

## 解説



# ファジィ制御とニューラルネットワークとの融合法†

林 勲††

## 1. はじめに

1965年にL. A. Zadeh<sup>1)</sup>がファジィ集合の概念を発表してから、最近、ようやく「ファジィ」という言葉が一般用語として広く用いられてきている。それにもない、ファジィ推論が制御分野に応用され、ファジィ制御<sup>2)</sup>としての応用事例<sup>3)</sup>が200例を越えているという。当初は運転制御やプロセス制御などの大規模システムに適用され、その有効性が示されたが、一昨年には、家電製品を中心にファジィ制御の大規模な導入が実現された。ファジィ制御は、一般に専門家の定性的な知識をif-then形式のルールで表現できるので、モデルの構造が理解しやすいという特徴がある。しかし、ファジィ制御にも多くの課題がある。たとえば、専門家の知識だけにより得られたif-thenルールは実際の入出力関係を表現していない場合があり、if-thenルールの設計手法は確立していない。また、制御環境の変化に対する適応性や学習機能に対する手法も確立していない。

本論文では、特にファジィ制御のif-thenルールの設計の問題を取り上げ、この課題を解決するため、ニューラルネットワーク<sup>4)</sup>を用いた種々の手法を紹介する。ニューラルネットワークは脳神経細胞の結合にヒントを得た数理ネットワークであり、学習機能、非線形性に優れている。特に、Rumelhartら<sup>5)</sup>の誤差逆伝播学習モデルは、学習によって入出力データからその写像関係を容易に自己獲得できるので、入出力関係の論理関係が明確でない場合にも適用することができる。ここでは、if-thenルールで表現できない制御対象に対しのみ、誤差逆伝播学習モデルを用いたニューロ

& ファジィ、及びif-thenルールのメンバシップ関数を調整できるニューロ・ファジィを中心に、ファジィ制御とニューラルネットワークとの種々の融合手法を紹介する。

## 2. ファジィ制御とニューラルネットワークとの関係

ファジィ制御は、1974年にE. H. Mamdani<sup>2)</sup>によって提案された。ファジィ制御では一般に定性的な制御知識をif-thenルールで表現するが、ここでは、次のような制御ルール<sup>6)</sup>を用いる。

$$\left. \begin{array}{l} R_1: \text{if } x_1 \text{ is } F_{11} \text{ and } \dots \text{ and } x_n \text{ is } F_{1n} \\ \quad \text{then } y = f_1(x_1, \dots, x_n) \\ \quad \quad \quad \vdots \\ R_r: \text{if } x_1 \text{ is } F_{r1} \text{ and } \dots \text{ and } x_n \text{ is } F_{rn} \\ \quad \text{then } y = f_r(x_1, \dots, x_n) \end{array} \right\} \quad (1)$$

ただし、 $x_1, \dots, x_n$  は入力変数を表し、 $y$  は出力変数を表す。また、 $F_{11}, \dots, F_{rn}$  は前件部のファジィ集合を表し、 $f_1, \dots, f_r$  は非線形方程式を表す。

入力  $\mathbf{x}_i = (x_{i1}, \dots, x_{in})$ ,  $i = 1, 2, \dots, N$  が与えられたとすると、推定値の出力  $y_i^*$  は次のように計算する。

$$\mu_{Fs}(\mathbf{x}_i) = \mu_{Fs1}(x_{i1}) \times \dots \times \mu_{Fsn}(x_{in}) \quad (2)$$

$s = 1, 2, \dots, r$

$$y_i^* = \frac{\sum_{s=1}^r \mu_{Fs}(\mathbf{x}_i) \times f_s(x_{i1}, \dots, x_{in})}{\sum_{s=1}^r \mu_{Fs}(\mathbf{x}_i)} \quad (3)$$

ただし、 $\mu_{Fs}(\mathbf{x}_i)$  は前件部のメンバシップ値である。

一方、脳の構造から人間の学習機能を模擬したモデルとして、ニューラルネットワークがある。

脳はニューロンと呼ばれる140億個の膨大な数の

† Fusion Method between Fuzzy Control and Neural Networks by Isao HAYASHI (Central Research Laboratories, Matsushita Electric Industrial Co. Ltd.).

†† 松下電器産業(株)中央研究所

神経細胞から構成され、一つのニューロンは他のニューロンと結合し、ネットワーク構造を形成している。ニューラルネットワークはこのネットワーク構造を数理的に模擬したモデルである。

ニューラルネットワークの一つに誤差逆伝播学習モデルがある。ここでは、誤差逆伝播学習モデルの学習法について説明しよう。いま、入出力データ  $(\mathbf{I}_i, \mathbf{O}_i)$ ,  $i=1, 2, \dots, N$  が誤差逆伝播学習モデルに与えられたとする。ただし、 $\mathbf{I}_i=(I_{i1}, I_{i2}, \dots, I_{in})$ ,  $\mathbf{O}_i=(O_{i1}, O_{i2}, \dots, O_{iL})$ , 入力層は  $n$  個のユニット、出力層は  $L$  個のユニットがあるとしている。この場合、第  $p$  層の  $q$  番目のユニット  $u(p, q)$  の入出力関係は次のように表される。

$$x_{iq^p} = \sum_{k=1}^{\omega} \alpha_{k,q^{p-1,p}} y_{ik^{p-1}} - \theta_{q^p} \quad (4)$$

$$y_{iq^p} = f(x_{iq^p}) \quad (5)$$

$$f(x) = \frac{1}{1 + \exp(-x)} \quad (6)$$

ただし、 $x_{iq^p}$  は、第  $i$  番目の入出力データに対するユニット  $u(p, q)$  の入力の総和であり、 $y_{iq^p}$  は出力である。また、 $\alpha_{k,q^{p-1,p}}$  は  $u(p-1, k)$  から  $u(p, q)$  へのユニット間の結合強度を表し、 $\theta_{q^p}$  は  $u(p, q)$  のしきい値を表す。さらに、第  $p-1$  層は  $\omega$  個のユニットがあると仮定している。

いま、学習アルゴリズムによる  $O_{iq}$  の推定値を  $EO_{iq}$  とすると、誤差逆伝播学習モデルでは、次の  $E_i$  を最小にする  $\alpha_{k,q^{p-1,p}}$  を求めることにより、ネットワークの構造を決定する。

$$E_i = \left( \sum_{q=1}^L (O_{iq} - EO_{iq})^2 \right) / 2 \quad (7)$$

$E_i$  を減少させるためのシナプス結合  $\alpha_{k,q^{p-1,p}}$  の変化量は、最急降下法<sup>7)</sup>により次のように計算できる。

$$\Delta \alpha_{k,q^{p-1,p}} = \eta \delta_q y_{ik^{p-1}} \quad (8)$$

ただし、

1) 第  $p$  が出力層の場合

$$\delta_q = \frac{\partial f}{\partial x_{iq^p}} \times (O_{iq} - EO_{iq}) \times y_{ik^{p-1}} \quad (9)$$

2) 第  $p$  が出力層でない場合

$$\delta_q = \frac{\partial f}{\partial x_{iq^p}} \times \sum_g \delta_g \alpha_{g,q^{p,p+1}} \quad (10)$$

であり、 $\eta$  は定数である。

(7)式を減少させるように、 $\alpha_{k,q^{p-1,p}}$  を出力層から入力層に順番に伝播して変更していくので、

この学習法は誤差逆伝播学習と呼ばれている。

ここでは、入力を  $\mathbf{x}=(x_1, x_2, \dots, x_n)$ , 出力を  $\mathbf{y}=(y_1, y_2, \dots, y_L)$  とするときの誤差逆伝播学習モデルの入出力関係を次のように記号的に表す。

$$\mathbf{y} = NN(\mathbf{x}) \quad (11)$$

誤差逆伝播学習モデルは、環境が動的に変化する場合でも、この学習機能により入出力関係を容易に同定することができる。

最近、ファジィ制御とニューラルネットワークとを融合した数多くのモデル<sup>8)</sup>が提案されている。これらのモデルは、ニューラルネットワークの学習機能や非線形性を用いてファジィ制御の問題を解決するために提案された。たとえば、次の二つの問題を考えることができる。

- ファジィ制御では、if-then ルールの設計手法が確立しておらず、入出力関係を十分に表現することができない場合がある。

- ファジィ制御は、制御環境の変化に対する適応性や学習機能がない。

前者の問題を解決するために、誤差逆伝播学習モデルを用いて、推定誤差の最も小さい if-then ルールを構築するモデルが数多く提案されているが、日本では、ファジィ制御の実用化が盛んであることから、この研究が主流を占めている。一方、後者の問題を解決するためには、ファジィ制御と誤差逆伝播学習モデルとの併用によって、適応性や学習機能を備えた制御システムが提案されている。本論文では、特に前者のモデルについて、その概略を説明する。

ファジィ制御では、非線形な入出力関係を表すことができる。しかし、専門家の知識だけによる if-then ルールから得られたモデルは実際の入出力関係を表現していない場合がある。通常は、推論値と出力データとの差が最小になるようにモデルを調整・再構築する必要がある<sup>9)</sup>。このモデルの調整・再構築の方法として、次の2種類がある<sup>10)~12)</sup>。

1) 非線形な入出力関係の中で、if-then ルールとして記述できる対象に対してはファジィ制御を用い、表現できない対象には誤差逆伝播学習モデルを用いる方法。

2) モデルとして if-then ルールのみを用いるが、誤差逆伝播学習モデルの学習により非線形な入出力関係を表現できるように、ルールのメンバ

シップ関数の形状を調整する方法.

第1の方法は「ニューロ & ファジィ」と呼ばれている. この手法には, 同一の制御対象に対して, ファジィ制御と誤差逆伝播学習モデルとを個別に適用したモデルと, ファジィ制御の実行時に制御量を誤差逆伝播学習モデルで補正するモデルの2種類が提案されている. 前者のモデルは, 専門家の知識を if-then ルールとして記述できる対象に対してはファジィ制御を用い, 表現できない対象には誤差逆伝播学習モデルを用いる. ただし, ファジィ制御と誤差逆伝播学習モデルの間には直接, 関連性はない. 後者のモデルは, 基本的には数式モデルとしてファジィ制御を用いるが, ファジィ制御の推論値と出力データとの差を誤差逆伝播学習モデルを用いて同定し, 非線形な入出力関係を同定できるように推論値を補正するモデルである. 図-1 に前者のモデルの概念図を示し, 図-2 に後者のモデルの概念図を示す. 家電製品などでの応用では, これらの2種類とも用いられている.

一方, 第2の方法は「ニューロ・ファジィ」と呼ばれている. 図-3 に概念図を示す. 誤差逆伝播学習モデルの逐次的な学習法を用いて, ファジィ制御の if-then ルールを構築する. また, if-then




図-1 ニューロ & ファジィの概念図(1)




図-2 ニューロ & ファジィの概念図(2)




図-3 ニューロ・ファジィの概念図

ルールを階層的にしたモデルも提案されている. これらは適応制御や学習制御の一種であるともいえるが, 家電製品などでの応用では学習後のモデルが使われている.

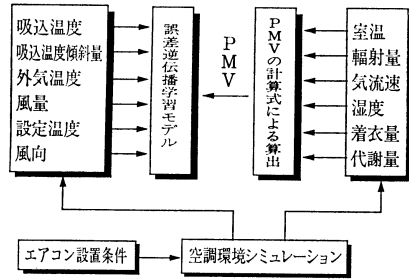
ここでは, ニューロ & ファジィとニューロ・ファジィの代表的な手法を紹介して, これらの違いを明らかにしよう.

### 3. ニューロ & ファジィとは

#### 3.1 二つのモデルを併用したニューロ & ファジィ

まず, ファジィ制御と誤差逆伝播学習モデルとが個別に適用されているニューロ & ファジィのモデルについてエアコンの応用事例<sup>13)</sup>を用いて説明しよう. このエアコンでは, 誤差逆伝播学習モデルを用いて室内機の温度を調整する制御モデルを構成し, ファジィ制御を用いて室外機のコンプレッサの凍結防止を制御している.

室内機では, 吸込温度, 吸込温度傾斜量, 外気温度, 風量, 設定温度, 及び風向などのデータをセンサで検知し, 人間の快適さを保持するように温度を制御している. しかし, これらの入出力関係を if-then ルールを用いて論理的に表現することは困難である. ここでは, 誤差逆伝播学習モデルを用いて入出力関係を同定している. 図-4 に本事例で用いる誤差逆伝播学習モデルを示す. この誤差逆伝播学習モデルは, 空調環境シミュレーションで作成した吸込温度, 吸込温度傾斜などの6入力のデータを誤差逆伝播学習モデルに入力し, 室温, 輻射量などから得られたPMV<sup>14)</sup>値を出力値として学習を行う. PMVとは, 数式モデルによって得られた快適さを定義する指標であり, 温度(°C), 周囲壁休輻射温度(°C), 気流速(m/s), 湿度(%), 着衣量(clo), 代謝量(met)か

図-4 誤差逆伝播学習モデルの学習過程<sup>13)</sup>

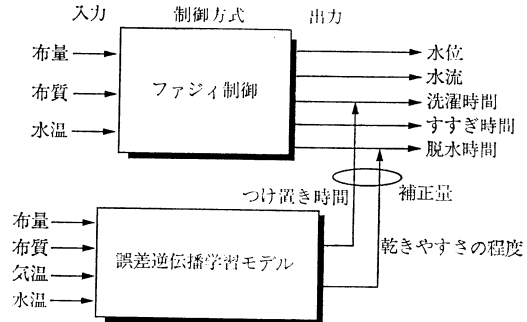
ら、 $[-0.5, 0.5]$  の PMV 値を得る。PMV 値は 0 の値が快適として定義され、 $\pm 0.5$  に近づいたがって不快さが増す。

室内機では、誤差逆伝播学習モデルが推定した PMV 値に基づいて、PMV 値が 0 よりも小さい場合には目標設定温度を上げ、逆の場合には目標設定温度を下げる制御を風量とともにやっている。

一方、ファジィ制御では、エアコンの暖房時における室外機のコンプレッサのデアイスの時間(分)を制御している。冬季に暖房用としてエアコンを動作させる場合、長時間の運転ではコンプレッサのまわりの温度が低下しコンプレッサが凍結する。凍結を防止するためには、コンプレッサを一定時間だけ停止させる必要がある。この停止時間をデアイス時間という。デアイス時間を決定するには、周囲温度と温度の変化量を用いる必要があり、容易には数式で表現することができなかった。ここでは、専門家の知識を用いて、if-then ルールとして構成している。ファジィ制御により、着霜状況に応じた効率の良い凍結防止運転を可能にし、暖房効率を向上させることができる。

### 3.2 制御量を補正するニューロ & ファジィ

次に、ファジィ制御の実行時に誤差逆伝播学習モデルを用いて制御量を補正するモデルについて説明する。図-5 にニューロ & ファジィを採用した洗濯機<sup>10)</sup>の制御方法を示す。この洗濯機では、布量、布質、水温の入力変数からファジィ制御により、洗濯時間、脱水時間などを推定する。しかし、これらの入出力関係は非線形性が強く、容易には if-then ルールを決定できない。ニューロ & ファジィでは、if-then ルールを正確に作成するかわりに、誤差逆伝播学習モデルを用いてファジィ制

図-5 ニューロ & ファジィを採用した洗濯機の制御方法<sup>10)</sup>

御の推定値を微調整する。具体的には、布質、気温、水温、の入力変数から誤差逆伝播学習モデルによって汚れの落ちやすさを推定し、洗濯工程の前のプロセスであるつけ置き時間が決定され、洗濯時間が微調整される。また、別の誤差逆伝播学習モデルにより、布量、布質、気温の入力変数から、洗濯物の乾きやすさの程度も推定し、脱水時間を微調整している。これらの2種類の誤差逆伝播学習モデルは、入力層、中間層、出力層がそれぞれ、3個、7個、1個のニューロンで構成されている3層構造である。学習のためのデータは、前者で192個、後者で、120個の実験データを用いている。

その他、ニューロ & ファジィの事例として、すすぎ時間を誤差逆伝播学習モデルで決定する洗濯機<sup>10)</sup>などもある。

## 4. ニューロ・ファジィとは

ファジィ制御にはチューニングの課題がある。チューニングとは、プロダクションルールを構築した後に、推論値と出力データとの差が最小となるようにファジィ推論ルールを変更・再構成する作業をいう。誤差逆伝播学習モデルの学習機能を用いて、このチューニングの問題を解決するモデルをニューロ・ファジィと呼ぶ。ここでは、二つのニューロ・ファジィモデルを紹介する。

### 4.1 ニューラルネット駆動型ファジィ推論

ニューラルネット駆動型ファジィ推論モデル<sup>15)</sup>は、前件部のファジィ集合と後件部の入出力関係を誤差逆伝播学習モデルを用いて同定する。いま、入力変数  $x_1, x_2, \dots, x_n$  と出力変数  $y$  による入出力データ  $(x_i, y_i) = (x_{i1}, x_{i2}, \dots, x_{in}, y_i)$ ,  $i = 1, 2, \dots, N$  が得られたとしよう。このとき、入出

カデータからファジィ推論ルールを構成する。  
 まず、前件部のファジィ集合を同定する手法について説明する。推論ルールの個数  $r$  が与えられたとすると、これらの境界領域を決定するため、 $N$  個の入力データ  $\mathbf{x}_i$  を複数のグループ  $C_s$ ,  $s=1, 2, \dots, r$  に分割する。入力データ  $\mathbf{x}_i$  が各分割  $C_s$  に属する度合  $Z_{is}$  を次のように定義する。

$$Z_{is} = \begin{cases} 1: \mathbf{x}_i \text{ が } C_s \text{ に属する場合} \\ 0: \mathbf{x}_i \text{ が } C_s \text{ に属さない場合} \end{cases} \quad (12)$$

次に、誤差逆伝播学習モデルの入力層に  $\mathbf{x}_i = (x_{i1}, x_{i2}, \dots, x_{in})$  を割り付け、出力層に  $\mathbf{Z}_i = (Z_{i1}, Z_{i2}, \dots, Z_{is}, \dots, Z_{ir})$  を割り付けて学習を行う。学習後、与えられた入力データ以外のデータ  $\mathbf{x}_v$ ,  $v=1, 2, \dots, K$  を誤差逆伝播学習モデルに入力する。得られる出力値  $\mathbf{EZ}_v = NN(\mathbf{x}_v)$  を用いて、第  $S$  番目のルールのメンバシップ値  $\mu_{Fs}(\mathbf{x}_i)$  を次のように定義する。

$$\mathbf{EZ}_v = (EZ_{v1}, \dots, EZ_{vs}, \dots, EZ_{vr}), \quad v=1, 2, \dots, K \quad (13)$$

$$\mu_{Fs}(\mathbf{x}_i) = EZ_{is}, \quad i=1, 2, \dots, N \quad (14)$$

前件部のメンバシップ関数を決定する例を図-6 に示す。図-6 では、たとえば入力データの1番目は  $(x_{11}, x_{12}) = (0.2, 0.15)$  であり、 $(R_1, R_2, R_3) = (1, 0, 0)$  となる。これらの関係をそれぞれ、誤差逆伝播学習モデル  $NN_{mem}$  の入力層と出力層に割り付けて構造を学習する。学習を行った後、たとえば、与えられた入力データ以外の新たなデータ  $(x_1, x_2) = (0.5, 0.4)$  を誤差逆伝播学習モデルに入力することにより、そのデータのメンバシップ値  $(R_1, R_2, R_3) = (0.4, 0.1, 0.2)$  を得る。

一方、各推論ルール  $R_s$  の後件部では、誤差逆伝播学習モデル  $NN_s$  を用いて、(1)式の  $f_s$  を




図-6 前件部のメンバシップ関数を決定する例




図-7 ニューラルネットワーク駆動型ファジィ推論の構成図

次のように定義する。

$$y_s = NN_s(\mathbf{x}), \quad s=1, 2, \dots, r \quad (15)$$

本手法のアルゴリズムの概念図を図-7 に示し、推論ルールの構成手順を次に示す。

- (ステップ1) 出力  $y$  に関連のある入力変数  $x_1, x_2, \dots, x_n$  を設定する。
- (ステップ2) 入力データを  $r$  分割し、図-7 の  $NN_{mem}$  を用いて前件部のメンバシップ関数の形状を決定する。
- (ステップ3) 図-7 の  $NN_1, NN_2, \dots, NN_r$  を用いて変数減少手順<sup>15)</sup>を行い、後件部の最適な誤差逆伝播学習モデルを求める。
- (ステップ4) 推定値  $y_i^*$  を、(2), (3)式により計算する。ただし、 $f_s(x_{i1}, \dots, x_{in})$  はステップ3での最適な誤差逆伝播学習モデルにより得られた推定値である。

#### 4.2 降下法ファジィ制御

降下法ファジィ制御<sup>16)</sup>では、ファジィ制御として簡略ファジィ推論<sup>17)</sup>を用いる。簡略ファジィ推論では、後件部の  $f_s$  は実数  $w_s$  となる。簡略ファジィ推論は、通常のファジィ推論よりも制御結果が良好であることが報告されている<sup>18)</sup>。

本手法では、前件部のファジィ数  $F_{sj}$  を三角形のメンバシップ関数とし、中心  $a_{sj}$  と幅  $b_{sj}$ 、及び後件部の  $w_s$  を最急降下法により調整する。ただし、この調整は、入力データ  $\mathbf{x}_i$  が入力された場合のファジィ推論の推定値  $y_i^*$  と出力値  $y_i$  との推定誤差  $E$  を




図-8 降下法ファジィ制御の構成図

最小にするように行う。

$$E = (y_i - y_i^*)^2 / 2 \quad (16)$$

この場合、 $E$  の値が最も減少する方向を示すベクトルは  $(-\partial E / \partial a_{sj}, -\partial E / \partial b_{sj}, -\partial E / \partial w_s)$  となる。

図-8 に本手法の構成図を示し、推論ルールを構築する手順を次に述べる。

(ステップ1) 出力  $y$  に関連のある入力変数  $x_1, x_2, \dots, x_n$  を設定する。

(ステップ2) 入力データ  $x_i$  に対するファジィ推論を行い、推論値  $y_i^*$  を求める。

(ステップ3) 最急降下法により、次式を用いて後件部の実数値  $w_s$  を更新する。

$$w_s^{t+1} = w_s^t - \frac{G_w \cdot \mu_{Fs}}{\sum_{s=1}^r \mu_{Fs}} \cdot (y_i - y_i^*) \quad (17)$$

ただし、 $G_w$  は学習係数であり、 $w_s^t$  は第  $t$  回目の更新により得られた実数値を表す。

(ステップ4) 同様にして、前件部のメンバシップ関数の中心値  $a_{sj}$  と幅  $b_{sj}$  を更新する。

$$a_{sj}^{t+1} = a_{sj}^t - \frac{G_a \cdot \mu_{Fs}}{\sum_{s=1}^r \mu_{Fs}} \cdot (y_i - y_i^*) \cdot \frac{2 \cdot (w_s^t - y_i^*) \cdot \text{sgn}(x_{ij} - a_{sj}^t)}{b_{sj}^t \cdot \mu_{Fs}(x_{ij})} \quad (18)$$

$$b_{sj}^{t+1} = b_{sj}^t - \frac{G_b \cdot \mu_{Fs}}{\sum_{s=1}^r \mu_{Fs}} \cdot (y_i - y_i^*) \cdot \frac{(1 - \mu_{Fs}(x_{ij}))(y_i - y_i^*)(w_s^t - y_i^*)}{\mu_{Fs}(x_{ij}) \cdot b_{sj}^t} \quad (19)$$

ただし、 $G_a, G_b$  は学習係数であり、 $\text{sgn}$  は次式のような関数を表す。

$$\text{sgn}(z) = \begin{cases} -1 & (z < 0) \\ 0 & (z = 0) \\ 1 & (z > 0) \end{cases} \quad (20)$$

(ステップ5) 次式を満足する場合はアルゴリズムを停止する。

$$E^t - E^{t+1} \leq \epsilon \quad (21)$$

ただし、 $E^t$  は第  $t$  回目の学習による(16)式を示し、 $\epsilon$  はしきい値である。

これらのニューロ・ファジィを掃除機に応用した事例を紹介する。掃除機ではゴミ量、ゴミの種類、及び床面の種類から吸い込み力を制御できる。ゴミセンサの動作原理を図-9 に示す。発行ダイオードとフォトトランジスタとの間をゴミが通過するとき受光量が変化し、この変化分からパルスを生成し、パルス幅の大小によってゴミの量と種類を判別する。図-10 に吸い込まれたゴミの




図-9 ゴミセンサの動作原理




図-10 ゴミ量の時間的変化

時間的な変化量を示す。この変化量により床面の種類を決定する。たとえば、畳や木床の場合はゴミが取れやすいので、短時間でゴミ量が少なくなり、一方、絨毯の場合は少なくなるらない。これらのゴミ量、ゴミの種類、及び床面の種類の3入力から、吸い込み量を制御する if-then ルールをニューロ・ファジィで構築している。入出力データは家庭や実験室で観測し、45個の if-then ルールを構成した。ファジィ制御で制御することにより、吸い込み力が強すぎて床ノズルが床面に吸いついて操作がしにくかったり、逆に、吸い込み力が足りずにゴミを吸い残してしまうことがなくなった。

このほかのニューロ・ファジィのモデルとして、if-then ルールの後件部は最急降下法を用いて調整するが、推論誤差の大きい領域に逐次的にルールを発生させる方法<sup>19)</sup>や、その発生過程において、前件部のメンバシップ関数の形状を内点ペナルティ法で調整する方法<sup>20)</sup>などが提案されている。これらの方法は、メンバシップ関数の調整のみならず、if-then ルールを自動発生できるので、その有用性は高い。

5. その他の融合法

ファジィ制御とニューラルネットワークとの融合手法として、誤差逆伝播学習モデル以外を用いた融合手法も多く提案されている。ここでは、その中で二つの手法を紹介する。

5.1 ファジィ連想記憶

1988年に、B. Kosko<sup>21)</sup>はニューラルネットワークを用いた連想記憶の一つのモデルとして、双方向連想記憶 (BAM: Bidirectional Associative Memories) を提案している。BAMでは2層のニューラルネットが相互に結合するようにネットワークを構成し、入出力間の双方向に演算処理を行い、パターンの想起を可能としている。このBAMを用いてファジィ推論ルールを表現するファジィ連想記憶<sup>22)</sup>が提案されている。図-11にファジィ連想記憶の概念図を示す。ファジィ連想記憶は、1)前件部と後件部との関係、2)前件部の命題、3)後件部の命題の三つから構成されている。図-11では、前件部と後件部との関係を Rule-part で表し、前件部の

命題を If-part、後件部の命題を Then-part で表している。If-partと Rule-part、および Then-part と Rule-Part とは BAM を構成している。前件部のユニット S, M, B はそれぞれ, Small, Medium, Big を表すメンバシップ関数を表現している。また、後件部のユニット  $f_1, f_2, \dots, f_r$  は与えられている出力関数を表す。

学習過程では、Rule-part の各 if-then ルールを表すユニットは互いに抑制する結合をもち、常にただ一つの if-then ルールを想起しようとする性質をもつ。推論値は、各ユニットの出力値の度合で出力関数が合成されることにより得られる。

5.2 CMAC・ファジィシステム

人間の小脳の機能を模倣した神経回路網モデルとして、CMAC<sup>23)</sup> (Cerebellar Model Arithmetic Computer) がある。CMACでは複数の顆粒細胞のサブモデルを構成し、これらのサブモデルが並列的に値を出力し、出力値の和を求めることにより推論値を計算する。顆粒細胞モデルは、CMACの推論値と出力データとの差を小さくするようにモデルのパラメータを学習する。このCMACを用いたCMAC・ファジィシステム<sup>24)</sup>が提案されている。図-12にCMAC・ファジィシステムの構成図を示す。CMAC・ファジィシステムでは、制御対象から得られた入出力データを用いて、CMACが逐次学習を行う。学習後のCMACの推論値を用いて if-then ルールの後件部の実数値をチューニングする。この手順を1回の操作として、ファジィ推論の推論誤差が改善されなくなるまで操作を繰り返す。

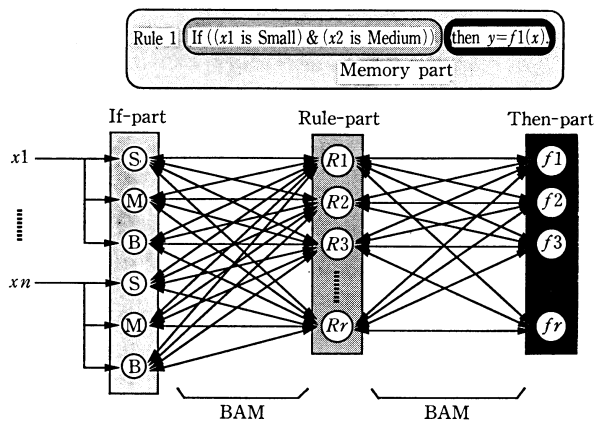


図-11 ファジィ連想記憶システムの概念図<sup>22)</sup>

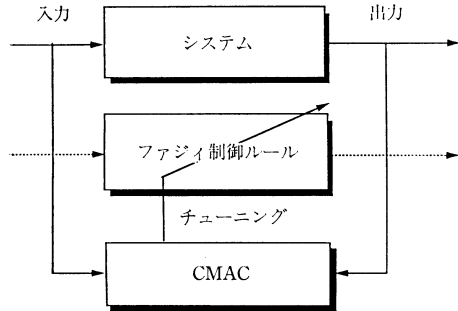


図-12 CMAC・ファジィシステムの構成図

## 6. おわりに

ファジィ制御の実用化には多くの問題が残されている。ここでは、if-then ルールの設計手法の問題を取りあげ、ニューラルネットワークの学習機能や非線形性を用いて、この問題を解決する種々の手法を紹介した。このほかの融合手法として、ニューラルネットワークの入出力データとしてファジィ数を取り扱ったり、ニューラルネットワークの構造をファジィ化する研究もある。その他、入力空間をファジィに分割して、個々の部分空間に対してニューラルネットワークを用いるモデルなどもある。

これらの融合研究は、将来、人間の思考、感性などのモデルを研究するうえで大いに参考となるであろう。今後、より実証的な研究により、その有用性を検討する必要がある。

## 参考文献

- Zadeh, L. A.: Fuzzy Sets, Inf. Control, Vol. 8, pp. 338-353 (1965).
- Mamdani, E. H. and Assilian, S.: An Experiment in Linguistic Synthesis with a Fuzzy Logic Controller, Int. J. Man-Mach. Stud., Vol. 1, No. 7, pp. 1-13 (1974).
- 日本ファジィ学会編集委員会編: 特集「ファジィ応用製品・技術」, 日本ファジィ学会誌, Vol. 3, No. 2, pp. 154-211 (1991).
- 甘利俊一: 神経回路網の数理, 産業図書 (1978).
- Rumelhart, D. E., Hinton, G. E. and Williams, R. J.: Learning Representations by Back-Propagation Errors, Nature, Vol. 323, No. 9, pp. 533-536 (1986).
- 菅野道夫: ファジィ制御, 日刊工業新聞社 (1988).
- 今野 浩, 山下 浩: 非線形計画法, 日科技連 (1978).
- 高木英行: あいまいさと知識情報処理, システム制御情報学会誌, Vol. 34, No. 5, pp. 263-273 (1990).
- 前田幹夫, 村上周太: 自己調整ファジィコントローラ, 計測自動制御学会論文集, Vol. 24, No. 2, pp. 191-197 (1988).
- 浅見直樹, 今井拓司: 家電業界に新たな潮流, ニューラル・ネットとファジィを組み合わせる, 日経エレクトロニクス, No. 528, pp. 165-169 (1991).
- 市橋秀友: ファジィ制御の簡易化とニューロ・ファジィ, ファジィ化製品開発の基礎と実際, 海文堂, pp. 27-48 (1991) (長町三生編).
- 林 勲: ニューラルネットワークとファジィ制御との融合手法, 電子技術, Vol. 34, No. 1, pp. 17-20 (1992).
- 中 基孫, 志田武彦, 吉田邦夫, 赤嶺育雄: ニューラルネットの空調機器への応用, 電子情報通信学会ヒューマンコミュニケーション研究会, HC 91-37, pp. 9-16 (1991).
- Fanger, P. O.: Thermal Comfort-Analysis and Application in Environmental Engineering, McGraw-Hill (1970).
- 林 勲, 野村博義, 若見 昇: ニューラルネット駆動型ファジィ推論による推論ルールの獲得, 日本ファジィ学会誌, Vol. 2, No. 4, pp. 585-597 (1990).
- 野村博義, 林 勲, 若見 昇: デルタルールによるファジィ推論の自動チューニング手法と障害物回避への応用, 日本ファジィ学会誌, Vol. 4, No. 2, pp. 379-388 (1992).
- 市橋秀友, 渡辺俊彦: 簡略ファジィ推論を用いたファジィモデルによる学習型制御, 日本ファジィ学会誌, Vol. 2, No. 3, pp. 429-437 (1990).
- 水本雅晴: ファジィ制御に対する改善法 (II), 第4回ファジィシステムシンポジウム講演論文集, pp. 91-96 (1988).
- 荒木昭一, 野村博義, 林 勲, 若見 昇: ルールを逐次的に生成するファジィモデリングの一提案, 日本ファジィ学会誌, Vol. 4, No. 4, pp. 722-732 (1992).
- 梶谷雄治, 片山 立, 西田行輝: ペナルティ法を用いたファジィ知識の自動獲得, 第8回ファジィシステムシンポジウム講演論文集, pp. 257-260 (1992).
- Kosko, B.: Adaptive Bidirectional Associative Memories, Appl. Opt., Vol. 2, No. 23, pp. 4947-4960 (1987).
- 山口 亨, 高木友博, 田鍋 実: ファジー連想記憶による知的センサーアーキテクチャ, 電子情報通信学会論文誌 C-II, Vol. J74-C-II, No. 5, pp. 289-299 (1991).
- Albus, J. S.: Brains, Behavior and Robotics, McGraw Hills (1981) ((訳) 小杉他: ロボティクス, 啓学出版 (1984)).
- 小澤 順, 林 勲, 若見 昇: ファジィモデリングのための CMAC による入出力データの検討手法の一提案, 第7回ファジィシステムシンポジウム講演論文集, pp. 435-438 (1991).

(平成4年8月11日受付)



## 林 勲

昭和56年大阪府立大学工学部経営工学科卒業。同年より昭和58年までシャープ(株)に勤務。昭和60年大阪府立大学大学院博士前期課程修了。昭和62年松下電器産業(株)に入社。以来、中央研究所にてファジィ推論とニューラルネットワークとの融合、ファジィ検索の研究に従事。工学博士。平成3年電気関係学会関西支部連合大会講演会奨励賞受賞。電気学会、日本ファジィ学会、IFSA (International Fuzzy Systems Association) 各会員。