

判別分析を基準とするファジークラスタリングによる 多次元データの可視化手法の提案

山本 康高^{†a)} 吉川 大弘^{††} 古橋 武[†]

A Proposal of Visualization Method for Multi-Dimensional Data Using Fuzzy Clustering Based on Multiple Discriminant Analysis

Kosuke YAMAMOTO^{†a)}, Tomohiro YOSHIKAWA^{††}, and Takeshi FURUHASHI[†]

あらまし 可視化は、多次元のデータの分布や構造を把握し、有用な知識を抽出するための重要な技術の一つである。可視データを得る方法の一つにクラスタリングと判別分析を組み合わせる方法がある。しかし、従来用いられている手法では、これらを独立に行っており、得られるクラスは判別分析を考慮していない。本論文ではファジークラスタリングとファジー判別分析 (Fuzzy Multiple Discriminant Analysis: FMDA) を反復適用する可視化手法を提案する。提案手法は、FMDA によって分割が容易であることをファジークラスタリングの基準とすることを特徴としている。本手法は、この基準のもとでクラス境界を自動的に決定できるため、データを解析しやすい可視化が行える。数値実験により、提案手法が適切なクラスを形成し、可視化されたデータから有用な知識が抽出可能であることを示す。

キーワード 可視化, 判別分析, クラスタリング, 次元圧縮

1. ま え が き

多次元のデータから有益な情報を抽出できる解析手法が望まれている。多次元データの解析において、データの全体像をとらえることができれば、知識抽出は容易となる。したがって、データを二～三次元空間 (以降、可視空間) に可視化することは、人が視覚的にデータ構造を把握することを容易にし、知識抽出に有効である。

このような二～三次元の空間で視覚的にとらえられるデータ (以降、可視データ) を得る方法の一つに、クラスタリングと次元圧縮を組み合わせた手法がある。クラスタリングはデータ構造を同定することで、対象の解析を容易にする。また次元圧縮は、データのもつ特徴を可視空間に射影することにより、データ構造の把握やデータの特性の定性的理解を容易にする。この

ような可視データを得るためには、多次元空間におけるクラスを極力重ならないように射影する適切な軸の設定が重要となる。

その方法の一つは、クラス内散布・クラス間散布の比を最大にする次元圧縮を行う多重 (正準) 判別分析 (Multiple Discriminant Analysis: MDA) である。MDA は、得られる射影軸が入力変数の線形式で構成されるため、各変数の係数により射影軸の意味を説明することを容易にする。

このほかにも、次元圧縮を行う手法には、線形射影を行う主成分分析 (Principal Component Analysis: PCA) や独立成分分析 (Independent Component Analysis: ICA) [1]、非線形写像を行う自己組織化マップ (Self Organizing Map: SOM) [2] や多次元尺度構成法 (Multi-Dimensional Scaling: MDS) [3] などがある。しかし、PCA や ICA は陽にクラスを扱えないこと、SOM や MDS は得られる可視空間が非線形写像の結果であるため、その解釈が困難であることなどの理由により、可視化の手法としては必ずしも適さない。

判別分析はクラスが既知であるものに対して行わ

[†] 名古屋大学, 名古屋市
Nagoya University, Nagoya-shi, 464-8603 Japan

^{††} 三重大学, 津市
Mie University, Tsu-shi, 514-8507 Japan

a) E-mail: yamamoto@cplx.cse.nagoya-u.ac.jp

れるが、対象となるデータによっては、それを知ることができないものも多い。そこで、このようなデータに対しては、一般にクラスタリングを行った後、判別分析を適用する方法がとられる。末永ら [4] は k-means 法によるクラスタリングを行った後、判別分析を行うクラスタ判別法を提案し、データの可視化の観点から判別分析の有効性を他手法 [5] との比較を交えて議論している。

この手法では、一つのデータを一つのクラスタのみに所属させるクリスピーなクラスタリング法が用いられている。一方、一つのデータが複数のクラスタに所属することを許容するファジークラスタリング [6] に基づいて可視データを得る研究も進められている。

筆者ら [7] はこれまでに、三次元以下の可視モデルの同定を目的として、代表的なファジークラスタリング法である Fuzzy C-Means (FCM) [8] と多重判別分析をファジークラスタに適用させたファジー多重判別分析 (Fuzzy Multiple Discriminant Analysis: FMDA) を用いた次元圧縮法を提案してきた。また、その発展として多次元正規分布を基底関数とし、EM アルゴリズムを利用するクラスタリング [9] やカーネル関数を利用した Kernel FCM [10] を用い、可視空間でのデータ分布を考慮した判別分析による次元圧縮法を提案してきた [11]。筆者らは文献 [7], [11] において、可視空間において構築したモデルによって多次元のデータからの知識抽出が可能であることを確認している。なお、筆者らは判別式として得られる軸を、多次元の変数を統合した軸として“統合軸”と呼んでいる。以降、本論文において提案手法により得られる射影軸も統合軸と呼ぶことにする。

これらのクラスタリングと次元圧縮による可視化の手法では、クラスタの基底関数がデータ構造を表現するのに適していた場合に、解釈容易な可視データを得ることができる。しかし、一般の多次元データにおいては適切な基底関数を事前に知ることは困難である。これに対して、解析目的に応じた目的関数を最適化するようにファジークラスタリングを行う手法が報告されている。

Runkler [12] は、MDS の一つである Sammon Mapping [13] をクラスタ構造をもつデータに適用できるように拡張した Fuzzy Nonlinear Projection (FNP) を提案している。FNP ではファジークラスタリングとそれらクラスタ内のデータの位相構造を保持した次元圧縮を反復して行う。しかし、FNP は非線形

写像であること、またクラスタが重なりをもつことを許容する次元圧縮であるため、可視空間におけるデータ解析には必ずしも向いていない。

山川ら [14] は正準相関分析の相関係数を最大にする FCM を提案している。正準相関分析は様々な線形解析を一般化したものとしてとらえることができるため、この手法は興味深い。各クラスタの分散が等しいという仮定をおく FCM を基礎としていることや、本論文のように可視空間でのデータ解析を目的としてはいない。

本論文では、解釈容易な可視データを得るために、判別分析の結果をクラスタリングの基準とする可視化手法を提案する。判別分析をファジー化した FMDA を用いることにより、FCM と同様の枠組で問題を定式化できることを示す。これにより、反復最適化によって、可視空間におけるクラスタ内の分散とクラスタ間の分散の比を最大とするクラスタを自動的に決定できる。

数値実験を行い、提案手法により、判別分析を目的としたクラスタが形成可能であることを示す。また、ベンチマーク問題として有名な UCI データベースのアイメデータに提案手法を適用し、得られた結果を従来法の結果と比較することで、提案手法が適切なクラスタを生成し、また、可視化されたデータからは有用な知識が抽出可能であることを示す。また、多変数をもつワインデータについても提案手法を適用することにより有用な知識が抽出できることを示す。

以下、2. では判別分析について概説し、3. で提案手法である判別分析を基準とするファジークラスタリングの手法について説明する。4. においては実験結果を示し、提案手法の有効性について考察する。最後に 5. でまとめる。

2. 判別分析

本章では、判別分析について概説する。以降、本論文で用いる記号・変数は、すべて表 1 に従う。

2 群の判別分析の目的は、射影空間におけるクラス間散布 ($w^t S_B w$) とクラス内散布 ($w^t S_W w$) の比を最大とする判別式 w を求めることである。そのため、目的関数は

$$J(w) = \frac{w^t S_B w}{w^t S_W w} \quad (1)$$

と与えられる。

このときクラス間散布行列 S_B 、及びクラス内散布

表 1 本論文で用いる記号一覧
Table 1 Nomenclature in this paper.

i, l	クラス番号を示す添字
j, k	データ番号を示す添字
s, t	変数の番号を示す添字
a, b	判別式の番号を示す添字
t	繰り返し回数を示す添字
P	原空間の次元数
Q	可視空間の次元数
N_D	データ数
N_C	クラス数
n_i	i 番目のクラスに含まれるデータ数
C_i	i 番目のクラス
θ	終了判定基準
x_k	k 番目のデータ $(x_{k1}, x_{k2}, \dots, x_{kP})^t$
W	判別式
w_a	a 番目の判別式
S_B	クラス間散布行列
S_W	クラス内散布行列
μ_{ik}	k 番目のデータの i 番目のクラスへの所属度
m_i	i 番目のクラス中心
v	全データの平均
m	ファジーネスパラメータ
λ	ラグランジュ係数

行列 S_W は

$$S_B = (m_1 - m_2)(m_1 - m_2)^t \quad (2)$$

$$S_W = \sum_{x \in N_{D1}} (x - m_1)(x - m_1)^t + \sum_{x \in N_{D2}} (x - m_2)(x - m_2)^t \quad (3)$$

と与えられる．

式 (1) を最大化する判別式は，

$$w = S_W^{-1}(m_1 - m_2) \quad (4)$$

と得られる．

この判別分析を多クラスに拡張した多重判別分析 (Multiple Discriminant Analysis: MDA) は, N_C 個のクラスを Q ($\leq \min(N_C - 1, P - 1)$) 本の判別式で分割することを目的とする．2 群の場合と同様に, 射影空間におけるクラス内散布に対するクラス間散布の比を最大にする変換行列 W を同定する．散布の程度を表すスカラ指標は散布行列の行列式となる．そのため, MDA における目的関数は

$$J(W) = \frac{|W^t S_B W|}{|W^t S_W W|} \quad (5)$$

と与えられる．また, 多群における S_B, S_W は式 (2), (3) を拡張して

$$S_B = \sum_i^{N_C} n_i (m_i - v)(m_i - v)^t \quad (6)$$

$$S_W = \sum_i^{N_C} \sum_{x \in N_{Di}} (x - m_i)(x - m_i)^t \quad (7)$$

と表される．ここで, 式 (6), (7) 中の各クラスを中心 (m_i) 及び全データの平均ベクトル (v) は,

$$m_i = \frac{1}{n_i} \sum_{x \in N_{Di}} x_k \quad (8)$$

$$v = \frac{1}{N_D} \sum_k x_k \quad (9)$$

となる．

式 (5) を最大にする判別式 (W) を求めることは,

$$S_B w_a = \gamma_a S_W w_a \quad (10)$$

という一般化された固有値問題を解くことに等しい [3]．ここで, γ_a は固有値である．この解は特性多項式

$$|S_B - \gamma_a S_W| = 0 \quad (11)$$

により, 固有値を求め,

$$(S_B - \gamma_a S_W) w_a = 0 \quad (12)$$

を解くことで導かれる．このとき固有値は, 射影する可視空間の次元数を決定する目安として用いることができる．本論文では可視化を目的としているため, 用いることができる判別式は最大三つまでである．そのため, 大きな固有値が四つ以上存在する場合, 判別分析によって適切な可視空間が得られるとは限らない．

3. 提案手法

2. における判別分析は, クラスが既知である場合に用いることができる．しかしながら, 事前にデータのもつクラスが分からない場合や事前に設定したクラスの基底関数がデータ構造を表現するのに適していない場合もある．そこで本論文では, 判別分析の目的関数をクラスタリングの基準に用いる手法を提案する．提案手法は, クラスタリングと, 判別分析による可視空間の同定を反復して行う．この手法では, クラスは判別式が張る部分空間でのデータ分布をもとに決定される．

提案手法が有効に働くための前提条件は, 元の多次元空間における真のクラスを分けることが可能な部

して選択する．

式 (28) は、ファジークラスタリングにおける所属度の更新式によく見られる形であり、FCM の場合、 A_i が i 番目のクラスタ中心と k 番目のデータとのユークリッド距離の二乗になる．ここで式 (28) における分母の指数が 1 のとき、 k 番目のデータの所属度が各クラスタへの距離の二乗の比によって決定されることになるため、慣例としてファジネスパラメータは $m = 2$ が用いられることが多い．このため本論文の実験においても m は 2 としている． m が大きい場合、各データは複数のクラスタに所属する傾向が強くなる．

提案手法の擬似コードを以下に示す．固有値の大きな判別式を統合軸として三つまで選び、この統合軸が形成する可視空間にデータを射影することで可視データを得ることができる．

```

begin
  input data set  $x \subset \mathbb{R}^P$ 
  input  $Q \in 1, \dots, \min(P-1, N_C-1)$ 
  set stopping criterion  $\theta, t \leftarrow 0$ 
  initialize  $\mu \subset \left\{ \mu_{ik} \in [0, 1] \mid \sum_i^{N_C} \mu_{ik} = 1 \right\}$ 
  standardize  $x$ 

  compute  $W$  using (10)
  do  $t \leftarrow t + 1$ 
    for  $k = 1, \dots, N_D$  in random order
      for  $i = 1, \dots, N_C$ 
        update  $\mu_{ik}$  using (28)
      end for
    end for
    compute  $W$  using (10)
  until  $|J^{(t)} - J^{(t-1)}| < \theta$ 
end

```

4. 実験と考察

本章では、提案手法の有効性を実験的に検証した結果について述べる．

4.1 では、人工データに対して提案手法を適用し、データ構造に適したクラスタリングが形成可能であることを示す．

また、4.2 では、UCI データベースの中から分類問題であるアヤメデータとワインデータを用いて実験を行う．4.2.1 ではアヤメデータに対して提案手法とク

ラスタ判別法を適用し比較実験を行い、提案手法の有効性を示す．また、可視化されたデータから有用な知識が獲得可能であることを示す．4.2.2 では、13 個の変数をもつワインデータに対して提案手法を適用し、有用な知識抽出が可能であることを示す．

4.1 人工データによる実験

実験を行うために、図 1 及び図 2(a) に示す分布をもつ人工データを作成した．本来、提案手法は多次元のデータ解析のために用いることを前提としているが、検証を容易にするため、実験では三次元のデータを作成した．図 1 は






図 1 データ I
Fig. 1 Data I.



(a) Data distribution in the original space.



(b) Data distribution projected onto the $x_1 - x_2$ plane.

図 2 データ II
Fig. 2 Data II.

$$\begin{aligned} \text{データ I} = & \{(x, y, x^2 \cdot y^2) \mid x, y \in \{0, 0.1, \dots, 1\}\} \\ & \cup \{(x, y, 1 - (1 - x)^2 \cdot (1 - y)^2) \\ & \mid x, y \in \{0, 0.1, \dots, 1\}\} \end{aligned} \quad (29)$$

より得られ、正方形の一端をねじった形状をもつデータ群 2 組から構成されている。また、図 2 (a) は、傘状のデータ構造となるように母数を定めた六つの異なる多次元正規分布からランダムに 200 個ずつデータを発生させることにより得た。図 2 (b) は、図 2 (a) を $x_1 - x_2$ 平面上に射影したときのデータ分布である。この図からデータが六つのクラスタをもっていることが分かる。

提案手法によるクラスタリング結果を評価するために、比較として各クラスタの分散が等しいことを仮定する FCM と多次元正規分布を基底関数とする EM アルゴリズムによるクラスタリング手法の結果を併せて示す。

図 3 は、図 1 に示すデータに各手法を適用したときのクラスタリング結果を示している。この結果は各手法において、所属度等の初期値を変化させて行った 30 回の試行中、目的関数が最も大きな値をとったときの結果を示している。

いずれも事前にクラスタ数を 2 に設定した結果である。各クラスタの記号を +, ○ として、各データは所属度の高い方のクラスタの記号を用いて表してある。結果の図における軸のスケールが、入力データと異なっているのは、データを平均 0, 分散 1 に標準化しているためである。クラスタリングは、教師なし学習であるため、一概に結果の善しあしを判断できないが、EM アルゴリズムによるクラスタリングと提案手法による結果がデータ分布を発生させた関数を最も適切に反映しており、FCM とは、異なる基準でクラスタが形成されていることが分かる。

同様に図 4 は、図 2 のデータに各手法を適用したときの代表的なクラスタリング結果である。図は所属度の最も大きなクラスタの記号を用いて各データを表示してある。各図は $x_1 - x_2$ 平面に射影した結果である。このデータに対しては、提案手法と EM アルゴリズムによるクラスタリング結果がデータ分布を発生させた関数を適切に反映していることが分かる。

4.2 実データによる実験

アヤメデータとワインデータの特徴を表 2 に示す。これらのデータは、正しいクラスタがあらかじめ分かっているが、本実験ではそれらを未知として、クラ




図 3 データ I の結果

Fig. 3 Results of clustering to the Data I.

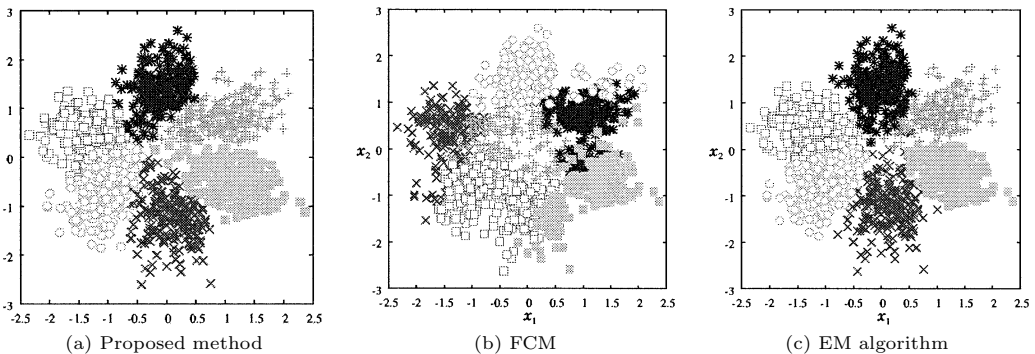


図 4 データ II のクラスタリング結果

Fig. 4 Results of clustering to the Data II.

スタリングと可視モデルの同定を行った。実験は、クラスタ数を 3、可視空間の次元数（統合軸の本数）を 2 として行った。

4.2.1 アヤメデータへの適用

表 3 に提案手法によるクラスタリング結果を示す。また同表に、可視化手法であるクラスタ判別法 [4] において用いられている k-means 法の結果と、多次元正規分布を既定関数とする EM アルゴリズムによるクラスタリング結果についても示す。実験結果は各手法とも 30 回の試行中、目的関数が最も大きな値をとったときの結果である。

表中において誤分類数は、所属度の一番大きなクラスタに当該データが所属するとしたときに、誤って他のクラスタに所属すると判定された個数を意味している。また、正答率は全データ中、正しくクラスタリングされた割合を%で示している。

表 3 より提案手法によるクラスタリングが真のクラスタを適切にとらえていることが分かる。4.1 の数値実験では、提案手法によるクラスタリングと EM アルゴリズムによるクラスタリングの結果には差が見られなかったが、このデータでは、提案手法によるクラスタリングが有効に働いている。これはアヤメデータが、線形判別が可能なデータ分布であったことに起因していると考えられる。この結果から、提案手法が多次元正規分布を規定関数とするクラスタリング手法とは異なる基準でクラスタリングを行っていることが分かる。

表 2 アヤメ/ワインデータの特徴
Table 2 Features of iris/wine data.

データ	変数	クラスタ数	データ数
アヤメ	4	3	150
ワイン	13	3	178

表 3 クラスタリング結果の比較
Table 3 Comparison of the results of clustering.

	誤分類数	正答率 (%)
k-means	22	85.3
EM-Algorithm	22	85.3
提案手法	5	96.7

表 4 提案手法における誤分類と所属度の関係
Table 4 Relationship between misclassification and degree of belonging.

	真のクラスタ	判別結果	C_1 への所属度	C_2 への所属度	C_3 への所属度
データ 1	C_1	C_2	0.37	0.60	0.03
データ 2	C_1	C_2	0.48	0.50	0.02
データ 3	C_2	C_1	0.53	0.44	0.03
データ 4	C_2	C_1	0.72	0.27	0.01
データ 5	C_2	C_1	0.53	0.43	0.04

ここで、提案手法により誤分類された五つのデータの各クラスタへの所属度を表 4 に示す。この表から、これらのデータは真のクラスタへの所属度も高いことが分かる。このように、未知のデータに対して、ファジークラスタリングでは複数のクラスタへの所属の可能性を所属度として示すことができる。

次に、図 5 にクラスタ判別法及び提案手法によって得られた可視空間にデータを射影した結果を示す。図中では、得られたクラスタを C_i で表している。提案手法では所属度最大のクラスタの記号を用いて各デー

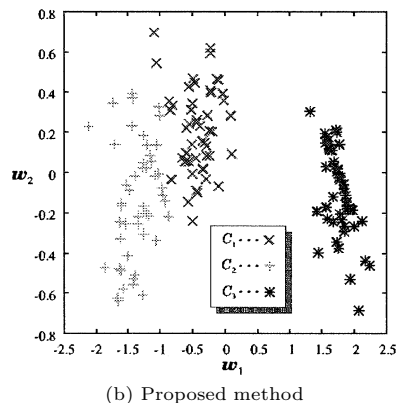



図 5 アヤメデータにおける可視化結果
Fig. 5 Visualized iris data.

表 6 ワインデータに対する統合軸
Table 6 Identified fusion axes to the wine data.

	x_1	x_2	x_3	x_4	x_5	x_6	x_7	x_8	x_9	x_{10}	x_{11}	x_{12}	x_{13}
w_1	0.07	-0.06	0.04	-0.08	-0.03	-0.27	0.75	0.04	0.05	-0.21	0.11	0.43	0.33
w_2	-0.45	-0.11	-0.35	0.41	-0.07	-0.07	0.10	0.02	0.28	-0.18	0.22	0.13	-0.52

表 5 アヤメデータに対する統合軸
Table 5 Identified fusion axes to the iris data.

	x_1	x_2	x_3	x_4
w_1	-0.13	-0.14	0.83	0.52
w_2	-0.02	0.71	-0.26	0.66




図 6 ワインデータの可視化結果
Fig. 6 Visualized wine data.

タを表してある。図 5 (b) より、アヤメデータのクラスタは統合軸 w_1 のみによって分割されていることが分かる。このとき、 w_1 と w_2 の各変数に対する係数を表 5 に示す。アヤメデータの各変数の意味は x_1 : ガクの長さ、 x_2 : ガクの幅、 x_3 : 花弁の長さ、 x_4 : 花弁の幅である。表よりクラスタを分割している w_1 には x_3 と x_4 が大きく寄与していることが分かる。そのため、 w_1 軸の意味は、“花弁の大きさ” ととらえることができる。アヤメデータが、花弁の大きさのみで判別可能であることは、文献 [15] においても述べられているが、同様の結果を統合軸による可視化という観点から明らかにしたことは、提案手法の特筆すべき点である。また、可視化されたデータから C_3 のアヤメは特に花弁が小さく、 C_1 と C_2 は似た大きさをもつという付加的な情報を得ることも可能である。

4.2.2 ワインデータへの適用

ワインデータに提案手法を適用したところ、得られたクラスタの誤分類数は 5 個であり、正答率は 97.2% であった。図 6 より、ワインデータの 3 クラスタが w_1 及び w_2 により適切に分割されていることが分かる。

w_1 は大まかに三つのクラスタを分け、 w_2 は (C_1, C_3) と C_2 を分けるのに寄与している。 w_1 と w_2 の各変数に対する係数を表 6 に示す。表より w_1 には、 x_7 と x_{12} が大きく寄与していることが分かる。これらは、それぞれ“フラボノイド”、“光学濃度”を意味している。“フラボノイド”は白ワインに比べ赤ワインに多く含まれていること、及びワインにおける色の濃さを考慮すると、 w_1 軸は赤ワインと白ワインを判別する軸であると考えられる。また、 w_2 には、 x_1 と x_{13} が負の値で大きく寄与している。これらはアルコールとブロリンの含有量を意味している。そのため C_2 は、これらの成分が少ないワインであるという知識を得ることができる。

実データを用いた実験により提案手法による可視化が、多次元データから有用な知識を得る一手法とし有効であることを示した。

5. む す び

多次元データの解析では、視覚的に解釈可能な二～三次元空間にデータを可視化することが重要である。本論文では、ファジー多重判別分析 (FMDA) の結果を基準とするクラスタリング手法と得られたクラスタの可視化手法を提案した。提案手法では、クラスタ内の分散とクラスタ間の分散の比を最大とし、FMDA による分割が容易となるクラスタを形成することができる。実験を通して提案手法が射影先におけるデータ分布の正規性に応じたクラスタリングが可能であることを示した。UCI のアヤメデータを用いて、従来法であるクラスタ判別法と提案手法の可視化結果の比較を行い、提案手法は適切なクラスタリングが可能であり、得られた可視データと及び統合軸の意味づけにより有用な知識抽出が行えることを示した。また、13 変数をもつワインデータからも提案手法により、知識抽出が可能であることを示した。今後は、射影面におけるクラスタデータ分布を考慮する拡張等を行っていきたい。

謝辞 本研究は、日本学術振興会特別研究員奨励費の援助を受けて行われた。

文 献

[1] A. Hyvärinen and E. Oja, “Independent component

- analysis: A tutorial,” *Neural Netw.*, vol.13, no.4, pp.411–430, 2000.
- [2] T. Kohonen, *Self Organizing Maps*, Springer, Heidelberg, 1995.
- [3] R.O. Duda, P.E. Hart, and D.G. Stork, *Pattern Classification — 2nd ed.*, A Wiley, 2000.
- [4] 末永高志, 佐藤 新, 坂野 鋭, “クラスタ構造に着目した特徴空間の可視化—クラスタ判別法—” *信学論 (D-II)*, vol.J85-D-II, no.5, pp.785–795, May 2002.
- [5] A. Hinneburg, D.A. Keim, and M. Wawryniuk, “HD-eye: Visual mining of high dimensional data,” *IEEE Comput. Graph. Appl.*, vol.19, no.5, pp.22–31, 1999.
- [6] 宮本定明, *クラスター分析入門*, 森北出版, 1999.
- [7] K. Yamamoto, T. Yoshikawa, and T. Furuhashi, “A proposal of fuzzy modeling on fusion axes considering the data structure,” *FUZZ-IEEE 2003*, pp.348–353, 2003.
- [8] J.C. Bezdek, *Pattern Recognition with Fuzzy Objective Function Algorithms*, Plenum, New York, 1981.
- [9] 赤穂昭太郎, “EM アルゴリズム—クラスタリングへの適用と最近の発展,” *日本ファジィ学会論文誌*, vol.12, no.5, pp.594–602, 2000.
- [10] 水津大輔, 宮本定明, “高次元空間への写像を利用したファジィc-平均法,” 第 18 回ファジィシステムシンポジウム (FSS2002), pp.123–126, 2002.
- [11] 山本康高, 古橋 武, 吉川大弘, “明示的なモデル構築のための入力空間の低次元化方法に関する研究,” 第 19 回ファジィシステムシンポジウム (FSS2003), pp.655–658, 2003.
- [12] T.A. Runkler, “Fuzzy nonlinear projection,” *FUZZ-IEEE 2003*, pp.863–868, 2003.
- [13] J.W. Sammon, “A nonlinear mapping for data structure analysis,” *IEEE Trans. Comput.*, vol.C-18, no.5, pp.401–409, 1969.
- [14] 山川あす香, 市橋秀友, 三好哲也, “正準相関係数を最大とするファジィc-Means クラスタリング法,” *日本経営工学会論文誌*, vol.51, pp.17–26, 2000.
- [15] 馬野元秀, 福中寿朗, 鳩野逸生, 田村坦之, “忘却の概念を用いたファジィ・ニューラルネットワークによるファジィルールの抽出,” *計測自動制御学会論文集*, vol.32, no.3, pp.409–416, 1996.

(平成 16 年 2 月 23 日受付, 8 月 20 日再受付)



山本 康高 (学生員)

2003 年 3 月三重大学大学院工学研究科電気電子工学専攻博士前期課程了。同年 4 月, 博士後期課程に進学, 2004 年 4 月より名古屋大学大学院工学研究科計算理工学専攻に転入学。現在に至る。ファジーモデリング及び多次元データの可視化技術に関

する研究に従事。



吉川 大弘

1997 名古屋大学大学院博士後期課程了。同年カリフォルニア大学バークレー校ソフトコンピューティング研究所客員研究員。1998 三重大学工学部電気電子工学助手。主としてソフトコンピューティングとその応用に関する研究に従事。博士(工学)。



古橋 武 (正員)

1985 名古屋大学大学院博士課程了, 1990 年 12 月より同大工学部助教授, 2001 年 1 月より三重大学情報工学科教授, 2004 年 4 月より名古屋大学大学院工学研究科教授, 現在に至る。工博。1994 日本ファジー学会論文賞受賞。主として, ソフトコンピューティングに関する研究に従事。

ティングに関する研究に従事。