

神経回路網モデルによるファジィ推論の定式化

高木, 英行
松下電器産業株式会社中央研究所

林, 勲
松下電器産業株式会社情報システム研究所

<https://hdl.handle.net/2324/4479723>

出版情報 : ファジィシステムシンポジウム講演論文集, pp. 55-60, 1988-05-30. 日本ファジィ学会
バージョン :
権利関係 :

神経回路網モデルによるファジィ推論の定式化

Formulation of Fuzzy Reasoning by Neural Network

林 勲¹
Isao HAYASHI

高木 英行²
Hideyuki TAKAGI

松下電器産業株式会社 情報システム研究所¹ 中央研究所²
Matsushita Electric Industrial Co., LTD.

Information Systems Research Laboratory¹ Central Research Laboratories²

ABSTRACT

In this paper, we propose Fuzzy Modeling formulated by Neural Network (NN). In Fuzzy Reasoning, the linguistic rules are represented by using propositions "IF x is A and y is B, THEN z is C". In Fuzzy Modeling that has been proposed by M.Sugeno, $z = f(x)$ is used instead of the proposition "z is C". Our method can obtain parameters in this function $f(x)$ and linguistic variables definitively and easily, because NN has non-linearity and self-organization feature. This is a new method combined Fuzzy Reasoning and NN.

1. はじめに

最近、ファジィ推論¹⁾が制御分野に応用され、ファジィ制御²⁾として実用化^{3),4)}されている。ファジィ制御とはIF---THEN---形式による、あいまいな自然言語を用いた制御法である。ファジィ制御はシステムが非線形である場合に有効であり、制御規則を自然言語で記述できるので、設計者が熟練者でなくても制御規則の設計が可能である。一方、ファジィ制御のTHENの部分の線形方程式にしたファジィ推論法として菅野らが提案したファジィモデル^{5),6)}がある。菅野らは統計的手法による推論規則の定式化を提案し、オートチューニング可能なファジィモデルの構築に大きく貢献した。しかし、計算アルゴリズムは発見的解法に基づいているため、複雑で、決定すべきパラメータ数も非常に多い。なお、ファジィモデルを得るためのモデリング手法をファジィモデリングと言う。

本論文では、神経回路網モデル⁹⁾を用いて、ファジィモデルを定式化する。神経回路網モデルと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る。回路網を構成するユニットは神経細胞の数理モデルである。ユニット間の接続強度を逐次学習で決定することにより、神経回路網モデル全体としては非線形問題を解くことができる。本論文ではこの能力を用いて、推論規則のTHENの部分の制御量推定式を同定し、かつ、IFの部分のファジィ変数・変数空間の分割の決定も行なう。神経回路網モデルを用いたファジィモデルの定式化とそのアルゴリズムを述べ、その性質を議論する。神経回路網モデルを用いたファジィモデリングは従来のファジィ推論に学習機能を持つ神経回路網の概念を導入した新しいモデル化手法であり、自己組織的なファジィ推論方法と言える。

2. ファジィモデリング

ファジィモデリング^{5),6)}とは、ファジィ推論規則やファジィ制御規則を決定し、システムのファジィモデルを構築することである。ファジィモデリングでは得べき制御操作量が実数値であるので、次の推論規則を用いる。ただし、ここでは簡単化のために多入力一出力としている。

$$R^s: \text{IF } x_1 \text{ is } A_1^s \text{ and } x_2 \text{ is } A_2^s \text{ and } x_m \text{ is } A_m^s \text{ THEN } y^s = a_0^s + a_1^s x_1 + a_2^s x_2 + \dots + a_m^s x_m, \quad s=1,2,\dots,r \quad (1)$$

ここで、 R^s はs番目の推論規則を意味し、 A_j^s , $j=1,2,\dots,m$ はファジィ変数¹⁾, a_j^s は後件部の線形式の係数、 y^s は出力変数である。入力 $x_1^s, x_2^s, \dots, x_m^s$ に対する制御操作量 y^s は y^s の重み付き平均として次のように得られる。

$$y^s = \frac{\sum_{i=1}^m w_i^s \cdot y^s}{\sum_{i=1}^m w_i^s} \quad (2)$$

ただし、

$$w^s = \mu_{A_1^s}(x_1^s) \times \mu_{A_2^s}(x_2^s) \times \dots \times \mu_{A_m^s}(x_m^s) \quad (3)$$

$$y^s = a_0^s + a_1^s x_1^s + a_2^s x_2^s + \dots + a_m^s x_m^s \quad (4)$$

である。ここで、(3)式の w^s は各入力変数の直積空間 $E = X_1 \times X_2 \times \dots \times X_m$ でのファジィ数 $A^s = (A_1^s, A_2^s, \dots, A_m^s)$ に対する入力変数 $x_1^s, x_2^s \in X_j$ のメンバシップ値を表わす。

3. 神経回路網モデル

脳神経系での情報処理機構を数理工学的に解明しようとの試みは、連想記憶や学習機械の研究として古くから行なわれていた^{7),8)}。近年、学習機械パーセプトロンの効果的な学習アルゴリズム backpropagation⁹⁾が発表され、非線形モデルの同定問題を解くモデルとして各種のパターン分類や推定の問題に適用され^{10),11)}、神経回路網モデルの情報処理能力が再び注目されるに至った。本論文では神

経回路網モデルの非線形問題の推定能力を利用し、ファジィモデリングによる(1)式の推論規則を得るための定式化を行なう。次に、神経回路網モデルを数理的に説明する。

生物の神経細胞は他の複数の神経細胞からシナプス結合を介して信号を受け取る。これ等の入力信号が閾値以上であれば神経パルスを発火し、以下であれば発火しない。以上の生理学的知見を工学的に表現したモデル例が図1に示す多入力一出力の非線形回路であり、数理モデルとして入力 x と出力 y の関係を(5)式で表わす。

$$y_i = f\left(\sum_j \alpha_{ji} x_{ji} + \alpha_0\right) \quad (5)$$

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

ここで α はシナプス結合をモデルに反映させた結合強度である。(6)式に sigmoid関数を用いるのは、2値関数的かつ backpropagation で要求される微分可能性を満足しているからである。

この神経細胞モデルをネットワーク結合したものが神経回路網モデルである。本論文では backpropagation アルゴリズムで学習する k 層パーセプトロンを神経回路網モデルとして採用して本提案のファジィモデリングを評価する。しかし、本提案の方法は神経回路網モデルを k 層パーセプトロンに限定するものではない。なお、情報処理能力の観点から4層以上のモデルにする必要はない¹²⁾。

本論文で用いる神経回路網モデルを定義しておく。

【定義1】

- (a) k 層パーセプトロンとは1層の出力層と $(k-1)$ 層の中間層を持つモデルである。
- (b) 神経回路網の入出力関係を(7)式で表現する。

$$y = NN(x) \quad (7)$$
- (c) モデルの規模を k 層 $[u_0 \times u_1 \times \dots \times u_k]$ で表現する。 u_i は各々入力層、中間層、出力層の神経細胞モデルの数である。
- (d) 入力層と中間層は、上記(c)以外に定数1のユニットをもつ。このユニットは下層の神経細胞モデルからの結合はないが、上層の神経細胞とは結合を持つ。
- (e) 隣接する層の神経細胞モデルは全て結合する。同一層内や層を飛び超えての結合はない。

(d)は(5)式の α_0 を表現するためである。また、(e)は4.4章の実験で用いるモデルの説明であり、神経回路網としては本質的ではない。例として、図2に3層 $[3 \times 2 \times 2 \times 2]$ パーセプトロン型の神経回路網モデルを示す。図2の場合(7)式は次式で表現される。

$$y = NN(x) = f\left(\sum_{k=1}^3 \alpha_{3k} f_k\left(\sum_{j=1}^2 \alpha_{2j} f_j\left(\sum_{i=1}^2 \alpha_{1i} x + \alpha_{10}\right) + \alpha_{20}\right) + \alpha_{30}\right)$$

神経回路網モデルの特徴として、非線形性と学習能力のために非常によく学習データに合ったモデル同定が可能である。このため、学習データが偏ったデータであった場合、学習データには大変よく合うが評価データにはあまり合わないということも有り得る。したがって、学習データは偏りなく多く与えることが、性能のよいモデル同定のポイントとなる。

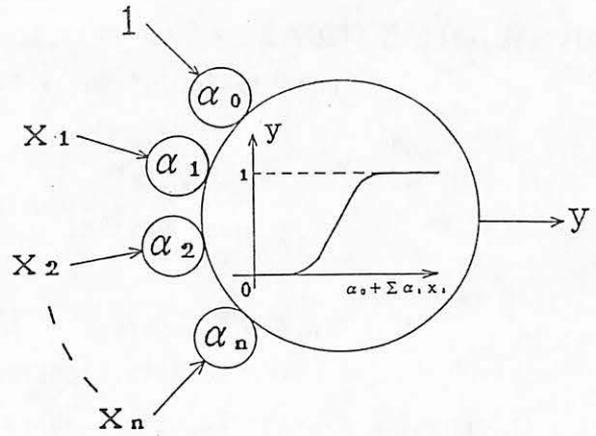


図1 神経細胞の数理モデル

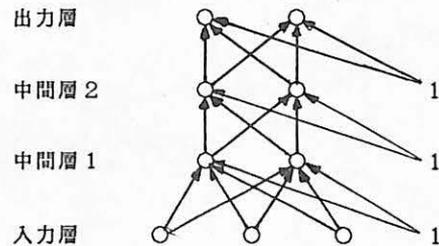


図2 3層パーセプトロン型神経回路網モデルの例

4. 神経回路網モデルによるファジィモデリングの定式化

ファジィモデルの定式化とは、(1)式の前件部、および後件部のそれぞれの構造同定を意味する。以下、前件部、および後件部の構造同定について説明する。

4.1 前件部の構造同定

前件部の構造同定とは入力変数の直積空間 E における推論規則の空間分割、および各ファジィ変数を表わすメンバシップ関数を決定することを意味する。ここでは、この推論規則による空間分割、およびメンバシップ関数の決定問題を規則クラスタリングと呼ぶ。例えば、次の推論規則を用いた規則クラスタリングを考えよう。

- R^1 : IF x_1 is Small and x_2 is Small THEN $y=x+2$
 - R^2 : IF x_1 is Big and x_2 is Small THEN $y=-1/2x+4$
 - R^3 : IF x_2 is Big THEN $y=2x+5$
- 規則クラスタリングを図3に示す。各推論規則 $R^1, R^2,$

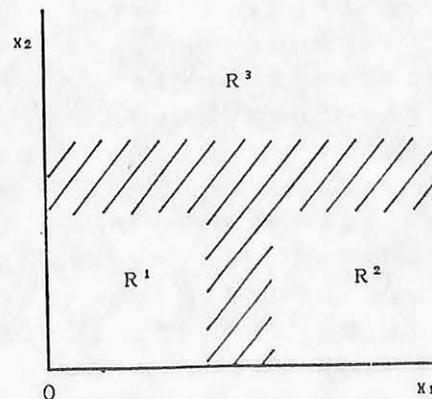


図3 規則クラスタリングの例

R^s が入力変数の空間分割を表わしているのがわかる。各分割は各推論規則の前件部のファジィ変数によって構成されているので、分割の境界はあいまいに分割されている。

直積空間 E での推論規則 $R^s, s=1, 2, \dots, r$ の前件部のファジィ数 $A^s=(A_1^s, A_2^s, \dots, A_m^s)$ に対する入力 x_i^s のメンバシップ値、すなわち(3)式の w^s は x_i^s が A^s に属する可能性¹³⁾を表わすと考えることができる。したがって、推論規則 R^s が与えられた場合の x_i の属する可能性を $\Pi(x_i | R^s)$ と表わすと、 w^s は

$$w^s = \Pi(x_i | R^s)$$

と表現できる。

規則クラスタリングは入力空間 E での各 R^s の A^s に属する x_i を可能性の意味からクラスタリングする問題と考えることができるので、次のように定義する。

【定義2】

推論規則 R^s が与えられた場合の x_i の属する可能性 $\Pi(x_i | R^s)$ を次の操作により定義する。

(1) 入力データ $x_i, i=1, 2, \dots, n$ をクラスタリング手法で R^1, R^2, \dots, R^r に r 分割する。

(2) 各入力データ x_i に対して、

$$\delta_i^s = \begin{cases} 1 & : x_i \in R^s \\ 0 & : x_i \notin R^s \end{cases}, \quad s=1, 2, \dots, r$$

を与える。クラスター $R^s, s=1, 2, \dots, r$ は E で推論規則を r 分割した結果を表わす。

(3) 神経回路網モデルを用いて、入力層の入力値に x_i を割り付け、出力層の出力値に δ_i^s を割り付けて推定値 $\hat{\delta}_i^s$ を求める。

(4) $\Pi(x_i | R^s) = \hat{\delta}_i^s$

定義2から、各推論規則 R^s のファジィ数 A^s のメンバシップ値 w^s が得られる。神経回路網モデルを用いたファジィモデリングでは前件部のファジィ数 A^s は前件部のファジィ変数の直積¹³⁾を計算して得るのではなく、 x_i が各 R^s の A^s に属する可能性を考慮したクラスター問題から得られる。したがって、神経回路網モデルによる規則クラスタリングは各前件命題が存在しないので、従来のように推論規則が図3のような矩形形状になると言う制約に縛られない。

4.2 後件部の構造同定

後件部の構造同定とは、後件部の制御操作量推定式の入力変数の選択、および係数の同定問題をいう。本提案方法では(4)式の線形方程式を非線形方程式に拡張し、神経回路網モデルの入出力関係(7)式を制御操作量推定式とする。入力変数の選択は、評価指標を誤差二乗和とする変数減少法により行なう。また、係数の同定では、(5)式の α_i を学習アルゴリズムで求める。したがって、後件部の入力変数は必ずしも前件部の入力変数とは一致しない。

以上、神経回路網モデルを用いた上記の前件部、および後件部の構造同定問題とは次の推論規則：

R^s : IF $x=(x_1, x_2, \dots, x_m)$ is A^s

THEN $y^s = NN(x_1, x_2, \dots, x_m)$, $s=1, 2, \dots, r$
 の前件部、および後件部の構造同定を意味する。ここで、

神経回路網モデルとして1個の神経細胞モデルを用い(6)式
 の非線形変換を無くせば $NN(x) = a_0^s + a_1^s x_1 + a_2^s x_2 + \dots + a_m^s x_m$ となり、菅野のファジィモデルの後件部と同じになる。

4.3 神経回路網モデルによるファジィ推論のアルゴリズム

次に、神経回路網モデルを用いたファジィ推論のアルゴリズムを説明しよう。推論モデルおよび、制御操作量は次の手続きで得られる。

【ステップ 1】

観測値 $y_i, i=1, 2, \dots, n$ に關係する入力変数 $x_{ij}, j=1, 2, \dots, k$ を定める。必要があれば入出力データ (x_i, y_i) の正規化を行う。

【ステップ 2】

観測値 y_i を出力、各入力変数 $x_{ij}, j=1, 2, \dots, k$ を入力とする神経回路網モデルを用いて誤差二乗和を評価指標とする変数減少法により、出力層に関連がある入力変数 $x_{ij}, j=1, 2, \dots, m, m \leq k$ のみを選択する。これは外乱となる入力変数を取り除き、従来の相関関係の大きい入力変数を選択することに相当する。

【ステップ 3】

入出力データ (x_i, y_i) をモデル推定の構造同定用データ(以下、TRDと記す。 n_i 個)と推定モデルの評価用データ(以下、CHDと記す。 n_c 個)とに分割する。

$n = n_i + n_c$ である。

【ステップ 4】

TRDを通常のクラスタリング手法を用いて最適な r 分割を行う。 r 分割された学習データの各組を $R^s, s=1, 2, \dots, r, R^s$ の学習データを $(x_i^s, y_i^s), i=1, 2, \dots, (n_i)^s$ とする。ただし、 $(n_i)^s$ は各 R^s でのTRDのデータ数を示す。ここで m 次元空間の r 分割は制御規則数を r 個にすることになる。

【ステップ 5】

前件部構造の同定を行う。 x_i を入力層の入力値に割り付け、出力層の出力値として、

$$w_i^s = \begin{cases} 1 & : (x_i, y_i) \in R^s \\ 0 & : (x_i, y_i) \notin R^s \end{cases}$$

for $i=1, \dots, n_i, s=1, \dots, r$

を割り付ける。学習によって w_i^s を推定する神経回路網モデルを同定し、各学習データ (x_i, y_i) の各 R^s に属する度合い w_i^s を推定する。定義2から、前件部のメンバシップ関数は推定値 \hat{w}_i^s で表わす。即ち、

$$\mu_{A^s}(x_i, y_i) = \hat{w}_i^s, \quad i=1, 2, \dots, n_i$$

とする。 $\mu_{A^s}(x_i, y_i) > 0$ となる学習データを改めて、 $(x_i^s, y_i^s), i=1, 2, \dots, (n_i)^s$ とする。

【ステップ 6】

ステップ5で得られた神経回路網モデルにCHDの各評価データ $(x_i, y_i), i=1, 2, \dots, n_c$ を代入して、CHDのメンバシップ値を求める。

$$\hat{w}_i^s = \mu_{A^s}(x_i, y_i), \quad i=1, 2, \dots, n_c$$

【ステップ 7】

後件部構造の同定を行う。各制御規則の後件部構造モ

デルを神経回路網モデルの入出力関係(7)式で表わし、TRDの入力値 $x_{i1}^s, \dots, x_{in}^s, i=1, 2, \dots, (n_c)^s$ と出力値 y_{i1}^s を割り付ける。学習によって制御操作量を推定する神経回路網モデルを同定する。次に、得られた神経回路網モデルにCHDの入力値 $x_{i1}^s, \dots, x_{in}^s, i=1, 2, \dots, (n_c)^s$ を代入し、誤差二乗和 θ_n^s を求める。

$$\theta_n^s = \sum_{i=1}^{(n_c)^s} (y_{i1}^s - \hat{y}_{i1}^s)^2$$

[ステップ 8]

変数減少法を用いる。各制御規則の後件部の制御操作量推定式の m 個の入力変数の中で、任意の1個の入力変数を取り除き、ステップ7と同様にTRDを用いて後件部毎に神経回路網モデルを同定する。次に、CHDを用いた場合の制御操作量の推定誤差二乗和 $\theta_{n-1}^{s^p}$ を計算する。

$$\theta_{n-1}^{s^p} = \sum_{i=1}^{(n_c)^s} (y_{i1}^s - \hat{y}_{i1}^s)^2, \quad p=1, 2, \dots, m \quad (8)$$

(8)式から、取り除いた入力変数のモデルに対する重要度合いがわかる。即ち、

$$\theta_n^s > \theta_{n-1}^{s^p} \quad (9)$$

となる場合には取り除いた入力変数 x^p の重要度は低いと考えられるので、 x^p を捨てる。

[ステップ 9]

残りの入力変数の個数を m 個としてステップ7と同様の操作を行う。以下、ステップ7～ステップ8を繰り返す、(9)式が全ての入力変数に対して成立しなくなった場合に計算を停止する。 θ^s が最小となるモデルが最適な神経回路網モデルである。

ステップ1～ステップ9により、各制御規則毎の前件部と後件部が決定され、ファジィモデルの構造同定が終了する。制御操作量 y_{i1}^s は以下の式により得られる。

$$y_{i1}^s = \frac{\sum_{s=1}^k w_{i1}^s \hat{y}_{i1}^s}{\sum_{s=1}^k w_{i1}^s}, \quad i=1, 2, \dots, n_c \quad (10)$$

ただし、 \hat{y}_{i1}^s はステップ9で得られた最適な神経回路網モデルにCHDを代入した推定値を示す。

4.4 数値例

定式化した神経回路網モデルによるファジィモデリングの有用性を示すために、菅野らが提案したファジィモデリングで用いた簡単な数値例⁶⁾を用いてファジィ推論を行う。ファジィ推論の計算過程を以下に述べる。

[ステップ 1, 2, 3]

表1に入出力データを示す。データ番号1-20は構造同定用(TRD)であり、データ番号21-40は評価用(CHD)である。したがって、 $n_c=n_e=20, m=$ となる。3層[3×3×3×1]パーセプトロンで15000回学習して入力変数の選択を行った結果、以下の結果が得られた。

| | 誤差二乗和 |
|----------------|--------|
| 全変数使用した場合 | 0.0007 |
| x_1 を取り除いた場合 | 0.3936 |
| x_2 を取り除いた場合 | 0.1482 |
| x_3 を取り除いた場合 | 0.0872 |
| x_4 を取り除いた場合 | 0.0019 |

これにより、入力変数 x_4 を省いても推定にはほとんど影響がないと判断し、以後の実験では用いない。

[ステップ 4]

TRDを通常のクラスタリング手法を用いて分割する。分割された各学習データは次のようになる。

| 制御規則 | 学習データ番号 |
|-------|------------------------------------|
| R^1 | 1, 2, 3, 4, 5, 11, 12, 13, 14, 15 |
| R^2 | 6, 7, 8, 9, 10, 16, 17, 18, 19, 20 |

[ステップ 5]

学習データ $(x_i, y_i), i=1, 2, \dots, 20$ の A^s に属する度合い $w_i^s = \{0, 1\}$ を $\hat{w}_i^s \in [0, 1]$ の値で推定するために3層[3×3×3×2]パーセプトロンを5000回学習し、前件部のファジィ数 A^s を得る。この時の制御規則 R^1 に対する前件部のファジィ数 A^1 を表2に示す。表2での学習データ

表1 入力出力データ

| 同定用データ | | | | | 評価用データ | | | | | | |
|--------|--------|-------|-------|-------|--------|-----|--------|-------|-------|-------|-------|
| No. | y | x_1 | x_2 | x_3 | x_4 | No. | y | x_1 | x_2 | x_3 | x_4 |
| 1 | 11.110 | 1 | 3 | 1 | 1 | 21 | 9.545 | 1 | 1 | 5 | 1 |
| 2 | 6.521 | 1 | 5 | 2 | 1 | 22 | 6.043 | 1 | 3 | 4 | 1 |
| 3 | 10.190 | 1 | 1 | 3 | 5 | 23 | 5.724 | 1 | 5 | 3 | 5 |
| 4 | 6.043 | 1 | 3 | 4 | 5 | 24 | 11.250 | 1 | 1 | 2 | 5 |
| 5 | 5.242 | 1 | 5 | 5 | 1 | 25 | 11.110 | 1 | 3 | 1 | 1 |
| 6 | 19.020 | 5 | 1 | 4 | 1 | 26 | 14.360 | 5 | 5 | 2 | 1 |
| 7 | 14.150 | 5 | 3 | 3 | 5 | 27 | 19.610 | 5 | 1 | 3 | 5 |
| 8 | 14.360 | 5 | 5 | 2 | 5 | 28 | 13.650 | 5 | 3 | 4 | 5 |
| 9 | 27.420 | 5 | 1 | 1 | 1 | 29 | 12.430 | 5 | 5 | 5 | 1 |
| 10 | 15.390 | 5 | 3 | 2 | 1 | 30 | 19.020 | 5 | 1 | 4 | 1 |
| 11 | 5.724 | 1 | 5 | 3 | 5 | 31 | 6.380 | 1 | 3 | 3 | 5 |
| 12 | 9.766 | 1 | 1 | 4 | 5 | 32 | 6.521 | 1 | 5 | 2 | 5 |
| 13 | 5.8700 | 1 | 3 | 5 | 1 | 33 | 16.000 | 1 | 1 | 1 | 1 |
| 14 | 5.406 | 1 | 5 | 4 | 1 | 34 | 7.219 | 1 | 3 | 2 | 1 |
| 15 | 10.190 | 1 | 1 | 3 | 5 | 35 | 5.724 | 1 | 5 | 3 | 5 |
| 16 | 15.390 | 5 | 3 | 2 | 5 | 36 | 19.020 | 5 | 1 | 4 | 5 |
| 17 | 19.680 | 5 | 5 | 1 | 1 | 37 | 13.390 | 5 | 3 | 5 | 1 |
| 18 | 21.060 | 5 | 1 | 2 | 1 | 38 | 12.680 | 5 | 5 | 4 | 1 |
| 19 | 14.150 | 5 | 3 | 3 | 5 | 39 | 19.610 | 5 | 1 | 3 | 5 |
| 20 | 12.680 | 5 | 5 | 4 | 5 | 40 | 15.390 | 5 | 3 | 2 | 5 |

表2 ファジィ数

| 同定用データ | | | メンバシップ値 | | |
|--------|-------|-------|---------|--------|--------|
| No. | x_1 | x_2 | x_3 | 規則 1 | 規則 2 |
| 1 | 1 | 3 | 1 | 0.9970 | 0.0031 |
| 2 | 1 | 5 | 2 | 0.9972 | 0.0028 |
| 3 | 1 | 1 | 3 | 0.9972 | 0.0028 |
| 4 | 1 | 3 | 4 | 0.9973 | 0.0027 |
| 5 | 1 | 5 | 5 | 0.9974 | 0.0026 |
| 6 | 5 | 1 | 4 | 0.0028 | 0.9971 |
| 7 | 5 | 3 | 3 | 0.0028 | 0.9972 |
| 8 | 5 | 5 | 2 | 0.0027 | 0.9972 |
| 9 | 5 | 1 | 1 | 0.0027 | 0.9973 |
| 10 | 5 | 3 | 2 | 0.0027 | 0.9973 |
| 11 | 1 | 5 | 3 | 0.9973 | 0.0028 |
| 12 | 1 | 1 | 4 | 0.9973 | 0.0027 |
| 13 | 1 | 3 | 5 | 0.9974 | 0.0026 |
| 14 | 1 | 5 | 4 | 0.9973 | 0.0027 |
| 15 | 1 | 1 | 3 | 0.9972 | 0.0028 |
| 16 | 5 | 3 | 2 | 0.0027 | 0.9973 |
| 17 | 5 | 5 | 1 | 0.0027 | 0.9973 |
| 18 | 5 | 1 | 2 | 0.0027 | 0.9973 |
| 19 | 5 | 3 | 3 | 0.0028 | 0.9972 |
| 20 | 5 | 5 | 4 | 0.0029 | 0.9971 |

は $\mu_{R^1}(x_1, y_1) = w_1^1 > 0$ となる入力データを用いる。同様に、 R^2 に対しても前件部のファジィ数を得る。

[ステップ 6]

ステップ5で求められた神経回路網モデルを用いて、CHDが A^* に属する度合いを得る。

[ステップ 7]

各制御規則における後件部の制御操作量推定式を同定する。3層 [3×8×8×1] パーセプトロンを 20000回学習した後の θ_4^* は次のように得られた。

| | |
|-----------------------|-------|
| 制御規則 1 : θ_4^1 | 27.86 |
| 制御規則 2 : θ_4^2 | 1.93 |

[ステップ 8, 9]

制御規則 R^* の後件部の構造モデルから任意の1個の入力変数を取り除いた場合の θ_3^* を求める。3層 [2×8×8×1] パーセプトロンを 10000~20000回学習した結果、制御規則 R^1, R^2 に対して次の誤差二乗和が得られた。

| | 規則 1 : θ_3^1 | 規則 2 : θ_3^2 |
|----------------|---------------------|---------------------|
| x_1 を取り除いた場合 | 42.84 | 0.93 |
| x_2 を取り除いた場合 | 74.71 | 119.61 |
| x_3 を取り除いた場合 | 55.27 | 73.28 |

各制御規則毎にステップ7とステップ8を比較すると

全ての $\theta_3^1 > \theta_4^1 (=27.86)$

x_1 を取り除いた場合の $\theta_3^2 < \theta_4^2 (=1.93)$

となっているので、制御規則1に対してはステップ7の神経回路網モデルを後件部モデルとする。制御規則2に対しては更に計算を続け、ステップ9の繰り返し計算で終了して、 (x_2, x_3) 入力の神経回路網モデルを後件部モデル

とする。得られたファジィモデルは

R^1 : IF $x=(x_1, x_2, x_3)$ is A^1 THEN $y^1 = NN_1(x_1, x_2, x_3)$

R^2 : IF $x=(x_1, x_2, x_3)$ is A^2 THEN $y^2 = NN_2(x_2, x_3)$

となる。得られた R^* の規則クラスタリングを x_2-x_3 平面図として図4に示す。また、(10)式の y_i^* を表3に示す。

5. 考察

次に、本論文で提案されたファジィモデリングとGMDH、および菅野らが提案したファジィモデルとの比較を行う。モデルの評価指標として、

$$D = \frac{1}{n} \sum_{i=1}^n \frac{|y_i - y_i^*|}{y_i}$$

を用いて、表4に結果を示す。

表4 ファジィモデルの性能評価

| | 同定用データ | 評価用データ |
|--------|--------|--------|
| GMDH | 4.7 | 5.7 |
| 菅野モデル1 | 1.5 | 2.1 |
| 菅野モデル2 | 1.1 | 3.6 |
| 本提案モデル | 0.47 | 4.79 |

アルゴリズムの結果、および表4から次の事が言える。

- 1) 表4のTRDに対する本手法のDはGMDHの4.7、菅野のファジィモデルの1.5、1.1と比べて0.47と非常に小さく、モデルが入出力データの関係をよく表現しているのがわかる。これは神経回路網モデルが学習機能に優れている特徴からも理解できる。
- 2) 一方、CHDに対してはGMDHの5.7と比較してD=4.79と小さくなっているが、菅野のファジィモデルよりは値が大きくなっている。この結果はモデルがデータ数の少ないTRDの局所的な特徴までもよく表現し過ぎている

表3 制御操作量の推定結果

| 同定用データ | | | | | 評価用データ | | | | |
|--------|--------|--------|---------|---------|--------|--------|--------|---------|---------|
| No. | y | y^* | w_1^1 | w_1^2 | No. | y | y^* | w_1^1 | w_1^2 |
| 1 | 11.110 | 11.136 | 0.9970 | 0.0031 | 21 | 9.545 | 8.882 | 0.9974 | 0.0027 |
| 2 | 6.521 | 6.534 | 0.9972 | 0.0028 | 22 | 6.043 | 6.140 | 0.9973 | 0.0027 |
| 3 | 10.190 | 10.210 | 0.9972 | 0.0028 | 23 | 5.724 | 5.712 | 0.9973 | 0.0028 |
| 4 | 6.043 | 6.140 | 0.9973 | 0.0027 | 24 | 11.250 | 10.547 | 0.9971 | 0.0030 |
| 5 | 5.242 | 5.370 | 0.9974 | 0.0026 | 25 | 11.110 | 11.136 | 0.9970 | 0.0031 |
| 6 | 19.020 | 18.995 | 0.0028 | 0.9971 | 26 | 14.360 | 14.334 | 0.0027 | 0.9972 |
| 7 | 14.150 | 14.134 | 0.0028 | 0.9972 | 27 | 19.610 | 19.061 | 0.0028 | 0.9972 |
| 8 | 14.360 | 14.334 | 0.0027 | 0.9972 | 28 | 13.650 | 13.918 | 0.0029 | 0.9971 |
| 9 | 27.420 | 27.373 | 0.0027 | 0.9973 | 29 | 12.430 | 12.293 | 0.0030 | 0.9969 |
| 10 | 15.390 | 15.383 | 0.0027 | 0.9973 | 30 | 19.020 | 18.995 | 0.0028 | 0.9971 |
| 11 | 5.724 | 5.712 | 0.9973 | 0.0028 | 31 | 6.380 | 7.178 | 0.9972 | 0.0028 |
| 12 | 9.766 | 9.791 | 0.9973 | 0.0027 | 32 | 6.521 | 6.534 | 0.9972 | 0.0028 |
| 13 | 5.8700 | 5.747 | 0.9974 | 0.0026 | 33 | 16.000 | 11.239 | 0.9969 | 0.0032 |
| 14 | 5.406 | 5.450 | 0.9973 | 0.0027 | 34 | 7.219 | 9.018 | 0.9971 | 0.0029 |
| 15 | 10.190 | 10.210 | 0.9972 | 0.0028 | 35 | 5.724 | 5.712 | 0.9973 | 0.0028 |
| 16 | 15.390 | 15.383 | 0.0027 | 0.9973 | 36 | 19.020 | 18.995 | 0.0028 | 0.9971 |
| 17 | 19.680 | 19.652 | 0.0027 | 0.9973 | 37 | 13.390 | 13.892 | 0.0030 | 0.9970 |
| 18 | 21.060 | 21.046 | 0.0027 | 0.9973 | 38 | 12.680 | 12.672 | 0.0029 | 0.9971 |
| 19 | 14.150 | 14.134 | 0.0028 | 0.9972 | 39 | 19.610 | 19.061 | 0.0028 | 0.9972 |
| 20 | 12.680 | 12.672 | 0.0029 | 0.9971 | 40 | 15.390 | 15.383 | 0.0027 | 0.9973 |

ために、CHDを十分に表現できないと考えられる。

- 3) ステップ3)以降で用いた x_4 を除いたデータはデータ番号3と15のように、重複しているデータが多い。データの個数40個の中で、重複していないデータの数は26個である。神経回路網モデルではデータが多ければ多いほど推定値がよくなるので、仮に、表1が重複していないデータが多いとするとDの値は更によくなると考えられる。

6. おわりに

本論文では、神経回路網モデルを用いて前件部および後件部の構造同定を行う新しいファジィモデリング手法を提案した。神経回路網モデルの非線形性および自己組織性を用いることにより、発見的解法を用いずに推論規則を容易に得ることができる。評価実験から、本手法は学習データへの追従性が非常に良く、複雑なシステムであっても従来の手法以上に同定性能が高いことが示された。

今後のファジィ推論の展開の一つに自己組織的な概念の導入がある。本論文はその一方法論を提言したものであり、より一層の展開を図っていく予定である。

参考文献

- 1) 水本, "種々のファジィ推論法 -If ... then ... の場合-", 電子通信学会論文誌, J64-D,5, pp379-386, 1981

- 2) 山崎,菅野, "ファジィ制御", システムと制御, 28,7, pp442-446, 1984
 3) 安信,宮本,井原, "予見ファジィ制御方式による列車自動運転", システムと制御, 28,10, pp46-54, 1984
 4) 柳下,伊藤,菅野, "ファジィ理論の浄水場薬品注入制御への応用", システムと制御, 28,10, pp597-604, 1984
 5) 姜,菅野, "ファジィモデリング", 計測自動制御学会論文集, 23,6, pp650-652, 1987
 6) 菅野道夫, "システムファジィモデリング", システムと制御チュートリアル講座'87「制御工学へのガイドライン」, pp79-98, 1987
 7) W.S.McCulloch and W.Pitts, "A Logical Calculus of the Ideas Imminent in Nervous Activity", Bulletin of Mathematical Biophysics, 5, pp115-133, 1943
 8) 甘利俊一, "神経回路網の数理", 産業図書, 1978
 9) D.E.Rumelhart et al, "Parallel Distributed Processing", MIT Press, 1986
 10) 高木,坪香, "ニューラル・ネットを用いた類似パルス抽出フィルタリング", 音響学会講演論文 3-P-11, 1988年3月
 11) 高木,原, "ニューラル・ネットを用いた7ビットの制御", 音響学会講演論文 3-P-12, 1988年3月
 12) R.P.Lippmann, "An Introduction to Computing with Neural Nets", IEEE ASSP MAGAZINE, Apr. 1987
 13) D.Dubois and H.Prade, "Fuzzy Sets and Systems; Theory and Applications", Academic Press, N.Y., 1980

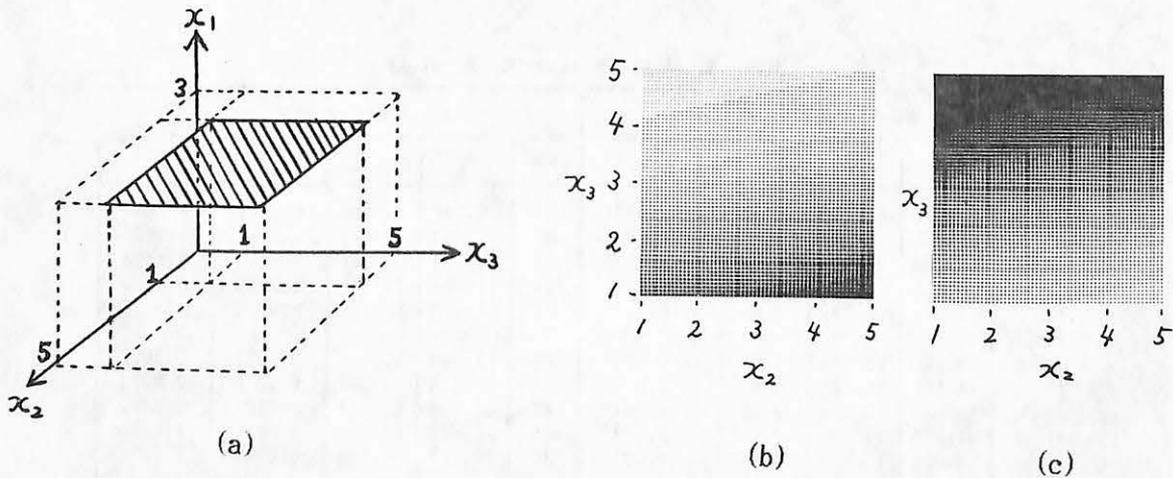


図4 制御規則のメンバシップ関数の超平面

- (a) 入力直積空間 $E = X_1 \times X_2 \times X_3$ を $x_1 = 3$ で切り取った時の平面
 (b) 平面(a)での制御規則1のメンバシップ関数
 (c) 平面(a)での制御規則2のメンバシップ関数

メンバシップ値の(0~1)を(淡~濃)に対応させて表示