

## 論文

# 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<sup>†</sup>

荒木 昭一\* 野村 博義\* 林 真\* 若見 昇\*

ファジィ制御器の有効な設計法の1つに、熟練オペレータの制御操作から得られる入出力データを用いて、その操作をモデル化する方法がある。モデル化に際しては、メンバシップ関数の形状やファジィ分割をどのようにして決めるかという問題がある。最近の研究では、ニューラルネットワークの構造や学習法を用いる手法や、メンバシップ関数の形状を規定するパラメータを最適化法を用いて同定する手法など、いくつかの方法が提案されている。しかし、これらの手法はあらかじめルール数を固定する方式である。本論文では、最急降下法に基づきパラメータを調整しながら、新たなルールを逐次的に生成してルール数を増加していく方式を提案する。ルールの生成は、前件部のメンバシップ関数でファジィ分割された入力空間内の領域の中で、推論誤差が最も大きい領域に対して行われる。これにより、対象の入出力関係の同定に必要なルール数を持つファジィ推論ルールが自動的に獲得できる。数値例として、非線形関数で表される入出力関係を同定し、提案手法の特長と有効性を示す。また、移動ロボットの障害物回避に応用した結果を報告する。

キーワード： ファジィ制御、 ファジィモデリング、 ルールの逐次生成、 障害物回避

## 1. はじめに

近年、様々な分野にファジィ推論が応用されており、特に、制御の分野においてその実用化が進展している<sup>1)</sup>。ファジィ制御器の設計法については、いくつかの指針が整理されている<sup>2)</sup>。専門家や熟練オペレータの持つ知識をファジィ推論ルールとして直接記述することが困難な場合には、オペレータの制御操作から得られる入出力データを用いて、その操作をモデル化する方法が有効である。このようなファジィ推論ルールを用いた非線形システムのモデル化はファジィモデリングと呼ばれている<sup>3)</sup>。ファジィモデリングは、ファジィ分割された部分空間ごとに対象システムの入出力関係を同定するので、複雑な入出力関係を持つシステムに有効であると考えられている。しかし、ルール

の記述に用いるメンバシップ関数の形状や前件部のファジィ分割をどのようにして決定するかという問題がある<sup>4)</sup>。

この問題に対する最近の研究には次のようなものがある。ニューラルネットワークの構造や学習法を用いる決定法が提案され、階層構造のニューラルネットワークを用いた誤差逆伝播学習法<sup>5)</sup>によりメンバシップ関数の形状を決定するニューラルネット駆動型ファジィ推論<sup>6)</sup>や、メンバシップ関数をシグモイド関数で構成し、その形状を規定するパラメータを結合荷重としてファジィ推論の計算過程を表現したネットワークを誤差逆伝播学習法により学習させるファジィニューラルネットワーク<sup>7)</sup>などがある。これに対して、ファジィ推論の数式モデルにおいてメンバシップ関数の形状を規定しているパラメータを、逐次的に与えられるデータから最適化法を用いて同定する逐次型ファジィモデリング<sup>8),9),10)</sup>がある。逐次型ファジィモデリングは、誤差逆伝播学習法に較べて極めて少ない学習回数で対象を同定できるという長所を持ち、実用性にすぐれている。しかし、対象の入出力関

<sup>†</sup> A Fuzzy Modelling with Iterative Generation Mechanism of Fuzzy Inference Rules

Shoichi ARAKI, Hiroyoshi NOMURA, Isao HAYASHI  
and Noboru WAKAMI

\*1 松下電器産業株式会社 中央研究所

電子機器基礎研究所 第6研究室

Central Research Laboratories, Matsushita Electric  
Industrial Co., Ltd.

係を所望の精度で近似するために必要な前件部のファジィ分割数(ファジィ推論ルール数)は、試行錯誤により決定されている。

本論文では、簡略ファジィ推論モデル<sup>8)</sup>を用いて、そのパラメータであるルール後件部の実数値を調整しながら、逐次的に新たなルールを生成して、対象の同定に必要なルール数を持つファジィ推論ルールを自動的に獲得する手法を提案する。パラメータの調整は、与えられたデータとファジィ推論の出力との差である推論誤差を評価規範として最急降下法に基づき行う。ルールの生成は、現在のルールのパラメータを調整しても推論誤差が減少しなくなった場合に、前件部に新たなメンバシップ関数を生成することにより行う。新たなメンバシップ関数は、ファジィ分割された前件部の領域の中で最も推論誤差の大きい領域をさらに分割するように1つずつ生成していくが、簡略ファジィ推論モデルの出力が多重線形関数であるため<sup>8)</sup>、前件部のファジィ分割は対象の非線形の強さに応じて決定されることになる。このパラメータ調整とルール生成を繰り返すことにより、対象の同定に必要なルール数を持つファジィ推論ルールを自動的に獲得することができる。

以下、まず2章で、提案するルールの同定法を説明する。次に3章で、簡単な数値例を用いて提案手法の有効性を示す。最後に4章では、移動ロボットの障害物回避に応用した結果を報告する。

## 2. ルールの逐次生成型ファジィモデリング

提案する同定法は、パラメータ調整とルール生成の2つの手続きからなる。2.1節で、同定に用いるルールの形式とパラメータの調整法を、2.2節でルールの生成法をそれぞれ説明し、2.3節で具体的な同定手順を示す。

### 2.1 ルールの形式とパラメータ調整法

まず、ルールの形式を説明する。提案手法では、後件部をメンバシップ関数でなく実数値で記述す

るルール<sup>11)</sup>を用いる。入力を  $x_i (i=1, \dots, n)$ 、出力を  $y$  とすると、ファジィ推論ルール  $R^k$  は次のように記述できる。

$$\begin{aligned} R^k : & \text{IF } x_1 \text{ is } A_{1j}^1 \text{ and } x_2 \text{ is } A_{2j}^2 \\ & \text{and } \cdots \text{ and } x_n \text{ is } A_{nj}^n \\ & \text{THEN } y \text{ is } w_k \end{aligned} \quad (1)$$

ただし、 $A_{ij}^i (j=0, 1, \dots, m^i)$  は入力  $x_i$  のファジィ集合、 $w_k (k=0, 1, \dots, N-1)$  は後件部の実数値である。添字  $k$  はルール番号、 $j^i$  は入力  $x_i$  のファジィ集合に付した番号を表す。また、 $N$  はルールの総数である。

提案手法では、前件部のファジィ集合の数を増加させることによりルールを逐次的に生成していく。このため、ファジィ集合  $A_{ij}^i$  のメンバシップ関数  $A_{ij}^i(x_i)$  を次式で与える。

$$A_{ij}^i(x_i) = \begin{cases} \frac{1}{a_{ij}^i - a_{ij}^{i-1}} (x_i - a_{ij}^{i-1}) & ; a_{ij}^{i-1} \leq x_i \leq a_{ij}^i \\ 1 - \frac{1}{a_{ij}^{i+1} - a_{ij}^i} (x_i - a_{ij}^i) & ; a_{ij}^i \leq x_i \leq a_{ij}^{i+1} \\ 0 & ; x_i \leq a_{ij}^{i-1}, a_{ij}^{i+1} \leq x_i \end{cases} \quad (2)$$

(2)式は、頂点を  $a_{ij}^i$ 、幅を  $(a_{ij}^{i+1} - a_{ij}^{i-1})$  とする三角型であり、隣りあうメンバシップ関数のメンバシップ値の和は1となる。入力  $x_1$  に7つのメンバシップ関数を設定した例を図1に示す。このときメンバシップ関数には、番号  $j^1$  が0から6まで与えられる。

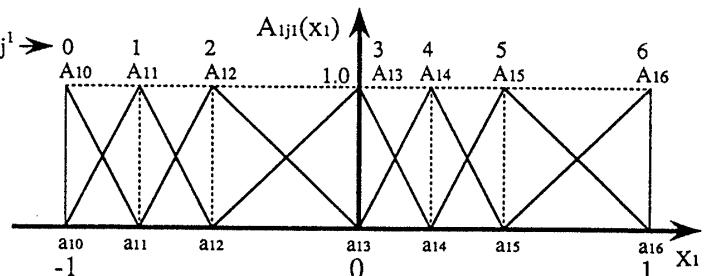


図1 メンバシップ関数の一例

図1の例で示したように、入力  $x_i$  の変域内で頂点の位置を指定すれば、メンバシップ関数は一意に決まる。したがって、新たに頂点を指定することによりメンバシップ関数の数を増加させ、任意の領域にルールを生成することができる。

前件部のメンバシップ関数の数が決まるとルール数が定まる。いま、入力  $x_i$  にメンバシップ関数が  $(m^i+1)$  個設定されているとすると、ルールはメンバシップ関数の組合せの数だけ存在するので、その総数  $N$  は次式で与えられる。

$$N = (m^1+1)(m^2+1)\cdots(m^{n-1}+1)(m^n+1) \quad (3)$$

また、ルール番号  $k$  は、メンバシップ関数の組合せに対応して与える。メンバシップ関数の組合せを、その番号  $j^i$  の組合せからなる番号列  $j^1j^2\cdots j^{n-1}j^n$  (例えば、01…21) で表すと、 $j^i$  は  $\{0, 1, \dots, m^i\}$  のいずれかの値をとる  $(m^i+1)$  進数であるから、メンバシップ関数の番号列に対応するルール番号  $k$  (10進数) は次式で与えることができる。

$$\begin{aligned} k = & j^1(m^2+1)(m^3+1)\cdots(m^n+1) \\ & + j^2(m^3+1)(m^4+1)\cdots(m^n+1) \\ & \cdots \\ & + j^{n-1}(m^n+1) \\ & + j^n \end{aligned} \quad (4)$$

$N$  個のルールを用いたファジィ推論の出力を次のようにして求める。

$k$  番目のルール前件部の適合度を、代数積 ( $\cdot$ ) を用いて次式で与える。

$$\mu_k = A_{1,j^1}(x_1) \cdot A_{2,j^2}(x_2) \cdot \cdots \cdot A_{n,j^n}(x_n) \quad (5)$$

このとき、 $A_{ij^i}(x_i)$  として(2)式を仮定し、適合度を(5)式で与えるので、入力  $x_i$  に対するルール前件部の適合度の総和  $\sum \mu_k = 1$  となる。したがって、ファジィ推論の出力  $y^*$  として重み付き重心を採用すると次式となる。

$$y^* = \sum_{k=0}^{N-1} \mu_k \cdot w_k \quad (6)$$

次に、パラメータの調整法を説明する。提案手法で調整するパラメータはルール後件部の実数値

である。1個の入出力データ  $(x_1, x_2, \dots, x_n, y^r)$  が与えられる毎に  $\mu_k$  と  $y^*$  を(5), (6)式により計算し、最急降下法に基づく次式により後件部の実数値  $w_k$  を更新する<sup>8),12)</sup>。

$$w_k^{\text{new}} = w_k^{\text{old}} - K_w \cdot \mu_k \cdot (y^* - y^r) \quad (7)$$

ただし、 $w_k^{\text{old}}$ ,  $w_k^{\text{new}}$  はそれぞれ更新前、更新後の後件部の実数値を表し、 $K_w$  は調整係数である。 $K_w$  には学習回数が増大しない範囲で、できるだけ小さな値を設定する。パラメータの調整は、 $N_d$  個の入出力データ  $(x_{1p}, x_{2p}, \dots, x_{np}, y_{pr})$ ,  $p=1, 2, \dots, N_d$  を繰り返し用いて、次式で計算されるデータ 1 個あたりの推論誤差が所定の閾値  $T_1$  以下になるまで行う。 $T_1$  には同定対象の入出力関係の近似における目標の推論精度を設定する。

$$D(t) = \frac{1}{N_d} \sum_{p=1}^{N_d} |y_{pr}^* - y_{pr}| \quad (8)$$

ただし、 $y_{pr}^*$  は  $p$  番目の入力データに対するファジィ推論の出力を表す。

## 2.2 ルールの生成法

ルールの生成法は、1) ルール生成領域の選択、2) 前件部のメンバシップ関数の生成、3) 後件部の実数値の生成、の 3 つの手順からなる。ルールの生成は、パラメータの調整を繰り返しても推論誤差が減少しなくなった場合、具体的には、次式で表される推論誤差の変化量が、所定の閾値  $T_2$  以下になった場合に行う。

$$\triangle D(t) = |D(t) - D(t-1)| \quad (9)$$

ただし、閾値  $T_2$  は推論誤差  $D(t)$  の減少にともなって、よりオーダーの低い値に変化させる。例えば、 $D(t)$  が  $1.0 \times 10^{-2}$  のオーダーに減少したならば  $T_2 = 1.0 \times 10^{-3}$  に、さらに  $D(t)$  が  $1.0 \times 10^{-3}$  のオーダーに減少したならば  $T_2 = 1.0 \times 10^{-4}$  という具合いにルールの獲得過程で変更していく。また、学習係数  $K_w$  の値が小さいほど、 $T_2$  には上記の例よりもさらに低いオーダーの値を設定する。

### 1) ルール生成領域の選択

前件部のメンバシップ関数によりファジィ分割されているすべての領域の中から、現在のルールでは推論誤差が大きく、他の領域に比べて近似精度が低くなっている領域を新たにルールを生成する領域として選択する。具体的には、入力変数毎に見て隣りあう2つのメンバシップ関数によりファジィ分割されているすべての領域の中から、推論誤差が最大の領域を選択する。推論誤差は、各領域に属している入出力データを用いて計算する。図2にルールを生成する候補領域の一例を示す。○はルールを表す。この場合には、入力 $x_1$ について $R_{10}$ と $R_{11}$ 、 $x_2$ について $R_{20}$ と $R_{21}$ の計4領域について推論誤差を計算する。

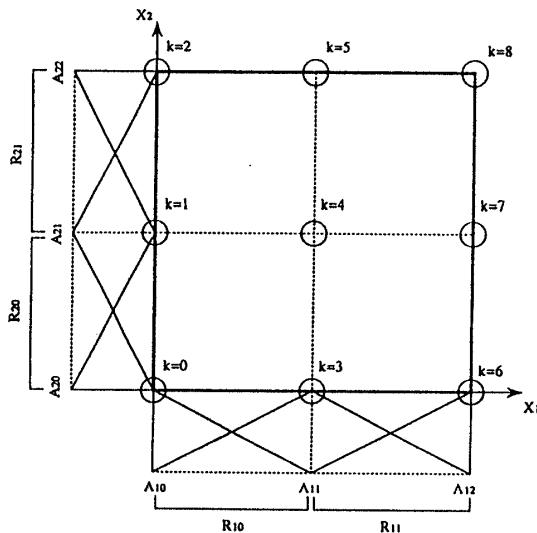


図2 ルール生成の候補領域

### 2) 前件部のメンバシップ関数の生成

手順1)により選択された領域をファジィ分割している2つのメンバシップ関数の頂点の中点を新たに頂点として、新たにメンバシップ関数を生成する。これにより新たなルール生成される。このとき、メンバシップ関数の番号 $j^i$ をその頂点の値が小さい順に更新し、ルール番号を(4)式により更新する。図2に示した領域 $R_{10}$ が選択された場合のメンバシップ関数の生成例を図3に示す。●で表されている3つのルールが新たに生成され、合計12個のルールに更新される。

### 3) 後件部の実数値の生成

1入力1出力の場合の後件部実数値の生成例を図4に示す。○はルール後件部の実数値、×は入出力データを表す。図4(a)に示したルールの後件部の実数値 $w_0, w_1$ を、(7)式を用いて推論誤差が下がらなくなるまで調整した結果を図4(b)に示す。このとき、(5), (6)式よりファジィ推論の出力 $y$ は次式で表される。

$$\begin{aligned} y &= (-x_1 + 1)w_0 + x_1 w_1 \\ &= (w_1 - w_0)x_1 + w_0 \end{aligned} \quad (10)$$

したがって、隣りあう2つのメンバシップ関数で分割されている領域でのファジィ推論の出力は、後件部の実数値を結ぶ1本の直線で表される。この性質を利用してルール後件部の実数値を定める。すなわち、図4(c)に示すように、更新されたルールの後件部の実数値は、その前件部のメンバシップ関数の頂点の値に対する更新前のルールによるファジィ推論の出力とする。これによりルール生成の前後でファジィ推論の出力が変化しない。したがって、推論誤差を増加させずにルールを生成することができる。パラメータの調整を継続することにより、図4(d)に示すような2本の直線で入出力関係を近似することになり、さらに推論誤差を小さくすることができる。

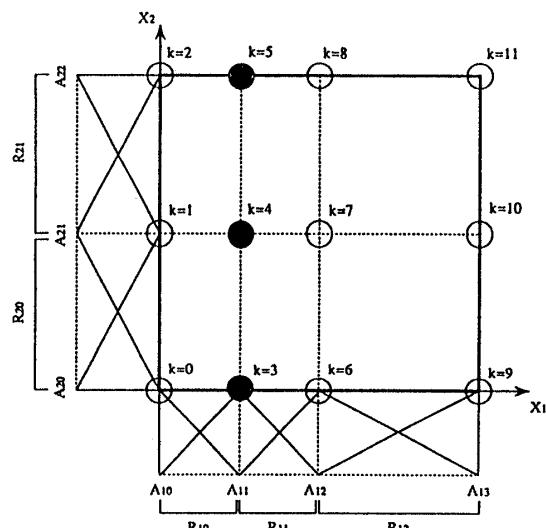


図3 メンバシップ関数の生成例

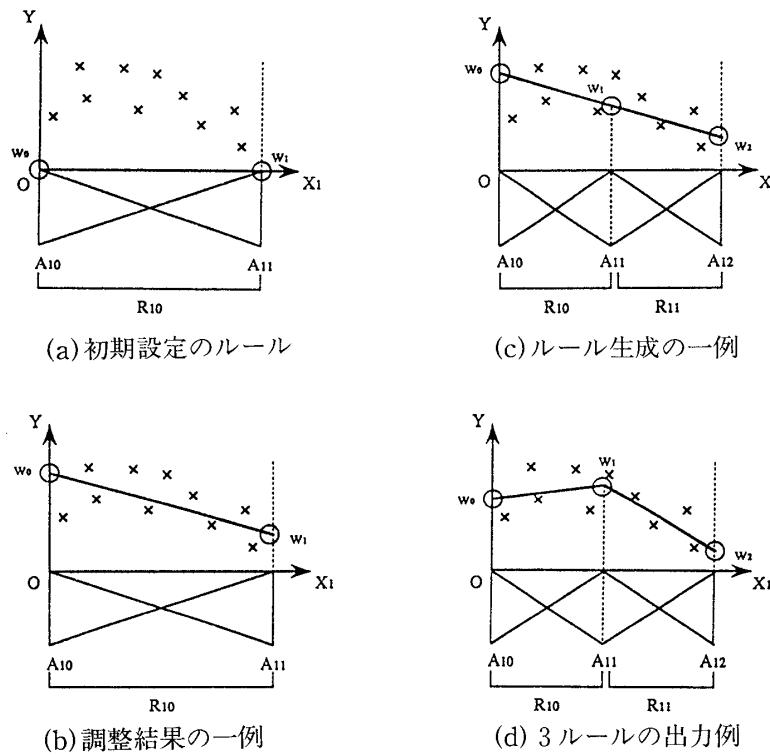


図4 後件部実数値の生成例

一般に多入力の場合には、各入力変数について隣りあう2つのメンバシップ関数でファジィ分割されている領域(入力変数がn個の場合、ある入力に対して同時に適合するルールは $2^n$ 個となるが、同じ $2^n$ 個のルールが同時に適合するような入力空間内の領域)では、ファジィ推論の出力は、後件部の実数値をパラメータとする多重線形関数で表される<sup>8)</sup>。入力変数が2つの場合のファジィ推論の出力の一例を図5に示す。これは図2において、ルール番号kを用いて0-1-4-3と表される矩形の領域(すなわち、 $R^0, R^1, R^3, R^4$ の2<sup>2</sup>個のルールが同時に適合する領域)でのファジィ推論の出力例である。

図5に示したような、出力が1つの多重線形関数で表される領域を、任意の数のメンバシップ関数でさらに分割しても、その中の1つ1つの領域の出力も多重線形関数となる。したがって、1入力の場合と同様にパラメータの値を設定すれば、もとの多重線形関数を、細分化された多重線形関数のつなぎあわせにより完全に表現できる。すなわち、多入力の場合も同様に、ファジィ推論の出力を変化させずにルールを生成することができる。

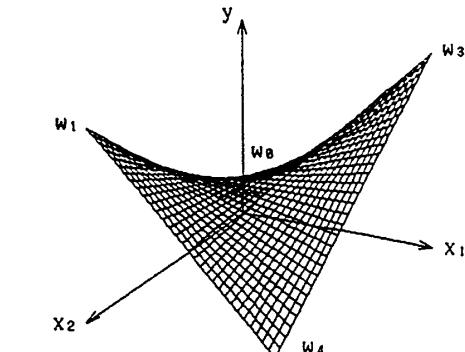


図5 多重線形関数で表されるファジィ推論の出力

### 2.3 ルールの獲得手順

以上で説明したパラメータ調整法とルール生成法によりファジィ推論ルールを獲得する手順を、図6のフローチャートを参照しながら説明する。

#### [ステップ1~2：ルール獲得の準備]

ルールの初期設定を行う。前件部のメンバシップ関数は各入力変数に2つ設定する。また、目標推論精度 $T_1$ 、および推論誤差の減少度合を判定する閾値 $T_2$ を設定する。

## [ステップ3~7: パラメータ調整]

$N_d$ 個の入出力データ  $(x_{1p}, x_{2p}, \dots, x_{np}, y_p)$ ,  $p=1, 2, \dots, N_d$  を順次入力し、ルールの適合度  $\mu_k$  とファジィ推論の出力  $y_p^*$  を(5), (6)式により求め、後件部の実数値  $w_k$  を(7)式により更新する。

## [ステップ8: アルゴリズムの終了判定]

推論誤差  $D(t)$  と推論精度  $T_1$  を比較する。

$D(t) > T_1$  ならばステップ9へ。

$D(t) \leq T_1$  ならば ルールの獲得終了。

## [ステップ9: ルールの生成判定]

推論誤差の変化量  $\Delta D(t)$  と推論誤差の減少度合の閾値  $T_2$  を比較する。

$\Delta D(t) > T_2$  ならばステップ3へ。

$\Delta D(t) \leq T_2$  ならばステップ10へ。

## [ステップ10~12: ルールの生成]

まず、新たにルールを生成する領域を選択する。次に、選択された領域に前件部のメンバシップ関数を生成して、ルールを更新する。最後に、ルールの後件部の実数値を定めてステップ3へ。

ここで、提案した同定法について、逐次型ファジィモデリング<sup>8)</sup>と対比して考察する。どちらもルールの後件部を実数値とした同定法であり、区分的な多重線形関数をつないで非線形な入出力関係を近似する。しかし、前件部のファジィ分割の決定法が大きく異なる。逐次型ファジィモデリングは、最初入力変数ごとにメンバシップ関数を2つ設定したルールを用いて同定を行い、推論誤差が減少しない場合にメンバシップ関数の数を試行錯誤的に増加して近似精度を上げる手法である。

また、メンバシップ関数はその頂点で入力変数の変域を等分割する三角型を用いている。このため、対象の入出力関係が非常に複雑である場合、ファジィ分割されている部分空間ごとに近似精度が大きく異なることがある。つまり、平均としては満足できる近似精度であっても、特定の部分空間で近似精度が極端に低くなっていることがある。これを等分割のメンバシップ関数を試行錯誤で設定する方法で改善しようとすると、近似精度の良い領域にまで必要以上にルールを設定することにな

る。これに対して提案手法では、推論誤差の大きい領域に逐次的にメンバシップ関数を生成していくので、対象の同定に必要なファジィ分割数が自動的に決まる。また、推論誤差は多重線形関数を基に計算されるため、対象の非線形性の強さに応じて入力空間が分割される。このため、逐次型ファジィモデリングのような等分割の場合に較べてより少ないルール数で同程度の近似精度が得られるというルール数低減の効果があると考えられる。

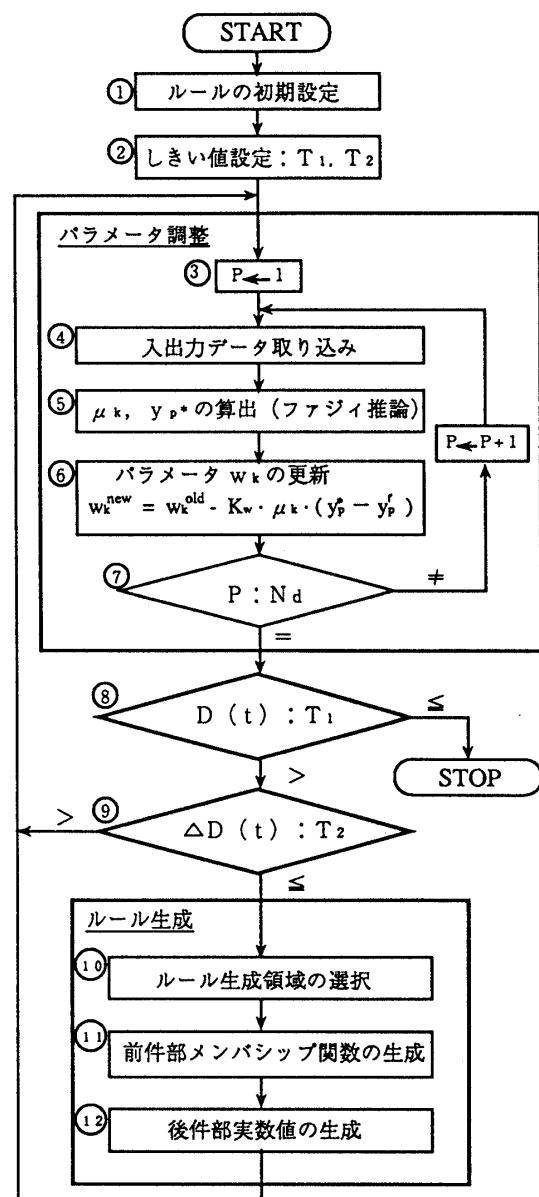


図6 ファジィ推論ルールの獲得手順

## 2.4 入出力データが新たに得られた場合

提案手法は、与えられたデータを用いた、入出力関係のバッチ処理的な同定法である。いま、ある対象を同定したとし、その後、新たな入出力データが得られたとする。新たなデータに対して推論誤差が大きい場合、対象を同定しなおす必要がある。ここでは、一から同定するのではなく、新たなデータのみを用いて、既存のルールに対してさらにルールを追加する方法について述べる。

まず、既存のルールから、そのルールを同定した際の推論精度よりも、新たなデータに対する推論誤差が大きい領域をすべて選択する。選択された領域群の中で互いに隣りあうものは1つの領域とみなす。推論誤差は、ファジィ推論の出力が1つの多重線形関数で表されるすべての領域について計算する。次に、選択された領域に、提案手法によりルールを追加生成する。ただし、選択された領域の内部にあるルールのみパラメータを調整する。以上の手続きにより、選択された領域外では既存のルールが表す入出力関係が保持され、かつ、新たなデータが表す入出力関係も同定できる。ルールの追加例を図7に示す。●は既存のルール、○と□は新たに追加されたルールを表し、○で表されているルールのパラメータのみ調整する。

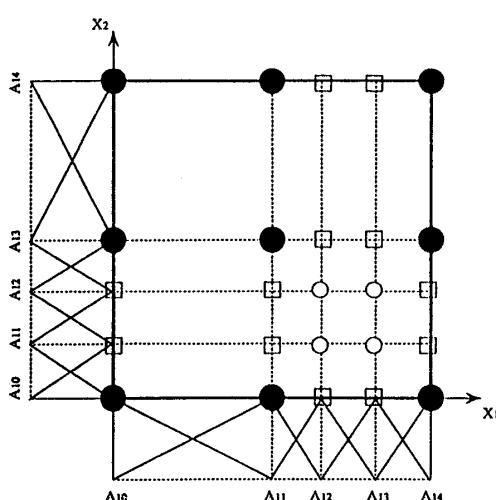


図7 ルールの追加例

## 3. 数値例

入力を  $x$ 、出力を  $y$  として次の式で表される入出力関係を同定することにより、提案手法の特長と有効性を示す。

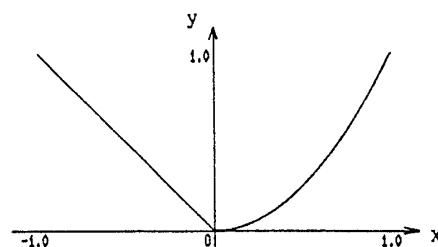
### (a) Linear and Quadratic

$$y = \begin{cases} -x & ; -1 \leq x < 0 \\ x^2 & ; 0 \leq x \leq 1 \end{cases} \quad (11)$$

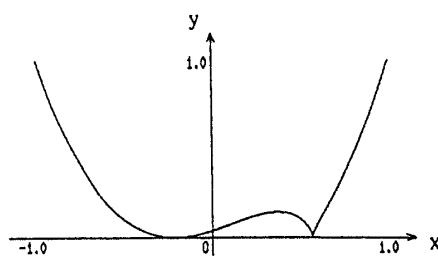
### (b) Fractional

$$y = 2^{-2/3} (1.27x + 0.27)^2 \{1 - (1.27x + 0.27)\}^{2/3} ; -1 \leq x \leq 1 \quad (12)$$

(11)式は線形関数と2次関数(Linear and Quadratic)からなり、(12)式は分数関数(Fractional)である。それらの入出力関係を図8に示す。



(a) Linear and Quadratic



(b) Fractional

図8 同定対象の入出力関係

入力  $x$  の変域  $[-1, 1]$  を等分割して得た 43 個の入出力データを用いてルールを同定した。パラメータの調整係数  $K_w$  と推論精度  $T_1$  はそれぞれ、(11)式の場合には、 $K_w = 0.1$ ,  $T_1 = 5.0 \times 10^{-3}$ , (12)式の場合には、 $K_w = 0.7$ ,  $T_1 = 7.0 \times 10^{-3}$ とした。同定されたルールの前件部のメンバシップ関数を

図9に示す。図8、図9から、非線形性の強さに応じた前件部のファジィ分割が得られていることがわかる。

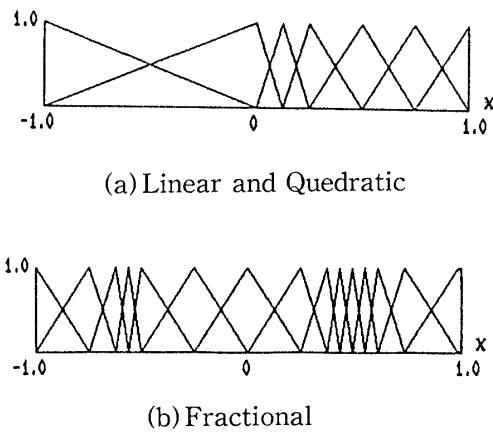


図9 生成された前件部メンバシップ関数

所定の推論精度を満たした後、さらにパラメータ調整のみを継続すると、推論誤差は(11)式の場合に $1.9 \times 10^{-3}$ 、(12)式の場合に $6.4 \times 10^{-3}$ まで減少した。また、同定されたルールを用いて、変域 $[-1, 1]$ を等分割した150個のデータに対して推論誤差を計算した。(11)式の場合に $2.0 \times 10^{-3}$ 、(12)式の場合に $6.6 \times 10^{-3}$ であり、同定用データの場合と同じオーダーの値が得られている。

次に、先の43個の入出力データについて、出力データに対し最大5%のノイズを乱数により与えたデータを用いて、(12)式の分数関数を同定した。

$K_w$ と $T_1$ は、ノイズを与えない場合と同じ値とした。この場合にも図9(b)と同じファジィ分割が得られており、また、150個のデータに対する推論誤差は $8.0 \times 10^{-3}$ であった。すなわち、推論誤差の大きさを判断基準としてルールを増加するにもかかわらず、ノイズに影響されることなく対象を同定できているといえる。

さらに提案手法の有効性を示すため、他の既存の同定手法との比較結果を表1に示す。比較の対象としては、提案手法と同様に入出力データを用いたパラメータの逐次同定法である逐次型ファジィモデリングと3層のニューラルネットワークを用いた誤差逆伝播学習法を選択した。比較は同定に必要な学習回数とルール数(パラメータ数)を行った。学習回数は43個の同定用データを1通り与えてパラメータを調整する手続きを1回としている。逐次型ファジィモデリングでは、ルール数を $2, 3, 4, \dots$ と設定したルールを順に同定していく(文献8にあるように、最初分割数を2として事前学習を行っている)、提案手法と同程度の推論誤差が得られたときのルール数を記載している。また、ニューラルネットワークについては、結合加重の数がパラメータ数となるが、それをファジィ推論ルールのパラメータ数とほぼ同数にして同定している(中間層の数を7とした:BP-7)。なお、提案手法と逐次型ファジィモデリングは、後件部の実数値のみをパラメータとしているのでルール数とパラメータ数は一致することになる。

表1 既存の同定法との比較

		BP-7	逐次型ファジィ	提案手法
(11)式	ルール(パラメータ)数	22	20	10
	推論誤差	5.4	1.0	0.9
	学習回数	23613	16	42
(12)式	ルール(パラメータ)数	22	21	17
	推論誤差	7.9	3.2	3.1
	学習回数	34622	20	46

ただし推論誤差は $\times 10^{-3}$

表1の結果からわかるように、提案手法と逐次型ファジィモデリングは、ニューラルネットに比べてきわめて少ない学習回数で対象を同定できている。さらに、同程度のパラメータ数で比較しているが、より高い近似精度が得られている。

また、提案手法と逐次型ファジィモデリングを比較した場合、学習回数は調整するパラメータ数が逐次的に増加していくため、やや提案手法の方が多い。しかし、提案手法の方がより少ないルール数で同程度の近似精度が得られている。これは、2.3節で考察したように、提案手法により得られる前件部のファジィ分割が入出力関係の非線形性の強さに応じて決まるためと考えられる。

#### 4. 移動ロボットの障害物回避への応用

ここでは、提案手法を移動ロボットの障害物回避に応用した結果を報告する。被験者の回避操作から得られた入出力データから、その回避ノウハウをファジィ推論ルールとして獲得し、ロボットに障害物を回避させるシミュレーションを行った。2.4節で示したルールの追加手法も用い、その有効性も示す。図10に障害物回避の概念図を示す。ロボットは障害物までの距離  $d[m]$  と角度  $\theta [rad.]$  を検知し、その入力データに基づいてファジィ推論を行い、進行方向と移動速度を決定する。この操作量を移動速度ベクトル  $A$  で表し、出力データとする。ただし、 $A$  の  $x$  座標成分  $A_x$  のみをフ

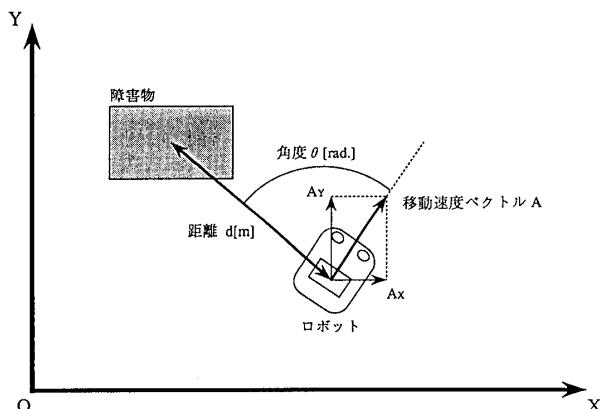


図10 障害物回避の概念図

アジィ推論により決定し、 $y$  座標成分  $A_y$  は一定としている。また、距離と角度の検知および操作量の決定に要する時間の間は、前回決定された操作量を維持するものとする。

被験者がロボットを操作して、障害物を回避したときの軌跡を図11に示す。得られた入出力データを用いて、推論精度  $T_1=0.5$  としてルールを生成した。獲得したルールの前件部のメンバシップ関数を図12(a)に示す。獲得されたルールは、合計36個である。このルールを用いて、同じ障害物を回避させたときの軌跡を図12(b)に示す。障害物を右から回避する被験者の回避ノウハウが、ファジィ推論ルールとして獲得されていることが確認できる。

次に、獲得された同じルールを用いて2つの障害物を回避させたときの軌跡を図13に示す。図13(a)では、2つとも障害物を回避できているが、図13(b)では、第2の障害物を回避できていない。これは、図13(b)での第2の障害物が、ロボットの進行方向に対して大きく右側にあるためと考えられる。このような障害物に対しては、左に回避することが有効である。

そこで、被験者に図11の回避動作とは逆に障害物を左から回避してもらい、新たに入出力データを収集した。2.4節で示した手順に基づき、ルールを

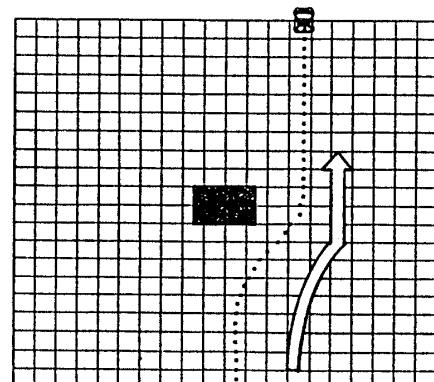


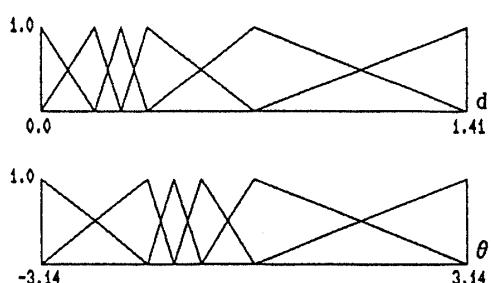
図11 被験者による回避軌跡

追加生成する。新たな入出力データに対して、既存のルールを獲得した際の推論精度  $T_1=0.5$  より推論誤差が大きい領域は、 $\{(d, \theta) \mid 0.00 \leq d \leq 0.707, 0.00 \leq \theta \leq 3.14\}$  であった。この領域にルールを追加生成し、領域内部にあるルールに対してのみパラメータを調整した。推論精度は同じく  $T_1=0.5$  とした。獲得されたルールの前件部のメンバシップ関数を図 14(a)に示す。ルール数は合計 70 個となった。この新たに獲得されたルールを用いて、図 13(b)と同じ配置の障害物に対して回避させた結果を図 14(b)に示す。この結果より、

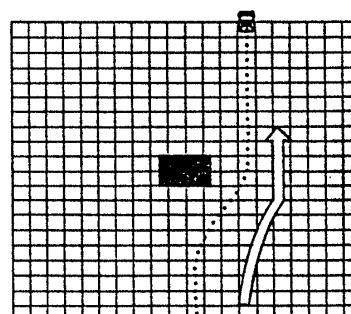
右に回避するルールを損なうことなく左に回避するルールが追加生成され、左右どちらにも回避することのできるファジィ推論ルールが獲得されている。

## 5. おわりに

本研究では、対象の同定に必要なルール数を持つファジィ推論ルールの自動獲得手法として、パラメータを調整しながら、入力空間内で部分的に推論誤差の大きくなっている領域に逐次的にルールを生成していく方式を提案した。簡単な数値例

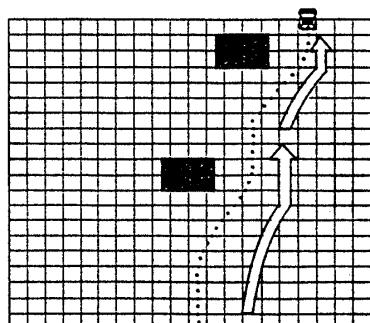


(a) 前件部メンバシップ関数

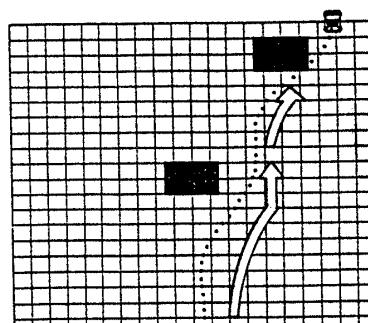


(b) 回避軌跡

図 12 獲得されたルールとその回避軌跡

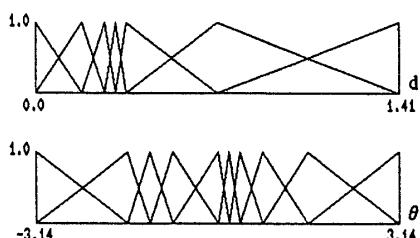


(a) 回避成功例

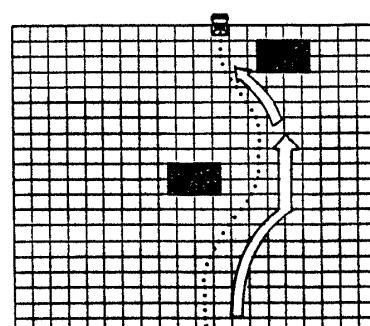


(b) 回避失敗例

図 13 2 つの障害物に対する回避軌跡



(a) 前件部メンバシップ関数



(b) 回避軌跡

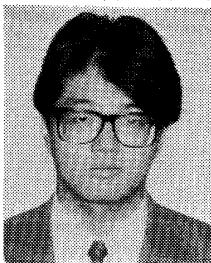
図 14 新しいルールとその回避軌跡

への適用から、非線形性の強さに応じてルールが生成され、等分割の場合に比べて同定に必要なルール数が低減されるという効果を示した。また、新たに入出力データが得られた場合にルールを再追加する手法について述べ、移動ロボットの障害物回避に適用してその有効性を確認した。

### 参考文献

- 1) 廣田：ファジイ制御の応用動向、計測と制御、Vol. 28, No.11, pp.970-975(1989)
- 2) 菅野：ファジイ制御、日刊工業新聞社(1988)
- 3) T.Takagi and M.Sugeno : "Fuzzy Identification of Systems and Its Application to Modelling and Control", IEEE SMC-15, pp.116-132, 1985.
- 4) M.Sugeno and G.T.Kang : "Structure Identification of Fuzzy Model", Fuzzy sets and Systems, 28, pp.15-33, 1988.
- 5) D.E.Rumelhart, J.L.McLleland and the PDP Research Group : Parallel Distributed Processing, MIT Press, 1987.
- 6) 林, 野村, 若見：ニューラルネット駆動型ファジイ推論による推論ルールの獲得、日本ファジイ学会誌、Vol.2, No.4, pp.133-145(1990)

### 著者紹介



荒木 昭一 (あらき しょういち)

松下電器産業㈱中央研究所 電子機器基礎研究所 第6研究室

1989年大阪府立大学・工学部・経営工学科を卒業、同年、松下電器産業㈱に入社、現在、中央研究所に所属。主として、ファジイ制御、ファジイモデリングの研究に従事。1992年電気関係学会関西支部連合大会奨励賞授賞。電子情報通信学会の会員。

7) 堀川, 古橋, 内川：ファジイニューラルネットワークによるファジイモデリング、第7回ファジイシステムシンポジウム講演論文集, pp.327-330(1991)

8) 市橋, 渡辺：簡略ファジイ推論を用いたファジイモデルによる学習型制御、日本ファジイ学会誌, Vol.2, No.3, pp.157-165(1990)

9) 渡辺, 市橋：n次メンバシップ関数を用いた逐次ファジイモデリングとそのクレーン制御への応用、日本ファジイ学会誌, Vol.3, No.2, pp.347-356(1991)

10) 市橋：C<sup>0</sup>級の階層型ファジイモデル、第7回ファジイシステムシンポジウム講演論文集, pp.505-508(1991)

11) 前田, 村上：自己調整ファジイコントローラ、計測自動制御学会論文集, 24-2, pp.191-197(1988)

12) 野村, 林, 若見：ニューラルネットの学習則によるファジイ推論の自動チューニングと障害物回避への応用、平成3年電気学会全国大会, s10-27/s10-30(1991)

(1991年11月7日 受付)

[問い合わせ先] (1992年5月15日 再受付)

〒570 大阪府守口市八雲中町3丁目1-1

松下電器産業㈱ 中央研究所  
電子機器基礎研究所 第6研究室

荒木 昭一 国内: 06-906-4849  
国際: 06-904-7252

E-mail: araki@crl.mei.co.jp

林 勲 (はやし いさお)



松下電器産業㈱中央研究所 電子機器基礎研究所 第6研究室

1981年大阪府立大学工学部経営工学科卒業、1985年大阪府立大学大学院(経営工学専攻)修了。1987年松下電器産業㈱に入社、現在、中央研究所に所属。主として、ファジイ推論とニューラルネットワークとの融合研究、ファジイ検索の研究に従事。1991年電気関係学会関西支部連合大会講演会奨励賞授賞。工学博士。人工知能学会、電気学会、日本ファジイ学会、国際ファジイシステム学会などの会員。

若見 昇 (わかみ のぼる)



松下電器産業㈱中央研究所 電子機器基礎研究所 第6研究室

1971年大阪大学・基礎工学部・制御工学科卒業、同年、松下電器産業㈱に入社、現在中央研究所電子機器基礎研究所第6研究室室長。ファジイ理論とその応用に従事。工学博士。日本ファジイ学会、情報処理学会、システム制御情報学会などの会員。



野村 博義 (のむら ひろよし)

松下電器産業㈱中央研究所 電子機器基礎研究所 第6研究室

1986年九州工業大学・工学部・制御工学科を卒業、同年、松下電器産業㈱に入社、現在、中央研究所所属。主として、ファジイ制御、ファジイエキスパートシェル、ファジイ推論とニューラルネットの融合研究に従事。システム情報制御学会などの会員。