j, O$ はファジィ数である。簡単化のため、文献[2]ではこのファジィ数として対称三角型ファジィ数が用いられており、本稿でも同様とする。対称三角型ファジィ数のメンバーシップ関数は、図2のように、中心 c と幅 w 、

もしくはサポート集合の下限 L と上限 U によって規定できる[3]。

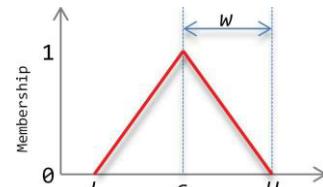


図2: 対称三角型ファジィ数のメンバーシップ関数[3]

ユニット内部関数 $f(x)$ にはシグモイド関数 $f(x) = 1/(1 + e^{-x})$ を用いる。図1のFNNのフィードフォワード計算の詳細は文献[2]を参照されたい。

3. ファジィ DE

FNNの入力層ユニット数を n ($i = 1, 2, \dots, n$)、中間層ユニット数を m ($j = 1, 2, \dots, m$) とすると、 $W_{j,i}$ の数は mn 、 W_j の数は m であり、結合強度の数は $mn + m$ である。さらに、ユニットしきい値の数は $m + 1$ である。したがって、FNNに含まれる結合強度およびしきい値の総数は $mn + 2m + 1$ である[3]。本研究が提案するファジィ DE は、この $mn + 2m + 1$ 個のファジィ数を genotype の値として用いる。genotype を $\mathbf{X} = (X_1, X_2, \dots, X_D)$ と表すと、 $D = mn + 2m + 1$ であり、 X_1, X_2, \dots, X_D の値は、対応する結合強度もしくはしきい値がとるファジィ数である。 X_1, X_2, \dots, X_D は、それぞれ、上限と下限、もしくは中心と幅によって規定できる。つまり、 $X_i = [x_i^L, x_i^U]$ もしくは $X_i = (x_i^c, x_i^w)$ であり、 $x_i^L, x_i^U, x_i^c, x_i^w$ は X_i の下限、上限、中心、幅を表す[3]。上下限を用いて規定する方法を LU モデル、中心・幅を用いて規定する方法を CW モデルと呼ぶことにする。

著者が提案したFDEのプロセス構成は、従来の実数DE[4]と共にである。ただし、解の初期化、適合度評価、子個体生成の方法が、ファジィ数 genotype を扱えるように拡張される。本稿では子個体生成の方法について記載する。DEの子個体生成の方法には様々なバリエーションがあるが、ここでは DE/rand/1/bin を例にして説明する。ある親個体の genotype を \mathbf{X}_a 、 \mathbf{X}_a の子個体を \mathbf{X}'_a 、 \mathbf{X}'_a のための donor vector および trial vector をそれぞれ \mathbf{Y}_a および \mathbf{Z}_a 、 \mathbf{Y}_a の生成に用いる3つの解を \mathbf{X}_{b1} 、 \mathbf{X}_{b2} 、 \mathbf{X}_{b3} とする。 \mathbf{X}_{b1} 、 \mathbf{X}_{b2} 、 \mathbf{X}_{b3} の選択方法は従来の DE/rand/1/bin と同一であり、 $\mathbf{X}_a \neq \mathbf{X}_{b1} \neq \mathbf{X}_{b2} \neq \mathbf{X}_{b3}$ である。 \mathbf{X}_a 、 \mathbf{X}'_a 、 \mathbf{Y}_a 、 \mathbf{Z}_a 、 \mathbf{X}_{b1} 、 \mathbf{X}_{b2} 、 \mathbf{X}_{b3} のいずれも D 次元ファジィ数ベクトルであり、各要素の値はここでは対称三角型ファジィ数である。

LU モデルを用いる場合は、 $\mathbf{Y}_{a,i} = [y_{a,i}^L, y_{a,i}^U]$ であり、 $y_{a,i}^L, y_{a,i}^U$ の値を次式によって決定する。

$$y_{a,i}^L = x_{b1,i}^L + F(x_{b2,i}^L - x_{b3,i}^L) \quad (6)$$

$$y_{a,i}^U = x_{b1,i}^U + F(x_{b2,i}^U - x_{b3,i}^U) \quad (7)$$

ただし、 $y_{a,i}^L \leq y_{a,i}^U$ を満たす必要がある。そこで、式(6),(7)で求められた $y_{a,i}^L, y_{a,i}^U$ が $y_{a,i}^L \leq y_{a,i}^U$ を満たさない場合は $(y_{a,i}^L + y_{a,i}^U)/2$ を求め、その値を $y_{a,i}^L, y_{a,i}^U$ の値として用いる。

一方、CW モデルを用いる場合は、 $Y_{a,i} = (y_{a,i}^c, y_{a,i}^w)$ であり、 $y_{a,i}^c, y_{a,i}^w$ の値を次式によって決定する。

$$y_{a,i}^c = x_{b1,i}^c + F(x_{b2,i}^c - x_{b3,i}^c) \quad (8)$$

$$y_{a,i}^w = x_{b1,i}^w + F(x_{b2,i}^w - x_{b3,i}^w) \quad (9)$$

ただし、 $0 \leq y_{a,i}^w$ を満たす必要がある。そこで、式(9)で求められた $y_{a,i}^w$ が $0 \leq y_{a,i}^w$ を満たさない場合は $y_{a,i}^w = 0$ とする。

式(6)-(9)における F はスケーリングファクタであり、従来の DE/rand/1/bin と同一である。また、 \mathbf{X}_a と \mathbf{Y}_a を用いて \mathbf{Z}_a を決定する方法も従来の DE/rand/1/bin と同一である。つまり、 $Z_{a,i}$ は $X_{a,i}$ もしくは $Y_{a,i}$ のいずれかであり、その選択を交叉確率 CR のもとで行う。さらに、 \mathbf{X}_a と \mathbf{Z}_a を用いて \mathbf{X}'_a を決定する方法も従来の DE/rand/1/bin と同一である。つまり、 \mathbf{X}_a と \mathbf{Z}_a のうちよりよい方を \mathbf{X}'_a とする。

このように、本研究の提案手法である FDE は、DE における donor vector の生成をファジィ数規定のためのパラメータごとに行い、パラメータの制約を満たさない場合には値を修正している。このアイデアを用いれば、DE/rand/1/bin 以外のバリエーションも同様に拡張が可能である。

4. ニューラルネットへの応用

進化的アルゴリズムを用いたニューラルネットの学習はニューラルネットワークと呼ばれている[5]。文献[2]の FNN を対象としたニューラルネットワークの試みとして、FDE を応用した。実験で用いたファジィ目標関数 $F(x)$ の例を図 3 に示す[3]。この $F(x)$ は実数入力 x に対して対称三角型ファジィ数を出力する関数であり、図 3 の F0.0L/F0.0U / F1.0 が、ファジィ数 $F(x)$ の下限 ($F(x)^L$) / 上限 ($F(x)^U$) / 中心 ($F(x)^c$) をそれぞれ表している。ここで、

$$F(x)^L = 0.2\sin(2\pi x) - 0.1x^2 + 0.4, \quad (10)$$

$$F(x)^U = 0.2\sin(2\pi x) + 0.1x^2 + 0.6, \quad (11)$$

$$F(x)^c = (F(x)^L + F(x)^U)/2, \quad (12)$$

である[3]。

FNN は中間層ユニット数=10 とし、FDE は、集団サイズ=100、世代数=10,000、F=0.5、CR=0.8、genotype の値の表現方法=LU モデルとして実験を行った。進的に生成された FNN のうち誤差最小の FNN が output したファジィ関数を図 4 に示す。また、学習後の FNN が入力値 $x = 0.3$ および $x = 0.7$ に対して出力したファジィ数を図 5 に示す。図 4 および図 5 より、学習後の FNN は図 3 の目標関数をよく近似できていることがわかる。

5. まとめ

本稿では、著者が提案したファジィ DE を用いてファジィ NN の進化的学習を試みた。実験の結果、学習後の FNN はファジィ目標関数をよく近似できていることがわかった。

今後の課題として、他のファジィ最適化問題への提案手法の適用が挙げられる。

参考文献

- [1] H. Okada, Proposal of fuzzy evolutionary algorithms with

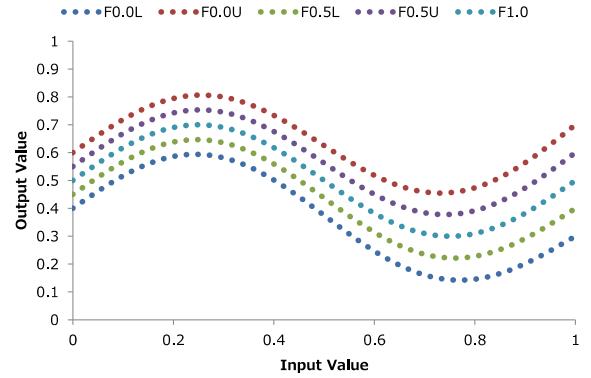


図 3: 学習対象として用いたファジィ関数[3]

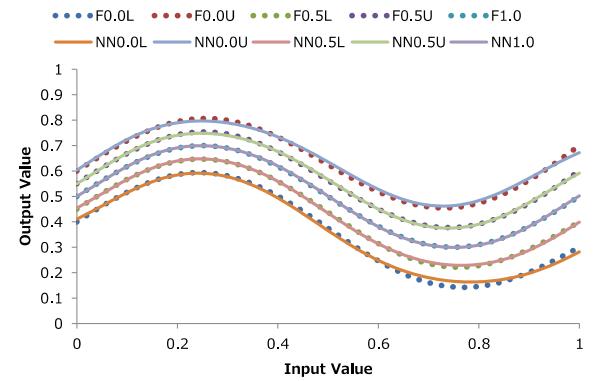


図 4: 学習後の FNN が output したファジィ関数

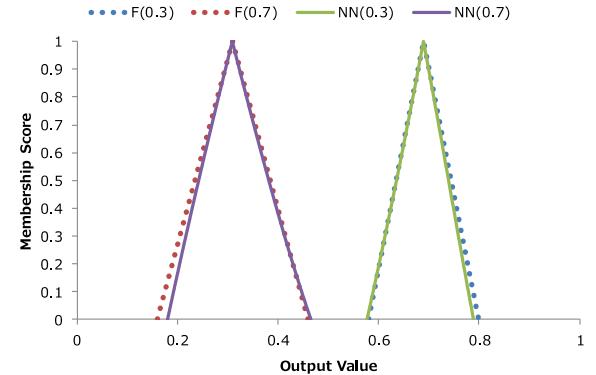


図 5: 学習後の FNN が output したファジィ数

fuzzy valued genotypes, Proc. of International Conference on Instrumentation, Control and Information Technology (SICE Annual Conference 2012), 1538-1541, 2012.

[2] H. Ishibuchi, H. Tanaka and H. Okada, Fuzzy neural networks with fuzzy weights and fuzzy biases, Proc. of IEEE International Conference on Neural Networks, 1650-1655, 1993.

[3] 岡田, 遺伝子の値をファジィ数に拡張した GA のニューラルネットワークへの応用, 情報処理学会関西支部平成 25 年度支部大会, C-5, 2013.

[4] R. Storn and K. Price, Differential evolution - a simple and efficient heuristic for global optimization over continuous spaces, Journal of Global Optimization, 11(4), 341-359, 1997.

[5] X. Yao, Evolving artificial neural networks, Proc. of the IEEE, 87(9), 1423-1447, 1999.