

## ファジィ推論アーキテクチャに基づくニューラル ネット

高木, 英行  
松下電器産業株式会社中央研究所

香田, 敏行  
松下電器産業株式会社中央研究所

小島, 良宏  
松下電器産業株式会社中央研究所

<https://hdl.handle.net/2324/4377859>

---

出版情報 : Journal of Japan Society for Fuzzy Theory and Systems. 3 (1), pp.133-141, 1991-02-15. Japan Society for Fuzzy Theory and Intelligent Informatics

バージョン :

権利関係 :





# ファジィ推論アーキテクチャに基づく ニューラルネット<sup>†</sup>

高木 英行\* 香田 敏行\* 小島 良宏\*

本論文ではファジィ推論ルール構造という高次知識構造をアーキテクチャとするニューラルネット(NARA: Neural-networks designed on Approximate Reasoning Architecture)を提案し、ルール構造に基づいて提案ニューラルネット(NN)を解析することで性能向上のための改善がしやすくなることを示す。NNの性能向上には事前知識等の組み込みが重要になってくるが、従来は統計処理・プレワイヤといった比較的低次の知識がNNに反映されるだけであった。NARAはファジィ推論ルール構造をフレームワークに、NNを部品として構成されている。高次知識表現構造(ファジィ推論のアーキテクチャ)のおかげでNARAにはいくつかのメリットがある。NARAの最も大きな特長は性能向上のためにNNの構造や部分的なNNに手を入れられる、即ち、次の一手が打てる点にある。NARAはファジィ推論ルールに対応する小さいNNで構成されているので、NARAの内部を分析することによって性能に関わる部分を特定したりその部分だけを修正したりすることができる。第2の特長はNNの学習時間の短縮・NNの性能向上である。本論文はモデルの構築アルゴリズムとシミュレーションによる評価を示す。

キーワード: ニューラルネット, ファジィ推論, 知識表現, 構造化

## 1. はじめに

ここ数年、ニューラルネット(NN)とファジィ理論の研究が大いに加速されるとともに、両技術の長所を組み合わせた新しい融合技術の模索が盛んになってきた。しかし、これらの研究のほとんどは、NNの学習機能・非線形性という特長をファジィシステムに反映させたものである。その逆にファジィ技術をNNに反映させたものは非常に少ない<sup>[1]</sup>。

文献[1]の研究方向で、NNにファジィ技術が導入されるならば、

(a) NN構造にファジィ論理の知識構造が組み込まれ性能向上が図られる

(b) NN学習アルゴリズムにファジィ論理が反映され高速化が図られる

の2点の可能性の大きさが指摘されている。本論文は前者(a)に位置付けられる研究である。ファジィ推論のルール構造に基づいてNNを構成することによって、改善すべき性能がNN内部のどの部分に依存するかを解析し易くし、その部分を改良することで性能向上を図り易くすることを目的にしている。構成形態は、複数の機能別NNを組み合わせた構造化NNといわれるNNに相当する。本論文の目的は提案モデルの構成方法だけではなく、それ以上に、ファジィ推論ルール構造を導入することで、性能改善のための対策が施しやすくなることを示すことにある。

以下、第2章ではこれまでの知識構造のNNへの組み込み方法の検討、第3章ではファジィ推論ルール構造に基づいた構造化NNの構成手順と改良方法、第4章では数値データに適用した場合の性能評価、について述べる。

<sup>†</sup> Neural-networks designed on Approximate Reasoning Architecture  
Hideyuki TAKAGI, Toshiyuki KOUDA and Yoshihiro KOJIMA

\* 松下電器産業株式会社 中央研究所  
Central Research Laboratories, Matsushita Electric Industrial Co., Ltd.

## 2. NNへの知識構造の組み込み

最も単純なNNを用いたパターン認識の方法は、単一のNNに入力ベクトルを与え、パターンクラスを識別するものである。しかしこの基本的な方法では、NN内部に表現されたパターン識別の知識が明示的に表現されていないので、パターン認識性能を向上させるためにNNをどのように改良すべきかがわからない。NNは学習アルゴリズムによって識別規則を自動形成できるという長所がある反面、改良のための手だてが得にくいという短所を併せ持っている。

NNの性能向上は、単純にNNへデータを入力して学習するだけでは難しく、事前に分かっている知識をいかにNNに組み込むか、にかかっている。NNのユニット数で決まる情報処理能力を、NNにさせたい処理に最大限に振り向けることが大切である。

従来のNNへの知識組み込み方法には、(1)データに統計的処理を加える、(2)pre-wiringを施す、(3)機能別に分けたNNを組み合わせる、などがある。(1)はNNへの入力ベクトルの各クラスの中心ベクトルあるいは数点の代表ベクトルを求めておいて、大局的なクラス分離学習を早めに行なう方法<sup>[2]</sup>や、データ分離し易いような重み係数の初期値から学習を始める方法<sup>[3]</sup>などがある。(2)は音声認識のためのNNでよく行なわれる方法で、ユニット間結合を事前に制限しておくことで時間情報を表現する方法である<sup>[4]</sup>。時間に限らず、図形であれば事前に分かっている空間分布の制約をネットワークに反映させることになる。

知識の扱いには色々なレベルがある。例えばパターンを扱うNNのように非明示的な知識表現でかつ直接内部に表現された知識の操作がし難いものから、プロダクションルール表現やフレーム表現のように直接的にかつ明示的に知識を扱えるものまで、多数のレベルがある。従来のNNへの知識構造の組み込み(1)(2)は前者のレベル、すなわち比較的低次の知識処理をNNに反映させていると

言える。本章で提案する方法は(3)に属する方法で、機能別NNの分類を、より高次で直接的な知識表現であるIF-THEN形式を持つファジィ推論ルールの形式を用いて行なうことで、従来の方法より高次の知識構造をNNに組み込む。NNの性能向上のためにIF-THEN形式に従って内部解析をすれば、どのルールが、どの前件部が、どの後件部が、問題かを把握し修正することが容易になる。この結果、問題がない他のNN構成部に影響を与えることなく問題箇所のみ修正でき、性能向上が図れる。

1つの大きなNNでは内部状態が重み係数として分散表現されており明示的でないためにどこを改良すべきかがわかり難かった。本構成方法はこの手だてを得やすいという点が最大の特長である。さらに、NNとファジィ推論の融合化において今後の課題とされる適応性<sup>[1]</sup>についても、全体に影響を与えず、追加学習すべき部分を限定できるため、適応性実現のための1つの課題解決になる可能性を持っている。

なお、本論文ではNNに組み込む高次知識構造としてIF-THEN形式のファジィ推論ルールの形式を用いた。その他の研究としては、得意とする適用分野が異なるNNを組み合わせるその制御を行なう $\mu$ BRAIN<sup>[5]</sup>やNNの各ユニットに命題を割付け信頼度やメンバーシップ値を重み係数に割り付けたコネクショニストエキスパートシステム<sup>[6][7]</sup>などもNNへの知識構造の組み込みであると言える。これらの研究は知識処理を第1の目的にしてNNを道具としているのに対し、本論文での提案手法はNNの性能改善のために知識構造を用いるという点が、研究目的の違いである。

## 3. ファジィ推論アーキテクチャに基づいたNNの設計と改良法

### 3.1 NARAの構造

以下ではファジィ推論アーキテクチャに基づいて設計したNNのことをNARA(Neural-networks designed on Approximate Reasoning Architecture)と省略形と呼ぶことにする。本節ではどのようにファジィ推論のアーキテクチャに基

づいてNNを構成するかを述べる。初めに、本構成方法の考え方の核となる2点を述べる。

第1のポイントは入力空間のファジィ分割である。NNは入力空間を分割しクラス判別を行なう。ニューロン出力はsigmoid特性を持つので、たとえ2値の教師データで学習しても、この入力空間の分割はクリスプな分割にならない。この点がファジィ推論のメンバーシップ関数を想起させる。つまり、NNのパターン分類は入力空間のファジィ分割という点で共通点が見いだせる。

第2のポイントはファジィ推論の場合、分割された空間(ルール)毎に独自の原理に従って処理(推論)をする点である。NNは獲得した知識が内部に分散表現されているため、単一のNNの場合、特定の領域に対応する部分だけに手を加えて他に影響を与えないということは難しい。しかし、複数のNNを組み合わせる構造化NNならば容易になる。




Fig.1 Neural-networks designed on Approximate Reasoning Architecture

以上の2点から、ファジィ推論ルールの前件部に相当し入力空間をファジィ分割するNNと、ファジィ推論ルールの後件部に相当し各ルール毎に独立のNNから成る構成が考えられる。Fig.1に構成を示す。この構成は、NN駆動型ファジィ推論<sup>[8]</sup>をすべてNNで構成した場合の形態とほぼ同じである。NN駆動型ファジィ推論はファジィ推論ルールにおけるメンバーシップ関数をNNで自

動形成させることを目的にしているが、本提案方法は、NNに知識構造を組み込むことで性能改善のためにNNの解析をやすくすることを目的にしており、本論文の目的もこのことを示すことにある。

この拡張として、前件部に相当するNNを他のメンバーシップ関数生成方法、例えば、廣田らのファジィクラスティングをメンバーシップ関数にする方法<sup>[9]</sup>、に置き換えても良い。その逆に後件部を他の処理方法に置き換えることや、両者を組み合わせる方法も考えられる。ただ、この拡張に伴ってだんだんNNの形態から遠ざかっていく。

### 3.2 NARAの設計法

次に具体的なNN設計方法を述べる。理解し易いように次節で示すパターン識別を例に説明する。この例のようにパターンを扱う場合feed-forward型NNを用いることが多いが、NARAを構成する個々のNNやその学習方法は特定のものに限定されるのではなく、包含的な概念である。




Fig.2 Pattern Classes for Identification

#### [手順1] 学習データのクラスティング

D次元特徴ベクトル(Fig.2の場合、2次元座標データ)の入力データをクラスティングする。この時、識別ラベル名はクラスティングする対象の変数に含めない。この結果、例えば文字認識のような場合、同じ識別ラベル 'a' がフォントの違いによって複数のクラスに分かれることも有り得る。各クラスを  $C^s$  ( $1 \leq s \leq r$ ,  $s$  はクラス番号で  $r$  はクラス数) とする。このクラス数  $r$  が推論ルール数に

相当する。Fig. 2 の場合  $r=4$  クラスになり、Fig. 3 のようにファジィ分割される。




Fig. 3 Clustered Area of Fig. 2

〔手順 2〕 ファジィ推論ルールの前件部に相当する  $NN_{mem}$  の学習

〔手順 1〕 でクラスタリングされた各クラス  $C^s$  のクラス番号  $s$  を教師データとする。〔手順 1〕 の学習データを用いて、 $D$  次元の特徴ベクトルを入力し  $r$  個のクラス識別を行なう NN を学習する。

ハードクラスタリング<sup>[10]</sup>を行なった場合、教師データはいずれか 1 つのクラスにのみ属する、というクリस्पデータであるが、学習された NN が内部形成するクラスは、クリस्प集合ではなくファジィ集合になる。つまり、NN が連続メンバーシップ関数を生成することになる。これが、本提案方式がファジィ推論のアーキテクチャに基づくという理由である。この NN を  $NN_{mem}$  と呼ぼう。また  $NN_{mem}$  の内部に形成されたファジィ分割された入力サブ空間を  $R^s$  ( $s$  はクラス番号) とする。NN の認識性能の点からみると、 $R^s$  がクリस्पでなくファジィ集合であるということは、汎化能力を高めることにつながる可能性がある。すなわち、偏りがあるために学習データの集合と評価用データの集合が完全に一致しない場合 (一般には学習データ数は有限なので、偏りなくデータを集めることはほとんど不可能)、学習データの集合から多少はみ出た評価用データを救済するために、学習データの集合と評価用データの集合のズレを吸収できるようにしくみが必要になる。 $R^s$  はファジィ集合なので、クラス境界には、 $R^s$  を定義するメンバ

ーシップ関数  $\mu_{R^s}(x)$  が  $0 < \mu_{R^s}(x) < 1$  に対応する空間領域があり、多少はみ出た評価用データも救済でき得る。

〔手順 3〕 各ファジィ推論ルールの後件部に相当する  $NN_s$  の学習

各  $C^s$  毎に、クラス内に含まれるコードを識別する NN を学習する。Fig. 2 の場合 4 つの後件部が EXOR (排他的論理) 問題のような識別をすることになる。こうしてできた  $s$  番目の推論ルール後件部に相当する NN を  $NN_s$  と呼ぼう。

〔手順 4〕 最終出力の決定

〔手順 2〕〔手順 3〕で学習した  $NN_{mem}$  と  $NN_1 \sim NN_r$  を Fig. 1 のように結合する。乗算器はメンバーシップベクトル  $\vec{m} = (m_1, m_2, \dots, m_r)$  の要素で、各ルールの後件部 NN の出力である認識ベクトル  $\vec{f}_s$  を重み付けする。こうして得られた各ルール毎の認識ベクトル  $m_s \cdot \vec{f}_s$  が加算され最終認識ベクトル  $\vec{x}$  になる。

$$\vec{x} = \frac{1}{\sum_{s=1}^r m_s} \sum_{s=1}^r m_s \cdot \vec{f}_s \quad (1)$$

### 3.3 性能向上のための改良

〔手順 5〕 エラー解析

上記〔手順 4〕で得られた構造化 NN の識別性能が利用者の予想・要求基準に達しなければ、性能を向上させるため識別誤りを解析する。識別誤りの解析とは、識別誤りを起こしたデータをクラス分類する  $NN_{mem}$  の識別性能はどうか、各ルールの後件部に対応する  $NN_s$  の識別性能はどうかなどを比較し、問題となる NN を特定することである。例えば Fig. 2 の場合、対応する Fig. 5 のデータを後述 4. 2 節で分析して分かるように、第 4 番目の出力に識別誤りが多く、課題はこのルールの前件部ではなく後件部の  $NN_4$  の識別性能向上にあることがわかる。

〔手順 6〕 性能向上のための改良

第 4 番目の推論ルールの領域  $C^4$  に属するデータをクラスタリングで解析すると、大きく 2 つのサブクラスに分かれていることがわかる (Fig. 4)。




Fig.4 Subclustered Area for Improvement of Fig.3

そこで、第4番目に推論ルールを満足した場合は、さらにFig.4に対応した2つのルールを適用するというように推論を行なうようNNを構成する。こうして4個+2個のルールに対して、5つの後件部 $NN_1, NN_2, NN_3, NN_{41}, NN_{42}$ ができ、各後件部はEXOR程度の難易度をもった識別を行なえばよいことになり、識別性能が向上する。

ここでの改良方法は識別問題の性格や[手順5]のエラー解析の結果に応じて異なり、多段推論の形式にして対処する方法以外にもいろいろ考えられよう。

### 3.4 ファジィ推論法との対応

初めに一般のファジィ推論と本論文でのNN設計に用いたファジィ推論の関係を述べる。

ルール : IF  $x$  is  $A$  THEN  $y$  is  $B$   
 事実 :  $x$  is  $A'$

結論 :  $y$  is  $B'$

を推論の合成規則で

$$B' = A' \circ (A \rightarrow B) \quad (2)$$

と表わそう。この推論は一般に

$$\mu_{B'}(y) = \sup_x (\mu_{A'}(x) \textcircled{1} (\mu_A(x) \textcircled{1}' \mu_B(y))) \quad (3)$$

と表わされる。(3)式はファジィ推論の一般形である。

$t$ /ノルム演算子  $\textcircled{1}$  と  $\textcircled{1}'$  としてmin演算を用いたMamdaniの方法では、(3)式は次のように変形される。

$$\begin{aligned} \mu_{B'}(y) &= \sup_x (\mu_{A'}(x) \wedge (\mu_A(x) \wedge \mu_B(y))) \\ &= \sup_x (\mu_{A'}(x) \wedge \mu_A(x)) \wedge \mu_B(y) \end{aligned} \quad (4)$$

さらに菅野らのファジィ推論法<sup>[12] [13] [14]</sup>では後件部が関数 $f(x)$ で表わされ、第2のmin演算子の代わりに乗算を用いた(5)式で表される。

$$\mu_{B'}(y) = \sup_x (\mu_{A'}(x) \wedge \mu_A(x)) \times f(x) \quad (5)$$

本論文での提案やファジィ推論にNNを導入にした方式<sup>[8] [11]</sup>は、基本的にはこの菅野らのファジィ推論法に対応している。NNへの入力古谷ら<sup>[11]</sup>のようにメンバーシップ関数 $\mu_{A'}(x)$ を複数の入力に割り付ける場合もあるし、単に

$$\mu_{A'}(x) = \begin{cases} 1 & x = x^* \\ 0 & x \neq x^* \end{cases} \quad (6)$$

としてsingleton  $x^*$ の入力を考え

$$y = \mu_A(x^*) \times f(x) \quad (7)$$

となる場合もある。

本論文でNNの設計に用いているファジィ推論アーキテクチャはこの(7)式を基本にして、さらに拡張したものである。いま $n$ 次元の入力ベクトル $\vec{x}$ と $r$ 個の推論ルールを考える。すると(7)式は(8)式のようにルール $s$ の推論結果を表す。

$$y_s = m_s \times f_s(\vec{x}) \quad (8)$$

$m_s$ はルール $s$ への適合度で、(9)式で表される。

$$m_s = \mu_{A_1}^s(x_1) \wedge \mu_{A_2}^s(x_2) \wedge \cdots \wedge \mu_{A_n}^s(x_n) \quad (9)$$

最終的な結論 $y$ は、各ルールの後件部で得られる推論値 $y_s$ を適合度 $m_s$ で荷重平均したものである。

$$y = \frac{1}{\sum m_s} \cdot \sum m_s \cdot f_s(\vec{x}) \quad (10)$$

以上が複数のsingletonを入力しスカラー値を出力する菅野らのファジィ推論法であるが、NNを用いた推論方法は、(9)式の前件部のmin演算がメンバーシップ関数の超曲面表現に吸収されることと、後件部がベクトル値を出力する非線形関数で表わされる点で、菅野らの推論法を拡張したものと言えるであろう。

前者についてさらに説明しよう。入力変数毎にメンバーシップ関数を設計する従来のファジィ推論ルールではなく、入力変数空間全体を非線形にファジィ分割し、分割された各部分空間全体を定義するメンバーシップ関数を前件部に持つ推論ルールが、NNを用いた推論ルールである。入力変数空間を意識した表記をすれば $s$ 番目の推論ルール

は

IF  $\vec{x} \in R^s$ , THEN  $f_s(\vec{x})$

で表わされる。 $R^s$ は入力変数空間上でファジィ分割された部分空間に対応するファジィ集合である。 $R^s$ は多次元空間上の部分空間であるからこれに対応するメンバーシップ関数は多次元空間上の超曲面である。従って、従来のように個々の入力変数毎にmin演算することなく、多次元上の1点 $\vec{x}$ に対する1つのメンバーシップ値が得られる。この演算は前件部の総合表現である $NN_{mem}$ によって行なわれる。入力変数空間を非線形にファジィ分割できることが拡張点である。

後件部の推論関数 $f_s()$ は $NN_s$ で行なわれるので、これも非線形である。

こうして求められる(10)式は非線形関数 $f(\vec{x})$ をベクトル出力 $\vec{y}(\vec{x})$ と拡張すれば(1)式となる。本論文はあくまでNNの設計に関する論文であるが、3.4節では、本論文提案NARAをファジィ推論システムとして見た場合の解釈を述べた。

## 4. 数値例による評価

前節の手順に従ってファジィ推論ルール構造に基づいたNNを構成し、性能改善のために次の一手が打てることを、2クラス判別問題に適用して評価する。なお、本章の実験では、feed-forward型NNを用いbackpropagation法<sup>[15]</sup>で学習する。学習の条件はいずれも、重み係数を $|w| \leq 0.3$ で乱数初期化し、学習率を0.5、慣性項係数を0.6として行なった。

### 4.1 準備

#### (a) 実験データ

Fig.2に対応した数値データを乱数値で作成する。各AおよびBに相当する領域に10個の一樣乱数を発生させる。この合計200個を学習データとする。これをFig.5に示す。

#### (b) NN構造

3層NNのモデル規模を(入力層ユニット数×中間層ユニット数×出力層ユニット数)で表現する。ただししきい値のための常に1をとるユニッ

ト<sup>[16]</sup>はこの数値に含めないものとする。Fig.5の場合、2次元座標を入力とし白か黒かの判定であるので、入力層ユニット数は2、出力層ユニット数は1である。

従来のNNとして $(2 \times 14 \times 1)$ の単一NNと本提案のNARAの重み係数とが同数になるよう中間層ユニット数を設定し、NNの性能に影響を与える要因をNNの構成だけに限定して比較実験を行なう。




Fig.5 Data for Closed Test




Fig.6 Data for Open Test

## 4.2 評価実験

### (a) 比較実験

( $2 \times 14 \times 1$ )の単一NNにFig.5の白／黒判別を行なわせるよう学習を行なわせた。しかし、2000回学習を行なったがまったく収束しなかった。したがって識別率は50%であった。これは非線形なEXOR問題のようなデータ分布をさらに複数組み合わせた問題であり、非線形性が大変強く、解の探索が非常に困難であるからである。

### (b) 構造化NNの設計と評価

[手順1]～[手順4]に従ってNNを設計する。階層的クラスタリング<sup>[17]</sup>を行った結果、最短距離法・最長距離法・Ward法など5種類の距離計算法を試みたが、いずれもクラスタ間距離の比較から4つのクラスタに分離するのが妥当であると判断された。[手順2]と[手順3]に従って前件部と後件部に相当するNNを学習させる。4つのファジィルール空間への帰属度を定める前件部相当の $NN_{mem}$ のモデル規模は( $2 \times 3 \times 4$ )、後件部相当の $NN_1 \sim NN_4$ のモデル規模は( $2 \times 2 \times 1$ )である。(a)の比較用単一NNと同じく重み係数の総和は42個(オフセット項用の重み係数を含めない場合)である。学習が終わりFig.1のように構造化されたNNを[手順4]の推論で白／黒判別を行なわせる。

識別率は85%であった。識別空間をFig.7(b)に示す。入力データは4つの推論ルールで推論できるという事前知識をNN構造に導入することで、知識構造を導入しない単一NNに比べて収束の速さ・性能の向上が示された。

### (c) エラー解析と性能の向上のための改良

本提案手法の特長は、(b)で得られた単に性能が向上するという点よりも性能向上のための改良

が図り易くなる点であり、本論文の目的はこの点を示すことにある。

[手順5]に従って誤識別データを解析しNARAを構成するどの部分に問題があるかを検討する。すると第4番目の推論ルールに相当するNNが問題であることが誤識別データから容易に分かる。しかも、クラスタリング結果の識別は間違えていないので、前件部の $NN_{mem}$ にも問題がなく後件部相当の $NN_4$ に問題があることがわかる。

続いて[手順6]に基づいてクラスタリングを行なうと、クラスタ間距離の比較から、第4番目のファジィルール分割された領域はさらに2つのクラスタから構成されていることが分かる。そこで第4番目の推論ルールが適用されたら、さらに多段推論を行なうこととし、 $NN_{41} \cdot NN_{42}$ をNARAに組み込む。

この結果、 $NN_4$ の識別率71%が $NN_{41} \cdot NN_{42}$ 共に93%まで改善され、NARA全体の識別性能は94%に向上した。識別空間をFig.7(c)に示す。かくして、ファジィ推論ルール構造に従ってNNの問題点を解析し改良することで識別率が85%から94%に向上した。以上の結果をTable 1に示す。


Table 1 学習データの識別率

単一NN	改良前のNARA	改良後のNARA
50 %	85 %	94 %


これをFig.6の500個の未学習データで評価した結果がTable 2である。

Table 2 未学習データの識別率


単一NN	改良前のNARA	改良後のNARA
50 %	83 %	89 %



(a) ordinary one NN



(b) NARA of 1st version



(c) improved NARA

Fig.7 Result of Evaluation



## 5. まとめ

本論文では第1に、NNにファジィ推論ルール構造を組み込んだ新しいモデルを提案した。知識処理システムやNNを適用する応用問題には、論理がはっきり表現される場合とまったく知識獲得できない場合だけでなく、ある程度の知識構造は見えるが完全ではないという中間状態の場合が多くある。むしろ現実社会では、このような場合の方が多とも言える。このような応用問題に適用できるシステムには、Fig.8に示すような、明示的な知識表現もできるNN、もしくはその逆のデータから学習機能で知識獲得できる知識システム、のように明示的な知識も非明示的な知識も扱えるシステムが求められる。例えば、音声学による論理的に把握できる部分と、個人差・発声変動などデータ依存で論理的に把握しにくい部分からなる音声認識のような応用などには、このように両者が扱えるシステムが有効であろう。本論文で提案するモデルは、この具体的実現であり、今後のNNとファジィ理論の長所を併せ持った融合化研究分野において、NNへファジィ理論を導入する研究の一方を提案するものである。




Fig.8 Fusion Technology of Data-based System and Rule-based System

本論文では第2に、このモデルが持つ従来のNNにない有効性を実験を通じて明らかにした。従来単一のNNではNNの持つ判別知識が重み係数という形で分散表現され、解析が困難であった。本提案モデルは直接的に知識を表現するIF-THEN形式という高次知識表現構造に基づいてNNを構成することによって、エラーの解析を行い易くし問題箇所を特定して改良しやすくしようとするものである。本論文では、ファジィ推論ル

ールのアーキテクチャに基づいてNNを設計する手順を述べ、性能改善を行なうための解析を行い易くし、解析結果に基づいてNNを改良することで性能が向上することをシミュレーションを通じて示した。

本論文では原理的性能をシミュレーションで示したが、今後は具体的応用を通じてその効果を評価していく予定である。

## 参考文献

- [1] 高木英行：あいまいさと知識情報処理；システム／制御／情報， Vol.34， No.5， pp.263-273 (1990)
- [2] 城，森：ニューラルネットの学習における新しいタイプの教師；電子情報通信学会技術研究報告 PRU 88-94， Vol.88， No.325， pp.23-30 (1988)
- [3] 二木徹：識別問題におけるバックプロパゲーションアルゴリズムの初期値決定法；電気学会論文誌C， 110 巻， 3 号， pp.119-125 (1990)
- [4] A.Weibel, T.Hanazawa, G.Hinton, K.Shikano and K.J.Lang：Phoneme Recognition Using Time-Delay Neural Networks；IEEE Trans. Acoustic, Speech and Signal processing, Vol.37, No.3, pp.328-339 (1989)
- [5] 古谷，国分，坂本：μBRAIN：知識体実現のための構造化ニューラルネットワーク；電子情報通信学会技術研究報告 MBE 88-80， pp.57-64 (1988)
- [6] S.I.Gallant：CONNECTIONIST EXPERT SYSTEM；Commun. ACM, Vol.31, No.2, pp. 152-169 (1988)
- [7] K.Yoshida, Y.Hayashi and A.Imura：A Connectionist Expert System for Diagnosing Hepatobility Disorders；6 th Conf. on Medical Informatics (MEDINFO'89)， (North-Holland)， pp.116-120 (1989)
- [8] H.Takagi and I.Hayashi：NN-driven Fuzzy Reasoning；Int. J. Approx. Reason., Special Issue of IIZUKA-88， (1991 年掲載予定)
- [9] 廣田，吉成：ファジィクラスタリングを用いたファジィ制御規則の同定；第5回ファジィ・システム・シンポジウム， pp.253-258 (1989)

- [10] 寺野・浅井・菅野：ファジィシステム入門；オーム社（1987）
- [11] 古谷，国分，坂本：NFS：ニューラルネットワークを用いたファジィ推論システム；情報処理学会論文誌，Vol.30，No.6，pp.795-798（1989）
- [12] T.Takagi and M.Sugeno：Fuzzy Identification of Systems and Its Applications to Modeling and Control；IEEE Tran. SMC-15-1，pp.116-132（1985）
- [13] 姜，菅野：ファジィモデリング；計測制御自動制御学会論文誌，Vol.23，No.6，pp.650-652（1987）
- [14] 菅野：ファジィ制御；日刊工業新聞社，（1988）
- [15] D.E.Rumelhart, G.E.Hinton and R.J.Williams：Learning representations by back-propagating errors；Nature, No.323-9，pp.533-536（1986）
- [16] 麻生英樹：ニューラルネットワーク情報処理；産業図書（1988）のp.53 図2-5を参照
- [17] 宮本定明：階層的クラスター分析の方法-I；システム／制御／情報，Vol.33，No.8，pp.424-430（1989）（なお、Vol.34，No.6までの間に6回シリーズで書かれている）
- （1990年6月6日 受付）  
（1990年8月10日 再受付）  
（1990年9月17日 再々受付）

[問い合わせ先]

〒570 守口市八雲中町 3-15

松下電器産業株式会社 中央研究所

高木 英行

☎：06-906-2409

☎：06-906-4596


e-mail takagi@it4.crl.mei.co.jp

## 著者紹介



**高木 英行** (たかぎ ひでゆき)

松下電器産業株式会社 中央研究所  
1981年九州芸工大修士課程了。同年松下電器産業株式会社入社。同社中央研究所において、Cコンパイラ・音声WPの開発を経て、現在、音声認識・聴覚モデル・神経回路網・ファジィ理論等の研究に従事。1988年度電子情報通信学会篠原記念学術奨励賞受賞。日本音響学会，電子情報通信学会，日本ファジィ学会，神経回路学会，ISSS各会員。



**香田 敏行** (こうだ としゆき)

松下電器産業株式会社 中央研究所  
1986年神戸大学大学院工学研究科修士課程(電気工学専攻)修了。同年松下電器産業株式会社入社。同社中央研究所において、画像処理の研究を経て、現在、文字認識・神経回路網等の研究に従事。電子情報通信学会会員



**小島 良宏** (こじま よしひろ)

松下電器産業株式会社 中央研究所  
1989年神戸大学大学院工学研究科修士課程(電気工学専攻)修了。同年松下電器産業株式会社に入社。中央研究所に勤務。電子情報通信学会会員。