

Fuzzy Modeling Using a Heuristic Method and Its Application to the Prediction Diagnosis of Ectopic Pregnancy

Mikio MAEDA, Katsuhiko HAYASHIDA, and Shuta MURAKAMI

Department of Computer Engineering,
Faculty of Engineering, Kyushu Institute of Technology

(received 10 March 1996; revised and accepted 15 June 1996)

Abstract: In this paper, we propose the heuristic clustering for a fuzzy modeling. This approach divide an input variable space into some clusters by using an approach following human's experience and intuition. An input variable space is divided into a lot of subspaces, and we suppose that their relations of input variables and output variables are linear. If unit normal vectors of some subspaces are similar, they are unified as a cluster. Then, some clusters are generated. After the heuristic clustering, we set membership functions of premise parts, and values of consequent parts are learned by a steepest decent method. To verify this approach, we show nonlinear function's approximation as a result. Furthermore, as an example of application, we show fuzzy model for the predicting diagnosis of ectopic pregnancy after the pregnancy effect for infertile patients.

keywords: fuzzy modeling, fuzzy expert system, simplified fuzzy reasoning, clustering, diagnosis, ectopic pregnancy

ヒューリスティックな手法を用いた ファジィモデリングとその予測診断への応用

前田幹夫 林田克彦 村上周太

九州工業大学工学部

要約: 本論文では、ヒューリスティック・クラスタリングにより入力変数空間をファジィ分割し、ファジィモデルを自動生成する手法を提案する。ヒューリスティック・クラスタリングにより人間の経験的・直観的な判断方法を利用したヒューリスティックな手法で入力変数空間をクラスタリングし、後件部を実数値としたファジィモデルを自動生成するものである。入力変数空間を直方体状に小さく切り分け、その部分の入出力関係を線形であるとみなし、単位法線ベクトルを計算し、単位法線ベクトルの似ている部分を集めてクラスタとすることでファジィ分割を実現する。また、ファジィルールの後件部実数値の学習には最急降下法を用いる。提案手法の検証のために従来手法との関数の近似能力の比較結果を示し、更に応用例として、不妊症患者の妊娠転帰後の予後予測診断モデル、つまり、子宮外妊娠の予測診断モデルの構築について示す。

キーワード: ファジィモデリング, ファジィエキスパートシステム, 簡略ファジィ推論, クラスタリング, 診断, 子宮外妊娠

Mikio MAEDA
Kyushu Institute of Technology
Sensuicho1-1, Tobata, Kitakyushu, 804, Japan
Phone: +81-93-884-3249, Fax: +81-93-871-5835
E-mail: mmaeda@mura.comp.kyutech.ac.jp

1 はじめに

近年の計算機技術の発達につれて、専門家の意思決定の過程や行動パターンを分析し、計算機上でモデル化することにより、問題を処理させようという試みがなされている。そのためのアプローチとして意思決定分析、知識工学的手法などが考えられる。意思決定分析には数学的に厳しい条件が伴うが、知識工学的手法は思考過程を原因と結果の関係(知識ルール)によって記述しモデルを構築する手法であり、意思決定分析ほどの厳しい条件を必要としない。また、結果を導くための推論の過程の理解が容易である。この知識工学的手法の応用であり、知識処理の実用的なシステムとしてエキスパートシステムがある。

ファジィ理論は、言葉の意味や定義に含まれるあいまいさ“ファジィネス”を用いてシステムの複雑性とデータの不完全性に対処する人間の認識、判断、思考などを表現するものである。エキスパートシステムにファジィ理論を導入することにより、さまざまなあいまいさに対処し得る実用性の高いエキスパートシステムがファジィ・エキスパートシステム[1][2]である。エキスパートシステムの問題のひとつに知識の獲得がある。これは、エキスパートの経験知識を引き出す方法である。エキスパートから直接、または得られたデータから、知識つまりエキスパートの意思決定過程と同等の“ファジィモデル”[3]を引き出す方法があり、それらを“ファジィモデリング”[4]と呼ぶ。ファジィモデリングとは、ファジィ関係やファジィ測度によるモデリングも含むが、データを用いた予測モデルには、データのあいまい性に注目し、回帰モデルの係数をファジィ数として同定する可能性線形回帰モデル[5]がある。また、構造のあいまい性に注目した、ファジィルール(IF-THEN ルール)の集合体であるルール型モデルがある[6][7]。

ルール型モデルのモデリングには、ルールの後件部を線形式とした後件部線形式モデル[8]のモデリング手法[9][10][11]やルールの後件部を非線形式とした後件部非線形式モデルのモデリング手法[12]が提案されている。さらに、ルールの後件部を実数値とした後件部実数値モデルのモデリング手法[13][14]も提案されている。後件部線形式モデルおよび後件部非線形式モデルは回帰モデルを拓

張したものであり、記述能力が高く、数量的な関係をモデル化するのに適している。また、それらは前件部のファジィ分割数(入力変数空間の分割)を抑えることができる。しかし、その欠点として、後件部が多項式であることからルールの解釈が難しくなり、同定にかなりの時間を要し、適応制御などの実時間のモデリングには不向きである。さらに、エキスパートシステムの知識ルール(例えば、“もし体温が高ければインフルエンザである”といった知識ルール)の獲得など、応用できない分野がある。

ルールの後件部を実数値としたモデルは元々ファジィ量であるのを実数値とみなしたもので、その特徴としては、Mamdaniの直接推論法に比べ推論が高速であり、実時間でのモデリングが行いやすいことや、ファジィ分割された変数空間の一つのブロックだけを考えたとき、入出力関係に非線形性の強い部分は現れないといった利点がある。また、このモデルは、後件部多項式モデルにおける後件部が定数項のみの場合と等価であるため、記述能力では後件部多項式モデルに劣るものの、定性的な理解が容易であるという特徴がある。さらに、このモデルはエキスパートから直接得られる知識ルールと同様のルール形式であり、エキスパートシステムの“知識ルール”として有効である。

さて、どのモデルにおいても、入力変数空間のファジィ分割は最も困難な作業であり、分割された領域のなかで、推論誤差の大きい領域を等分割し、逐次的にルールを生成する手法[13][14]が提案されているが、これらの方法は領域を等分割するため、初期の段階でのファジィ分割が柔軟でない。

本研究では、モデルの構築の方法や過程が理解しやすいものであれば、エキスパートシステムの利用者にとって構築されたモデルが受け入れ易いと考え、後件部実数値ファジィモデルのモデリングにおいて、人間の経験的・直観的な判断方法を利用したヒューリスティックな手法で入力変数空間をクラスタリングし、ファジィ分割を行う手法を提案する。そして、応用例として、不妊症患者の妊娠転帰後の患者が子宮外妊娠となるかどうかの予後予測診断(判定)モデルの構築について示す。

2 ヒューリスティックな手法による ファジィモデリング

2.1 ルールの形式と推論方法

本手法では、前件部メンバシップ関数に正規三角型メンバシップ関数を用い、後件部を実数値とし、推論には簡略推論法[15]を用いる。(1)式に前件部変数の場合のルール形式とその推論計算を(2)式に示す。

$$R_i: \text{IF } x_1 \text{ is } A_{i1} \text{ and } x_2 \text{ is } A_{i2} \text{ THEN } y = \bar{y}_i \quad (1)$$

$$(y \text{ is } B_i)$$

$$(i = 1, 2, \dots, n)$$

$$y^* = \frac{\sum_{i=1}^n w_i \cdot \bar{y}_i}{\sum_{i=1}^n w_i} \quad (2)$$

$$w_i = \mu_{A_{i1}}(x_1^*) \cdot \mu_{A_{i2}}(x_2^*)$$

ここで、 x_1, x_2 は入力情報（症状、検査等）、 y は出力（疾患名、治療名等）、 A_{i1}, A_{i2} はファジィラベル、 \bar{y}_i は可能性を表す。 w_i は実入力 x_1^*, x_2^* の*i*番目のルールの前件部に対する適合度を表すものと解釈する。 y^* は*y*の推論値（実数値）であり、 \bar{y}_i はそれぞれ*i* = 1, 2, ..., *n*に対して、メンバシップ関数 $\mu_{B_i}(y)$ (*i* = 1, 2, ..., *n*)が最大値をとるときの*y*の値である。図1に前件部メンバシップ関数の例を示す。図の C_k (*k* = 1, 2, ..., 5)はファジィラベルであり、(1)式の条件部のファジィラベルの各々はこの中の一つを採る。




図1 前件部メンバシップ関数

2.2 ヒューリスティック・クラスタリング

クラスタリングの手順は大きく3つのステップに分かれる。2入力1出力の場合のクラスタリングの方法について、順を追って説明する。

(ステップ1-1)

x_1 軸を N_1 個、 x_2 軸を N_2 個の区間に分けることで、入力変数空間を格子状に区切る。次に、各々の格子の入出力関係を1つの平面と仮定し、それぞれの格子内に属するデータセットを用いて単位法線ベクトルを計算する。法線ベクトルの計算の方法について以下に示す。図2において、 x_1 軸上において*i*番目、 x_2 軸上において*j*番目の区間によって切り取られる格子の入出力関係を平面とみなし、その方程式 $f_{ij}(x_1, x_2)$ を(3)式とすると、その法線ベクトル v_{ij} は(4)式で表される。




図2 *i, j*番目の格子において仮定される平面

$$f_{ij}(x_1, x_2) = a_{ij1}x_1 + a_{ij2}x_2 + a_{ij3} \quad (3)$$

$$v_{ij} = \begin{bmatrix} a_{ij1} & a_{ij2} & 1 \\ d & d & d \end{bmatrix}^t \quad (4)$$

ここで、 t は転置を意味し、

$$d = \sqrt{a_{ij1}^2 + a_{ij2}^2 + a_{ij3}^2} \quad (5)$$

である。係数 $a_{ij1}, a_{ij2}, a_{ij3}$ は最小二乗法による線形回帰分析を用いて求める。

(ステップ1-2)

x_1 軸について、 x_2 軸の区間を固定してある断面を切り出し、その断面で隣り合う格子の単位法線ベクトル間距離（内積）を計算する。図3(a)において、*ij*番目の格子の単位法線ベクトルを

$$\mathbf{v}_{ij} = [x_{ij1} \quad x_{ij2} \quad y_{ij}]^t$$

とする。また、 $(i+1)j$ 番目の格子の単位法線ベクトルを

$$\mathbf{v}_{(i+1)j} = [x_{(i+1)j1} \quad x_{(i+1)j2} \quad y_{(i+1)j}]^t$$

とする。隣り合う格子の法線ベクトル間の距離 $dis_1(\mathbf{v}_{ij}, \mathbf{v}_{(i+1)j})$ ($i=1,2,\dots,N_1-1$) を(6-a)式により計算する。これを x_2 軸のすべての区間、つまり ($j=1,2,\dots,N_2$) について計算する。同様の手続きを図3(b)のように x_2 軸についても行い、(6-b)式に示す単位法線ベクトル間距離 $dis_2(\mathbf{v}_{ij}, \mathbf{v}_{i(j+1)})$ ($i=1,2,\dots,N_1, j=1,2,\dots,N_2-1$) を計算しておく。

$$dis_1(\mathbf{v}_{ij}, \mathbf{v}_{(i+1)j}) = \sqrt{(x_{(i+1)j1} - x_{ij1})^2 + (x_{(i+1)j2} - x_{ij2})^2 + (y_{(i+1)j} - y_{ij})^2} \quad (6-a)$$

$$dis_2(\mathbf{v}_{ij}, \mathbf{v}_{i(j+1)}) = \sqrt{(x_{i(j+1)1} - x_{ij1})^2 + (x_{i(j+1)2} - x_{ij2})^2 + (y_{i(j+1)} - y_{ij})^2} \quad (6-b)$$




図3 単位法線ベクトル間の距離の計算

(ステップ1-3)

x_1 軸のファジィラベルの数 LN_1 個から定義域両端の2つのファジィラベルの数を除いた LN_1-2 個の x_1 軸上の区間と区間の境界を距離の大きなものから順にピックアップし、メンバシップ関数の頂点の設定位置とする。 x_2 軸についても同様に、 LN_2-2 個の位置を決定し、入力変数空間がクラスタリングされる。図4は $N_1=4, N_2=4, LN_1=4, LN_2=4$ とした場合の例である。距離 dis_1, dis_2 が計算され、 x_1 軸において、

dis_1 の値は0.88が最も大きいので1つ目の設定位置が決定される。0.64が次に大きい値であるが、既に設定位置に決定されているので無視し、次に大きい値0.52により2つ目の設定位置が決定される。 x_2 軸についても同様な手続きにより設定位置が決定され、前件部メンバシップ関数が設定される。

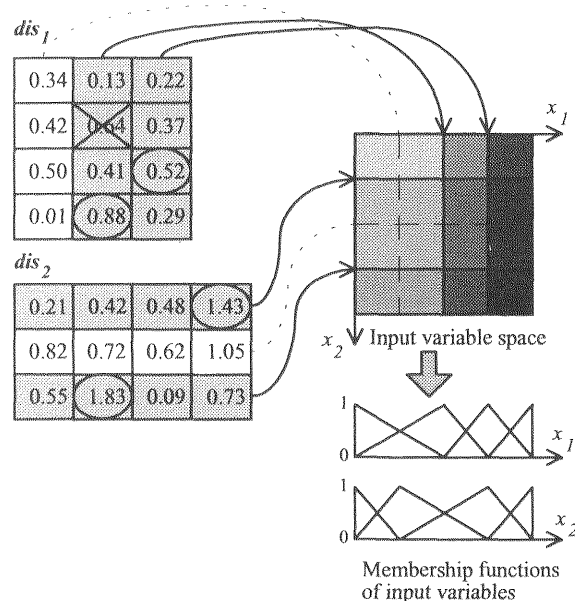


図4 入力変数空間分割の例

2.3 後件部実数値の学習

2.2 のクラスタリングの結果から得られる入力変数空間の分割を用いて、後件部の実数値の同定を行い、ファジィ分割を実現する方法について説明する。クラスタリングの結果、ルールを設定する点が全部で $LN_1 \times LN_2$ 個決定される。これらを用いてメンバシップ関数を設定し、後件部の実数値の学習を行う。学習の方法には最急降下法[16]を用いる。入力変数 x_1, x_2 のデータ x_{1k}, x_{2k} ($k=1,2,\dots,N$) と、それに対する出力変数 y のデータ y_k ($k=1,2,\dots,N$) が与えられると、(7)式によりファジィ推論の出力値 y_k^* を計算する。

$$y_k^* = \frac{\sum_{i=1}^{LN_1} \sum_{j=2}^{LN_2} w_{ijk} \cdot \bar{y}_{ij}}{\sum_{i=1}^{LN_1} \sum_{j=2}^{LN_2} w_{ijk}} \quad (7)$$

ただし、 \bar{y}_{ij} は i, j 番目のルールの後件部実数

値である。また、 w_{ijk} は i, j 番目のルールに対する入力データ x_{1k}^*, x_{2k}^* の前件部適合度であり、

$$w_{ijk} = \mu_{A_{ij1}}(x_{1k}^*) \cdot \mu_{A_{ij2}}(x_{2k}^*) \quad (8)$$

で計算される。各ルール R_{ij} における後件部の実数値 \bar{y}_{ij} を最急降下法に基づく(9)式により更新する。

$$\bar{y}_{ij}^{NEW} = \bar{y}_{ij}^{OLD} - k_w \cdot w_{ijk} (y_k^* - y_k) \quad (9)$$

ここで、 k_w は調整係数である。

2.4 モデリングの手順

2.2の入力変数空間分割および2.3の後件部実数値の学習方法を用いて、2入力1出力データに対するモデリングを行う手順について示す。

(ステップ2-1)

以下に示す初期設定作業を行う。

- ①入力変数 x_1, x_2 および出力変数 y の実データを読み込み、それぞれ $[-1, 1]$ の範囲に規格化する。
- ②入力変数 x_1, x_2 の各軸の区間の分割数 N_1, N_2 を設定する。これらは、各格子の単位法線ベクトルを求めるために、格子内に十分にデータが存在するように(10)式により設定する必要がある。

$$N_M \geq \frac{N}{N_1 \times N_2} \quad (10)$$

ここで、 N_M はひとつの格子に存在を要するデータの数である。データにはばらつきがあるため、この値はある程度大きなものでなければならない。

- ③モデルの目標推論誤差平均 T_1 を設定する。
- ④変数 x_1, x_2 の各軸のラベル数 LN_1, LN_2 の初期値を設定する。定義域の両端の2つのラベルを考慮すると、3以上の値でなければならない。
- ⑤2.2のクラスタリングにおいて、(ステップ1-1) 単位法線ベクトルの計算を行う。また、(ステップ1-2) 単位法線ベクトル間距離の計算も行う。
- ⑥調整係数 k_w を学習回数が増大しない範囲でできる限り小さな値に設定する。

- ⑦学習回数 $l=0$ とする。

(ステップ2-2)

2.2のクラスタリングにおける(ステップ1-3) 入力変数空間分割を行う。

(ステップ2-3)

N 個の入出力データを用いて2.3の後件部実数値の学習を行う。また、学習回数 $l \leftarrow l+1$ とする。

(ステップ2-4)

(11)式を満足すれば、モデルに必要な精度が確保されているとして終了する。満足しない場合には、(ステップ2-5)に進む。

$$D(l) \leq T_1 \quad (11)$$

ここで、 $D(l)$ は推論誤差平均であり、(12)式によって計算される。

$$D(l) = \frac{1}{N} \sum_{i=1}^N |y_i^* - y_i| \quad (12)$$

ここで、 y_i は実際の出力データ、 y_i^* はモデルの推論値である。

(ステップ2-5)

(13)式を満足すれば、これ以上学習しても効果はないと判断し、(ステップ2-6)へ進む。満足しない場合には、さらに学習を行うために(ステップ2-3)に進む。

$$\Delta D(l) \leq T_2 \quad (13)$$

ここで、 $\Delta D(l)$ は誤差の減少の度合であり、(14)式によって計算される。

$$\Delta D(l) = |D(l) - D(l-1)| \quad (14)$$

また、 T_2 はそのしきい値であり、推論誤差の減少にともない、よりオーダーの低い値に変化させる。例えば、 $D(l)$ が 1.0×10^{-4} のオーダーに減

少しの場合は T_2 は 1.0×10^{-5} といった具合に変更していく。

(ステップ2-6)

x_1, x_2 の各入力変数軸の区間で、まだメンバーシップ関数の設定位置と決定していない区間のうち、法線ベクトル間の距離の大きい方の変数軸のラベル数、つまり、 LN_1, LN_2 のどちらかをインクリメントし、ラベル数を増加させる。そして、(ステップ2-2)に戻る。

以上の手続きにより、モデリングが行われる。これらの手続きのフローチャートを図5に示す。

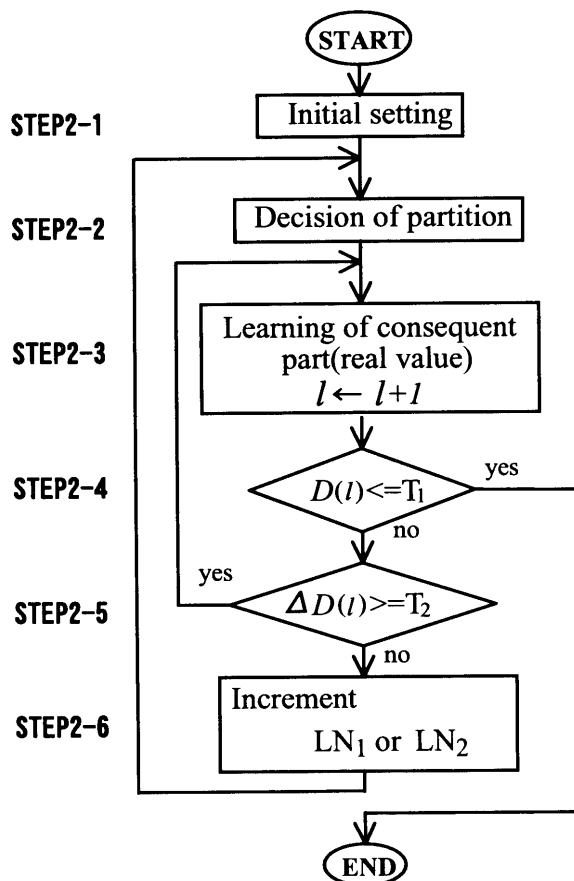


図5 モデリングの手順

3 従来手法との関数近似能力の比較

提案手法と、従来の手法である誤差の大きい領域にルールを自動生成する手法を用いて(15)式に示す2入力1出力関数を同定し、推論誤差平均の値を比較することで、モデリング性能の比較を行う。

$$y = f_1(x_1) + f_2(x_2)$$

$$f_1(x_1) = \begin{cases} -(x_1 + 0.125) & ; -1 \leq x_1 < -0.125 \\ (x_1 + 0.125)^2 & ; -0.125 \leq x_1 \leq 1 \end{cases}$$

$$f_2(x_2) = \begin{cases} -(x_2 - 0.375) & ; -1 \leq x_2 < 0.375 \\ (x_2 - 0.375)^2 & ; 0.375 \leq x_2 \leq 1 \end{cases} \quad (15)$$

入力変数 x_1, x_2 の変域を $[-1, 1]$ とし、一様乱数によりデータを 2000 個発生させる。また、提案手法における入力変数 x_1, x_2 の区間分割数 $N_1 = N_2 = 20$ とし、モデルの目標推論誤差平均 $T_1 = 0.01$ とした場合の従来手法と提案手法でのモデリングにおける推論誤差平均の推移を表1に示す。

表1 推論誤差平均の推移

Convention		Propose	
Total of rules	Average of error	Total of rules	Average of error
3×3	0.074715	3×3	0.056233
3×4	0.034491	4×3	0.033425
4×4	0.020652	—	—
—	—	5×3	0.020121
4×5	0.017446	5×4	<u>0.018138</u>
4×6	0.016251	6×4	0.013559
4×7	0.014997	—	—
—	—	6×5	0.013220
5×7	0.014639	7×5	0.010175
6×7	0.012617	7×6	0.010146
7×7	0.010922	7×7	0.008489
8×7	0.009966	—	—

表1を見ると、ルールの条件部の組み合わせは少し異なる(二つのアルゴリズムの差によって生じた)が、ルール総数で比較すると、提案手法の推論誤差平均が、表の下線を記した値を除き、従来手法より小さくなっている。この結果から、提案手法は、従来手法よりも適切な位置にルールが設定され、同定する対象の関数をより高い精度で近似しているということがわかる。また、提案手法は、従来手法よりはやく条件を満たした。そして、ラベルの数を1つ増加した場合の推論誤差平均は、従来手法より良い結果となっている。また、同定の対象である関数の変数 x_1 の関数である $f_1(x_1)$ と、変数 x_2 の関数である $f_2(x_2)$ の入出力関係を図6(a)に、提案

手法において, $LN_1 = LN_2 = 7$, ルール数 7×7 の場合に設定されたメンバシップ関数を図 6(b)に示す.

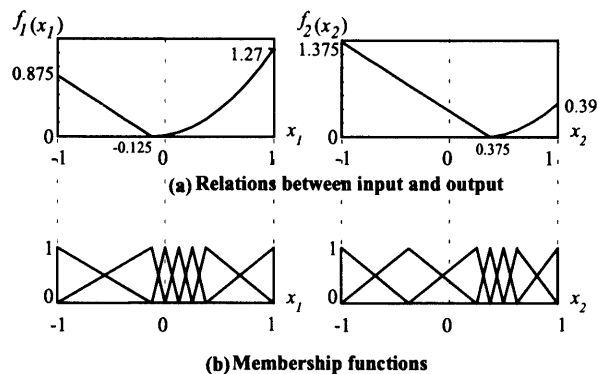


図 6 関数の入出力関係とメンバシップ関数

同定対象の関数の入出力関係を図 7(a)に示す. また, 提案手法において $LN_1 = LN_2 = 7$, ルール数 7×7 の場合の入出力関係を図 7(b)に示す.

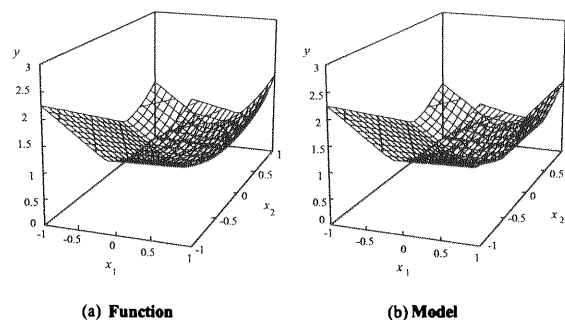


図 7 関数と生成されたモデルの入出力関係

図 6 を見ると, 同定の対象である関数 $f_1(x_1)$ と, 関数 $f_2(x_2)$ の非線形性の強い変数値の部分にルールが設定されていることがわかる. また, 若干の無駄があるが, これはデータによる影響であると思われる. データに偏りがあった場合, その部分の平面の法線ベクトルが偏ったものになってしまうため, ベクトル間の距離が大きくなってしまいうためであると思われる. また, 図 7(a)と図 7(b)を比較すると, ほとんど同じ入出力関係が得られていることがわかる.

4 妊娠転帰後の子宮外妊娠診断モデル

4.1 不妊症患者への治療と子宮外妊娠

不妊症の原因には男性側にある場合と女性側

にある場合があるが, ここでは女性側の不妊症について考える. 女性側の子宮, 卵管, 卵巣のどの部位が障害されても不妊の原因となるが, その中のひとつとして排卵障害がある. この場合, その原因が卵巣なのか, もっと中枢の視床下部, 脳下垂体なのかによって治療の方法が異なる. 治療の成績がいいのは脳下垂体の働きに異常がある場合で, ホルモン剤の内服や注射により軽症では 80 パーセント, 重症でも 30~50 パーセントは排卵を起こすことができる. このような目的によく用いられるのが各種の排卵誘発剤と呼ばれるもので, クロミフェンや HMG, HCG などの薬である. また, 排卵障害のうち, 異常な乳汁分泌がある場合や, プロラクチンという脳下垂体ホルモンの異常がある場合には, プロモクリプチンが使用される. 検査と薬剤の進歩により, 排卵障害で不妊になっている人の治療成績は最近非常によくなっているが, 多胎や流早産などの頻度は, 正常の妊娠に比べて高い. これらの治療により, 妊娠に成功した場合, 通常, 妊娠 4 週 0 日から 4 日に妊娠反応が出る. 正常子宮内妊娠であれば妊娠 4 週 5 日から 5 週 3 日までに子宮内に胎嚢 (胎児の袋) ができる. 黄体ホルモンの値が低い場合, また出血があるとき, 妊娠 5 週 3 日になっても経膈超音波で子宮内に胎嚢が見えないときなどは子宮外妊娠を疑う. 子宮外妊娠の診断では妊娠 6 週 7 日位までに経膈超音波で子宮外に胎嚢を疑わせる所見が見える. 更に, 腹腔鏡により確定診断する. 妊娠反応が出て子宮内に胎嚢が見えはじめる妊娠 4 週 5 日までに子宮外妊娠かそれ以外かを予測するために, 妊娠反応が出た時点で HCG の定量, 黄体ホルモン (プロゲステロン), エストラジオールを採血, 出血がないか, 腹痛がないかなどを問診する [17][18].

4.2 子宮外妊娠の診断モデルの構築

排卵後 7 日のプロゲステロン, エストラジオール, 妊娠 4 週目のプロゲステロン, エストラジオール, HCG と妊娠の予後に関する実際のデータ (症例数 73, うち確定診断が子宮外妊娠だったものは 7 症例, それ以外だったものは 66 症例) から, 子宮外妊娠の診断モデルを構築する.

具体的には、排卵後 7 日のプロゲステロン値 P および、排卵後 7 日目に対する妊娠 4 週のプロゲステロン値の増分 ΔP を入力変数とする。出力変数は子宮外妊娠発生の可能性とし、確定診断が子宮外妊娠であれば 1、それ以外の場合を 0 としてモデリングを行う。区間分割数 $N_1 = N_2 = 5$ 、 $T_1 = 0.42$ として同定実験を行ったところ、 $LN_1 = 6, LN_2 = 5$ 、ルール数 6×5 、誤差平均 $D = 0.418981$ で終了した。図 8 は生成されたモデルの前件部メンバシップ関数である。また、生成されたルールを表 2 に示す。




図 8 前件部メンバシップ関数

表 2 診断ルール

Pos. (Cons. value)	P						
	P1	P2	P3	P4	P5	P6	
ΔP	NB	0.684	0.756	0.007	0.084	0.164	0.205
	NM	0.698	1.478	0.521	0.126	0.451	0.470
	NS	0.199	0.493	0.304	-0.195	-0.025	0.227
	PS	-0.069	0.036	-0.023	0.092	0.333	0.406
	PB	-0.012	0.040	0.470	0.492	0.500	0.500

表 3 度数及び累積度数とその割合

Pos. (Output value)	Ectopic pregnancy			Other		
	Freq.	Accumulation Freq.	Ratio (%)	Freq.	Accumulation Freq.	Ratio (%)
0.9~	0	0	0	0	0	0
0.8~ Less than 0.9	0	0	0	0	0	0
0.7~ Less than 0.8	1	1	14.3	0	0	0
0.6~ Less than 0.7	1	2	28.6	0	0	0
0.5~ Less than 0.6	1	3	42.9	2	2	3.0
0.4~ Less than 0.5	0	3	42.9	2	4	6.1
0.3~ Less than 0.4	2	5	71.4	9	13	19.7
0.2~ Less than 0.3	2	7	100	14	27	40.9
0.1~ Less than 0.2	0	7	100	15	42	63.6
~ Less than 0.1	0	7	100	24	66	100

表 2 を見ると、排卵後 7 日のプロゲステロン値が低く、妊娠 4 週に排卵後 7 日よりプロゲステロン値が減少しているものが子宮外妊娠の可能性が高い傾向にあることがわかる。また、排卵後 7 日のプロゲステロン値が P5 あるいは P6 で、妊娠 4 週のプロゲステロン値の増分が PB の場合の後件部の実数値が 0.5 となっているが、この部分にはデータが存在せず、学習が行われなかったためである。次に、生成されたモ

デルに対して、モデリングに用いた全ての症例について可能性を計算させた。表 3 は、確定診断が子宮外妊娠であった症例と、それ以外の症例についての度数と累積度数および累積度数に対する割合を示したものである。また、子宮外妊娠とそれ以外の疾患（正常妊娠、流産等）の可能性に対するヒストグラムを図 9 に示す。




図 9 ヒストグラム

表 3 の累積度数の割合を見ると、確定診断が子宮外妊娠であった症例については、0.5~1 までに 42.9 パーセントが入っており、可能性が高くなった。ほぼ半数が、子宮外妊娠である疑いが強いという結果が得られた。それに対して、確定診断がそれ以外であった症例については、0.5~1 に 3.0 パーセントが入り、ほとんどのデータについて子宮外妊娠である疑いは弱いという結果が得られた。また、図 9(b)を見ると、確定診断が子宮外妊娠でない症例は可能性が低い傾向が明らかに現れており問題はないが、図 9(a)を見ると、確定診断が子宮外妊娠であった症例のうち、0.2 から 0.4 未満に 4 つの症例が入っており、低い値となっている。これらの症例について調査したところ、排卵後 7 日のプロゲステロン値に対して、妊娠 4 週目のプロゲステロン値がそれほど下がっていない傾向にあることがわかった。その他の 3 症例は妊娠 4 週目のプロゲステロン値が大きく下がっていた。確定診断が子宮外妊娠以外であった症例は排卵後 7 日のプロゲステロン値に対して、妊娠 4 週目のプロゲステロン値が上昇する傾向にあるが、それほど上昇しない症例もあり、それらと先の 4 つの症例の区別がつきにくかったためであると考えられる。また、症例数が少なすぎるのがなにより大きな原因であると思われる。

今回は、入力変数を 2 つとし、73 症例を用いてモデリングを行ったが、これらの結果から、排卵後 7 日のプロゲステロン値 P および、排卵後 7 日から妊娠 4 週目のプロゲステロン値の変化分

ΔP から子宮外妊娠を起こすかどうかをある程度推測することが可能であると思われる。今回は症例数が少なく、データをモデリングと検証のため2分割する必要があるが、それができなかった。より多くの症例について検定などを行い、モデリングを行えば、より高い精度で診断を行えるモデルを構築することが可能であると思われる。

5 まとめ

本論文では、人間の経験的・直観的な判断方法を利用したヒューリスティック・クラスタリングで入力変数空間をクラスタリングし、ファジィ分割を行う手法を提案した。ヒューリスティック・クラスタリングは、入力変数空間を格子状に切り分け、それぞれの格子の入出力関係を平面(タイル)とみなす。そして平面の傾きの大きく異なる部分、つまり隣り合う格子の単位法線ベクトル間の距離の大きい部分をピックアップし、分割点とすることで入力変数空間を線形な部分(クラスター)に分ける手法である。また、ヒューリスティック・クラスタリングの結果を用いて前件部のメンバシップ関数を設定し、後件部の実数値を最急降下法により学習することによりファジィモデルを生成する手法を示した。

提案手法の検証のために、分割された領域のなかで、推論誤差の大きい領域を等分割し、逐次的にルールを生成する従来のファジィ分割手法との関数の近似能力の比較を行った。その結果、変数軸の分割数をひとつ増加させた場合、提案手法は、推論誤差の平均値において、従来手法より一部を除いて常に小さく、良好な結果が得られた。また、若干のロスはあるものの、同定の対象の関数の非線形性の強い部分にルールが生成されており、適切なファジィ分割の実現が可能であるという結果が得られた。

実例において、不妊症患者に対する治療によって、妊娠反応が出た時点での子宮外妊娠を予測するモデルを提案手法を用いて構築した結果、症例数が少ないながらも、子宮外妊娠をある程度予測することができるモデルを構築できたと思われる。

今後の課題としては、データのばらつきによって生ずる無駄な分割を少なくすることや、ルール

を必要に応じて削減する機能を持たせること、ユーザインタフェースを開発し、モデルの作成がだれにでも容易にできるようなモデリング・システムを構築すること、さらに複雑な対象や、他分野の同定対象のモデリングを行うことが挙げられる。

最後に、妊娠患者のデータを提供していただいた佐賀医科大学野見山真理先生に感謝します。

参考文献

- [1] 日本ファジィ学会 : 講座ファジィ 8 ファジィ・エキスパート・システム, 日刊工業新聞社 (1993)
- [2] 寺野, 浅居, 菅野 : 応用ファジィシステム入門, オーム社 (1989)
- [3] 寺野 : システム工学入門 - あいまい問題への挑戦 -, 共立出版 (1985)
- [4] 田中 : ファジィモデリングとその応用, 朝倉書店 (1990)
- [5] 菅野, 田中 : システムのファジィモデリングとその解析, 第13回システムシンポジウム講演論文集, pp.81-84 (1987)
- [6] T.Takagi, M.Sugeno : Fuzzy Identification of Systems and Application to Modeling and Control, IEEE Trans. Systems, Man and Cybernetics, Vol. S.M.C.-15, No.1, pp.116-132 (1985)
- [7] M.Sugeno, G.T.Kang : Structure Identification of Fuzzy Model, Fuzzy Sets and Systems, Vol. 28, pp.15-33 (1988)
- [8] 中森, 領家 : ファジィモデリング再考, 日本ファジィ学会誌, Vol.5, No.3, pp.453-464 (1993)
- [9] 菅野 : ファジィ制御, 日刊工業新聞社 (1988)
- [10] 廣田, 吉成 : FCV(Fuzzy C-Varieties)によるファジィ分割アルゴリズム, 第13回知能システムシンポジウム, pp.13-18 (1991)
- [11] 林, 野村, 若見 : ニューラルネット駆動型ファジィ推論による水温ルールの自動獲得, 日本ファジィ学会誌, Vol.2, No.4, pp.587-597 (1990)
- [12] M.Maeda, S.Murakami : A Design for Fuzzy Logic Controller, INFORMATION SCIENCES 45, pp.315-330 (1988)
- [13] 荒木, 野村, 林, 若見 : 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)

[14] 梶谷, 片山, 西田 : 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, pp.257-260 (1992)

[15] 前田, 村上 : 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)

[16] 市橋, 渡辺 : 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.157-165 (1990)

[17] 相賀 : 最新医学全書 4, 小学館 (1990)

[18] 野見山, 中村 : IVF・ET, AIH妊娠例における妊娠4週血中progesterone測定の有用性についての検討, 第46回日本産科婦人科学会雑誌, Vol.46 (1994)



村上 周太 (むらかみ しゅうた)

九州工業大学工学部電気工学科情報工学教室


1969年 東京工業大学大学院理工学研究科博士課程制御工学専攻修了, 工学博士。

1969年 九州工業大学制御工学科講師, 1970年 同助教授,

1984年 九州工業大学情報工学科教授, 現在に至る。

ファジィ制御, コンピュータネットワーク, 意思決定理論などの研究に従事。

計測自動制御学会, 日本オペレーションズ・リサーチ学会, 国際ファジィシステム学会, 日本ファジィ学会などの会員。



前田 幹夫 (まえだ みきお)

九州工業大学工学部電気工学科情報工学教室

1969年 国立熊本電波高専旧本科卒,

1990年 工学博士。

1969年 九州工業大学制御工学科技官,

1975年 同大学情報工学科技官,


1989年 同大学情報工学教室(旧情報工学科)助手,

1996年 同助教授,

現在に至る。

ファジィ制御, ファジィエキスパートシステム, 医療における意思決定, ニューラルネットワークなどの研究に従事。

計測自動制御学会, 日本ファジィ学会, 日本機械学会などの会員。



林田 克彦 (はやしだ かつひこ)

九州工業大学大学院工学研究科博士前期課程

1994年 九州工業大学電気工学科情報工学コース卒。

1994年 九州工業大学大学院電気工学専攻博士前期課程入学,

現在に至る。

ファジィ制御, ファジィエキスパートシステム, ファジィモデリングなどに興味を持つ。