

全ANDルール構成型ファジィ・ニューラルネットワーク

1C-8

松岡輝彦* 井上剛** 荒巻隆志**

シャープ株式会社

プリント商品開発研究所* 応用システム研究所**

1. はじめに

現在考案されているファジィ・ニューラルネットワークでは経験者の知識をファジィルールとして抽出し、そのルールに依存したネットワークを構築している。しかし経験者の知識が曖昧な時や、ルールが掴めていない時には正しいネットワークを構築することができない事がある。そこで我々はこのような場合にも少量の実験データを学習することで正しく入出力関係をシミュレートできるファジィ・ニューラルネットワーク（以下FNN）を考案したので報告する。

2. FNNの構成

本報告におけるFNNの構造について、図1に示す2入力1出力のFNNを例として説明する。FNNは5つの層から構成されている。第一層目が入力層である。第二層目と第三層目がそれぞれメンバーシップ層の前半部と後半部であり、図2に示す3つのメンバーシップ関数を構成している。第四層目がルール層であり、第三層目の2つのノードの出力同士のANDを取るよう構成されている。このANDの取り方は、各2つの入力パラメータのそれぞれのメンバーシップ関数の全組み合わせを取っている。i入力でk種類のメンバーシップ関数の場合、 C_2^k 種類のANDルールで構成される事になる。第五層目が出力層であり、ANDルールの全出力値の加重平均を取るよう構成されている。

3. FNNの演算/学習方法

FNNの演算/学習方法について図1のネットワークを用いて説明する。入力層からメンバーシップ層後半部まで式1～式2a（又は式2b）の演算を行う。

$$H_{ij} = x_i + w_{cij} \quad (i=1,2; j=1,2,3,4) \quad (式1)$$

$$M_{ik} = f(H_{ij} \cdot w_{gij}) \quad (j=1; k=1, j=4; k=1) \quad (式2a)$$

$$M_{ik} = \min \left\{ f(H_{ij} \cdot w_{gij}), f(H_{i+j} \cdot w_{gij+1}) \right\} \quad (j=2; k=2) \quad (式2b)$$

Fuzzy Neural Network Composed of AND Rules

Teruhiko Matsuoka, Tsuyoshi Inoue, Takashi Aramaki
SHARP Corporation, Product Development Laboratories
Printing and Reprographic Systems Group, and Integrated
Media Laboratories

1-9-2 Nakase, Mihama-ku, Chiba-shi, Chiba 261, Japan

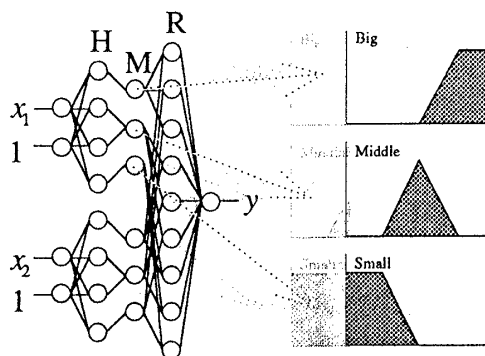


図1

図2

x_i は入力パラメータの値、 w_{cij} は入力層の定数1とメンバーシップ層前半部との結合係数、 H_{ij} はメンバーシップ層前半部の出力値、 w_{gij} はメンバーシップ層前半部とメンバーシップ層後半部との結合係数、 f はシグモイド関数、 M_{ik} はメンバーシップ層後半部の出力値、 $\min\{A, B\}$ はAとBのどちらか小さい値を選択する関数である。式2aで図2に示すBigとSmall、式2bでMiddleのメンバーシップ関数の出力値が得られる。次にメンバーシップ層後半部からルール層への演算を行う。

$$R_n = \min \{ M_{ik}, M_{ik} \} \quad (i=1,2; n=C_2^k; k=2) \quad (式3)$$

R_n はルール層の出力値である。これで各ANDルールの論理積の値が得られる。最後にルール層から出力層への演算を行う。

$$y = \sum R_n \cdot w_{fn} / \sum R_n \quad (式4)$$

w_{fn} はルール層と出力層との結合係数、 y は出力層の出力値である。次にこの出力値が正しくなるよう学習する為、出力層の出力値とサンプルデータの出力値（教師データT）との二乗誤差Eを求める。

$$E = (T - y)^2 / 2 \quad (式5)$$

この誤差を小さくするよう各結合係数を微調整していく。これがFNNの学習となる。微調整する量を求めるためにEを各結合係数により偏微分する。

$$\Delta w_{fn} = \partial E / \partial w_{fn} \quad (式6)$$

$$\Delta w_{gij} = \partial E / \partial w_{gij} \quad (式7)$$

$$\Delta w_{cij} = \partial E / \partial w_{cij} \quad (式8)$$

この偏微分値に学習係数を掛けたものを現在の各結合係数に加えることで結合係数の微調整を行っていく。

3種類の結合係数のうち、 w_{fn} の初期値は経験者の知識から得られたファジィルールに基づいて設定しており、0.5を基準としてファジィルールのBigを+0.25、

Middleを0.0、Smallを-0.25とし、各ANDルール毎に5段階で設定している。更にこのANDルールは全てのルールが内包されているため、結合係数の初期値が曖昧な知識から得たファジイルールであっても学習で微調整することにより、正しいファジイルールに修正することができる。

4. ルールの抽出方法

このように学習したネットワークから新たにファジイルールが抽出できる。1つの入力についてのみ注目したシングルルール、2つの入力について注目したダブルルール、その他3つ以上の入力についても抽出可能である。抽出方法はルール層から出力層への結合係数 w_{fn} を使い、次の演算規則により行う。

4.1. シングルルール

ある1つの入力パラメータが関わる全てのANDルールで、Big、Middle、Small毎に結合係数の総和を求め比較し、その大小関係をシングルルールとする。

$$\text{図1の } x_1 \text{ の場合: } w_{big1} = \sum_{n=1,2,3} w_{fn}, w_{middle1} = \sum_{n=4,5,6} w_{fn}, w_{small1} = \sum_{n=7,8,9} w_{fn}$$

$$\text{図1の } x_2 \text{ の場合: } w_{big2} = \sum_{n=1,4,7} w_{fn}, w_{middle2} = \sum_{n=2,5,8} w_{fn}, w_{small2} = \sum_{n=3,6,9} w_{fn}$$

(例) ' $w_{big1} > w_{middle1} > w_{small1}$ ' なら、

“入力 x_1 が大きいと出力 y は大きい”となる。

4.2. ダブルルール

ある2つの入力パラメータのみに関わる全てのANDルールにおいて、各入力パラメータのBig、Middle、Small毎に結合係数の総和を求め比較し、それぞれの大小関係のANDをダブルルールとする。図1の場合上記2つのシングルルールのANDを取る。

出力パラメータの出力を求める演算が w_{fn} の加重平均であり、 w_{fn} はサンプルデータに沿って微調整されることから、抽出されるルールはサンプルデータの出力の傾向に沿ったルールとなる。これにより、学習させたサンプルデータの傾向と経験者の知識との整合性を調べる事が可能となる。

5. 歯抜けデータの演算/学習

更に、このFNNで入力パラメータの一部の値が未知の値であるときにも、出力パラメータの値を演算したり、学習できるよう改良した。これは未知の値をその入力パラメータの取りうる最大値と最小値を用いて演算することで行う。各層の出力値も取りうる最大値と最小値で表される。既知の値は最大値=最小値=入力値となる。演算方法は前述の式に従い、最大値側と最小値側に分けてそれぞれ行う。ルール層の出力では、出力パラメータの値を求める際に、最初に未知の値の

入力パラメータに関与しないANDルールの結合係数のみで加重平均を求める。次いで出力パラメータの最大値を求める為に加重平均が大きくなるよう未知の値の入力パラメータに関するノードの中から結合係数の最大値を選択し、又、最小値を求める為に加重平均が小さくなるよう未知の値の入力パラメータに関するノードの中から結合係数の最小値を選択し、再度各々の加重平均を求める。その結果、未知の入力値を含む入力パラメータに対して出力パラメータの取りうる範囲が求められる。学習時は演算に寄与したノードに関わる結合係数のみを微調整し、未知の値に関するANDルールの結合係数は既知の値に関するANDルールの結合係数ほどは微調整されない。また、未知の値の入力パラメータの $w_{c_{ij}}$ と $w_{g_{ij}}$ の微調整は行われない。これは未知の値がメンバーシップ関数のどこに属するか不明なため、誤った微調整を行わないような効果を期待する上で有効である。これにより、サンプルデータが少ない時でも、未知の値を含むサンプルデータを加えて演算でき、更に学習時も既知の値に関する結合係数の微調整が未知の値に関する結合係数の微調整分をカバーして、誤学習を極力抑えるように努めることが可能となる。

6. まとめ

以上述べてきたように本報告におけるFNNでは、経験者の知識の量や曖昧さに関わらずネットワークを一意に構築でき、学習後のネットワークから新たなファジイルールを抽出することも可能である。また、ファジイルールをネットワークの結合係数に初期設定している為、実験で得られる各種サンプルデータが一様に振られていない場合にも、誤学習を極力抑え、データの振られていない範囲でも傾向を表すことが可能である。更に未知の値を含むサンプルデータであっても演算や学習が可能であるため、一部の実験パラメータが抜けているようなサンプルデータでも、有効に活用することが可能である。

参考文献

- 1) S. Horikawa, T. Furihashi, and Y. Uchikawa, "On Fuzzy Modeling Using Fuzzy Neural Networks with the Back-Propagation Algorithm," in Transactions on Neural Networks, vol.3, no.5, 1992, pp. 801-806.
- 2) H. Ishibuchi, A. Miyazaki, K. Kwon, and H. Tanaka, "Learning from incomplete Training Data with Missing Values and Medical Application," in Proc. IJCNN'93, vol. II, 1993, pp. 1871-1874.