ファジイ帰納学習アルゴリズムの改良

正員 櫻井 茂明, 非会員 荒木 大 (東芝)

The Improvement of Fuzzy Inductive Learning Algorithm
Shigeaki Sakurai, Member, Dai Araki, Non-member (TOSHIBA Corporation)

Inductive learning algorithms acquire knowledge from a training example set. The algorithms basically deal with discrete attributes. To deal with numerical attributes, the algorithms must have the procedure which transforms numerical values to discrete values. We proposed a fuzzy inductive learning algorithm IDF which learned a fuzzy decision tree from a training example set. IDF also has the procedure which transforms an attribute range to fuzzy ranges and can deal with numerical and fuzzy values. However, this procedure tends to decompose the attribute range for the upper attribute in the fuzzy decision tree to many fuzzy ranges. Thus we propose new procedure which composes redundant fuzzy ranges using Akaike's information criterion and improve the IDF. We made numerical experiments for some real training example sets and verified the efficiency of new IDF. We also compare new IDF with C4.5 which is a representative inductive learning algorithm and show that IDF is more efficient than C4.5 in terms of classification accuracy.

キーワード: ファジイ集合、帰納学習、赤池情報基準、C4.5 アルゴリズム

1 はじめに

問題とその解からなるデータを多数集めたデータ集合から知識を自動的に獲得する手法として、ID3⁽¹⁾、CART⁽²⁾、GID3⁽³⁾、C4.5⁽⁴⁾といった多数の帰納学習アルゴリズムが提案されている。これらのアルゴリズムは、分類クラスに対するエントロピーを基準にした属性選択を行ないながら、知識を生成していく。この属性選択手続きは、基本的には離散属性を扱うように設計されているので、数値属性を扱うには、数値属性を適切な離散属性に予め変換する必要がある。

CART、GID3、C4.5では、数値属性(A)を扱うために、しきい値(H)を決定し、 $A \leq H$ 、 $A > H$ の2値の離散属性に変換する。しかしながら、この手法では、数値属性を3つ以上の領域に分割したい場合には、各領域を再帰的に2分割しなければならない。また、再帰的な分割の際には、分割された領域にのみ着目しており、分割された領域間の関係を全く考慮していない。このため、分割された領域間に跨るような冗長な領域を生成するという問題があった。

一方、LMDT⁽⁵⁾では、数値属性を扱うために、複数の属性の組合せを考慮した線形関数を用いて、領域の分割を行なう。この手法は、単一の属性に着目した手法とは異なり、数値領域全体を考慮した分割を行なうことができる。しかしながら、属性の組合せが膨大なものとなるため、探索空間が大きくなり過ぎるという問題があった。

我々が開発したIDF⁽⁷⁾では、複数の属性の組合せは考慮しないものの、各分類クラスに対応した領域を生成する。すなわち、3種類の分類クラスが存在すれば、属性領域を3分割にする。この手法は、分類クラス数を考慮した分割を行なっているので、分類クラス数によらずに2分割を行なう手法に比べて、冗長な領域の生成を回避することが期待できる。しかしながら、この手法でも、分類クラスが属性領域内にまとまって存在していない場合には、再帰的な分割を行なう必要がある。このため、分割された領域間に跨るような冗長な領域の生成を完全には回避することはできなかった。

そこで、分類クラス数に応じた分割が終了した後で、赤池情報基準(AIC)⁽¹⁾を利用して、冗長な領域を統合することにより、分割された領域間に跨るような冗長な領域の生成を回避する。

また、提案するアルゴリズムは、従来のIDFと同様に、数値属性に含まれるノイズの影響を考慮して、滑らかな判断を行なう境界を生成する。すなわち、多くの帰納学習アルゴリズムで採用している離散的な区間の代わりに、ファジイな区間を生成する。

この論文では、数値属性及びファジイ属性に対して、ファジイな区間を生成する新たなアルゴリズムを提案し、このアルゴリズムを従来のIDFに組み込んで、IDFを改良する。また、改良したIDFと従来のIDFとの比較を行なうとともに、代表的な帰納学習アルゴリズムC4.5とも比較を行ない、改良したIDFの有効性を検証する。

図1 ファジィ決定木
Fig.1. Fuzzy decision tree.

2 ファジィ決定木

本章では、ファジィ集合理論⁽¹⁰⁾⁽¹¹⁾により表現形式を拡張した決定木(ファジィ決定木)⁽⁷⁾について説明する。

<2.1> 構成 ファジィ決定木はあいまい性を含んだ判断規則を表現できるように、従来の決定木を拡張した決定木であり、次の3点が改良されている。

- 分岐ノードにおいては、離散属性の他、数値属性やファジィ属性も割り当てられる。
- ノード同士を結ぶ枝には、属性値あるいは属性領域を分割するファジィ集合がラベル付けされる。以下においては、このファジィ集合をファジィ分岐判断項目(FCI)と呼ぶ。
- 末端ノードにおいては、確信度の付いた分類クラスが割り当てられる。

ファジィ決定木の例を図1に示す。この図において、「室温」と「湿度」がファジィ属性である。各ファジィ属性は、「寒い」、「暑い」と「低い」、「高い」と名付けたFCIを持つ。また、「電源」は離散属性であり、「ON」、「OFF」の属性値を持つ。

左下の末端ノードには (class1, 0.8), (class2, 0.2) というラベルが付いている。このラベルは class1 の確信度が0.8で、class2 の確信度が0.2であることを意味している。他の末端ノードにも同様な形式のラベルが付いている。

<2.2> 推論 ファジィ決定木を用いた推論方法は、分岐ノードにおける処理と末端ノードにおける処理から構成される。

分岐ノードにおいては、ラベル付けされている属性に対応する事例の属性値を評価し、下位のノードに事例を伝播させる。このとき、属性値が複数のFCIに跨る場合には、FCIごとの事例の確信度を計算して、複数の下位ノードに事例を伝播させる。

一方、末端ノードにおいては、到達した事例の確信度と末端ノードの分類クラスの確信度を掛け、到達した事例に対する確信度の付いた分類クラスを求める。事例が複数の末端ノードに到達する場合には、各末端ノードごとに計算した確信度の付いた分類クラスを合計して、確信度の付いた分類クラスを得る。

3 ファジィ決定木の生成

この章では、前章で説明したファジィ決定木を、事例集合から生成するIDFについて説明する。

<3.1> IDF アルゴリズム IDF は事例集合からファジィ決定木を生成するファジィ帰納学習アルゴリズムである。IDF の基本的な処理の流れは、Quinlan によって提案された ID3⁽⁵⁾ と同じである。すなわち、選択した属性を用いて、事例集合を再帰的に分割していくことにより、ファジィ決定木を成長させていく。しかしながら、数値属性やファジィ属性の扱いを可能とするために、属性選択基準の計算方法、事例集合の分割方法、決定木の成長終了判定方法を改良した。また、数値属性やファジィ属性に対して、FCI を生成する機能を新たに追加した。この FCI 生成アルゴリズムについては、新たに AIC を導入した手法を提案するので、次節で詳細に説明する。そこで、以下においては、FCI の生成方法以外の部分に関し、表 1 に示す IDF アルゴリズムを、ID3 との違いに着目して説明する。

IDF は、ステップ 3.(b) において、相互情報量を計算して、属性の選択基準とする。相互情報量を属性の選択基準とする点に関しては、ID3 と同じであるが、この相互情報量は、事例の確信度の和と FCI を利用して計算する。すなわち、(1) 式により、相互情報量を計算する。

$$gain_f(A_i, S) = I_f(S) - E_f(A_i, S) \quad (1)$$

ただし、

$$I_f(S) = - \sum_{k=1}^{n_0} p_{S,c_k} \cdot \log_2(p_{S,c_k})$$

$$p_{S,c_k} = \frac{|S_{c_k}|}{|S|}$$

$$E_f(A_i, S) = \sum_{j=1}^{n_i} p_{s,f_{ij}} \cdot I(S_{f_{ij}})$$

$$p_{s,f_{ij}} = \frac{|S_{f_{ij}}|}{|S|}$$

ここで、 n_0 は分類クラスの数、 n_i は属性 A_i ($i = 1, 2, \dots$) を表す FCI の数、 S_{c_k} は分類クラスが c_k である訓練事例の集合、 $S_{f_{ij}}$ はファジィ分岐判断項目 f_{ij} に対応する訓練事例の集合、 $|X|$ は集合 X に含まれる訓練事例の確信度の和を求める演算とする。

次に、ステップ 3.(d) において実行される事例集合の分割方法について説明する。IDF においては、属性値の代わりに FCI を用いて、事例集合を分割する。事例集合の分割方法は、FCI に関する訓練事例の帰属度の計算、帰属度による確信度の更新という二つのフェーズから構成される。

帰属度の計算フェーズは、選択した属性 A_i を表す FCI に対する訓練事例 t_k の帰属度を計算する。すなわち、ファジィ分岐判断項目 f_{ij} のメンバーシップ関数を $m_{f_{ij}}(x)$ 、属性値 v_{ik} のメンバーシップ関数を $m_{v_{ik}}(x)$ とすれば、ファジィ分岐判断項目 f_{ij} に対する訓練事例 t_k の帰属度 $grade_{ijk}$ は、(2) 式により与えられる。

$$grade_{ijk} = \max_x \{ \min(m_{f_{ij}}(x), m_{v_{ik}}(x)) \} \quad (2)$$

表 1 IDF アルゴリズム

Table 1 IDF algorithm.

1. 訓練事例をルートノードに割り当てる。
2. ノードに対して、最小占有率を越えるか最小確信度濃度を下回ったならば、ノードを末端ノードとし、確信度の付いた分類クラスをラベル付けする。
3. さもなければ、ノードを分岐ノードとする。
 - (a) 非離散属性に対して、FCI を生成する。また、離散属性に対しては、属性値を FCI として設定する。
 - (b) 各属性ごとに相互情報量を計算する。
 - (c) 相互情報量が最大となる属性を選択する。
 - (d) 選択した属性に対応する FCI に従って、ノードに割り当てられている事例をファジィ分割する。
 - (e) 各ファジィ部分集合に対して、ノードを生成し、もとのノードと生成したノードを枝で結ぶ。このとき、各枝には対応する FCI を割り当てる。
 - (f) 生成した各ノードに対して、[ステップ 2] からの処理を実行する。

帰属度による確信度の更新フェーズは、(2) 式から計算された値を正規化することにより、事例の確信度を計算する。すなわち、事例 t_k の確信度を p_k とすれば、事例のファジィ分岐判断項目 f_{ij} に関する確信度 $prob_{ijk}$ は、(3) 式により与えられる。

$$prob_{ijk} = p_k \cdot \frac{grade_{ijk}}{\sum_{l=1}^{n_i} grade_{ilk}} \quad (3)$$

従って、 $prob_{ijk}$ を確信度を持つ、事例がファジィ分岐判断項目 f_{ijk} に関する事例集合に割り当てられる。ただし、確信度の値が 0 になる事例は下位のノードに伝播させる必要がないので、事例集合から削除する。

最後に、ステップ 2. において判定するファジィ決定木の成長終了条件について説明する。ファジィ決定木の成長は、基本的には異なる分類クラスを持つ事例を分離するまで行なう。しかしながら、データには、通常ノイズが含まれているので、訓練事例を完全に分割するファジィ決定木が、新たな事例の分類クラスを正しく評価するとは限らない。このような場合、適切なところでファジィ決定木の成長を終了した方が、決定木が大きくなり過ぎるのを避けることができる。そこで、IDF においては、最小占有率、最小確信度濃度という 2 つのしきい値を導入し、ファジィ決定木が過度に成長しないようにした。最小占有率とは、同一の

分類クラスを有する事例の占有率に関するしきい値である。この占有率が最小占有率を越えた場合に、ファジィ決定木の成長を終了する。ただし、占有率は(4)式を用いて計算する。

$$occupy_s = \max_k \left\{ \frac{|S_{c_k}|}{|S|} \right\} \quad (4)$$

また、最小確信度濃度はノードに属する事例の確信度の和に関するしきい値である。確信度の和が最小確信度濃度より小さくなった場合に、ファジィ決定木の成長を終了する。

<3.2> FCIの生成 従来のFCI生成アルゴリズム⁽⁷⁾では、属性領域を細分化していけば、分類クラスの平均値の周りに同じ分類クラスを持った属性値が集まるという観点から、平均値を基準にしてFCIの生成を行なった。この方法では、細分化した領域ごとに、分類クラスの平均値を求めているので、細分化した領域間の関係を全く考慮していない。このため、細分化した領域を跨るような冗長なFCIを回避することはできなかった。そこで、分割の終了後に、隣接するFCIを統合するフェーズを新たに追加する。このとき、統合を判定する基準としては、*AIC*を利用する。この統合フェーズの追加により、冗長なFCIを排除した最適なFCIを生成する。

以下においては、表2に示すFCI生成アルゴリズムを詳細に説明する。

例えば、ある属性に対して、図2に示すように分類クラス、 c_1, c_2, c_3, c_4 が分布しているとすると、このとき、ステップ3.(a)において、 c_1, c_2, c_3, c_4 の各平均値を計算する。また、ステップ3.(b)において、この平均値を中心としたメンバーシップ関数を生成する。すなわち、一方の分類クラスしか現れない範囲においては、帰属度1を持ち、分類クラスが共存する範囲においては、隣接するメンバーシップ関数との境界を一次式を用いて決定するメンバーシップ関数を生成する。これにより、図2に示すような台形型のメンバーシップ関数が生成できる。

図2 ファジィ分岐判断項目
Fig.2. The fuzzy class items.

このメンバーシップ関数を持つFCIにより、事例集合をファジィ分割したら、ステップ2.に戻って、FCIごとに十

表2 FCI生成アルゴリズム
Table 2 Algorithm for making FCI.

1. 非離散属性に対して、属性領域を一つのFCIとみなす。
2. 全てのFCIに対して、最小占有率を越えるか最小確信度濃度ノードを下回ったならば、FCIの分割を終了し、[ステップ4]に進む。
3. さもなければ、条件を満たさないFCIを一つ選択する。
 - (a) 分類クラスごとの属性値の平均値を計算する。
 - (b) 平均値を中心を持つファジィ分岐判断を生成する。
 - (c) 生成したFCIに対して、[ステップ2]からの処理を実行する。
4. 分割フェーズが生成したモデルに対して、*AIC*の値を計算する。
5. 隣接するFCIを統合したとして、*AIC*の値を計算し、*AIC*の値が最小になるモデルを選択する。
6. 統合前のモデルの*AIC*の値が統合後のモデルの*AIC*の値より小さくなるか、統合前のモデルのFCIの数が2になったならば、統合フェーズを終了する。
7. さもなければ、選択したモデルに対応する、隣接するFCIを統合し、*AIC*の値を更新する。
8. [ステップ5]に戻る。

分な分割が行なわれているかを判定する。ここで、この判定には、最小占有率、最小確信度濃度を用いる。この判定により、分割が不十分と判定されたFCIに対しては、ステップ3.により、さらに分割を行なう。

属性領域の分割が終了したら、冗長なFCIの統合を実施する。まず、ステップ4.において、現状のモデルにおける*AIC*の値を計算する。ここで、*AIC*とはモデルの良さを測る一つの基準であり、分類クラスを識別するモデルの場合には、(5)式で与えられる。

$$AIC = -2 \sum_{i,j} n_{ij} \log_e \frac{nn_{ij}}{n_i n_j} + 2(C_0 - 1)(C - 1) \quad (5)$$

ただし、確信度の付いた事例を扱うことを考慮して、 n が事例の確信度の和、 n_{ij} が*i*番目のクラスを持ち、*j*番目のFCIに対応する事例の確信度の和、 n_i が*i*番目のクラスを持つ事例の確信度の和、 n_j が*j*番目のFCIに対応する事例の確信度の和、 C_0 が領域の分割数、 C がクラス数を表すとする。

分割終了後のモデルの*AIC*の値を計算したら、ステップ5.において、隣接するFCIを統合した場合の*AIC*を各

表3 実験データ概要
Table 3 Experimental data.

出典	データ名	事例数	属性数	分類クラス数
The liver disorders data from BUPA Medical Research Ltd.	liver-disorders	345	6(6)	2
The famous iris classification data used by R.A. Fisher (1936)	iris	150	4(4)	3
The glass types data from USA Forensic Science Service	glass	214	9(9)	7
The heart disease data from Cleveland Clinic Foundation	cleveland	303	13(6)	2

計算し、最も AIC の値が小さくなるモデルを選択する。例えば、図2のようなメンバーシップ関数を持つ FCI が生成されているとする。このとき、メンバーシップ関数 f_1, f_2 を統合したメンバーシップ関数を持つ FCI と f_3, f_4 からなるモデル、メンバーシップ関数 f_2, f_3 を統合したメンバーシップ関数を持つ FCI と f_1, f_4 からなるモデル、メンバーシップ関数 f_3, f_4 を統合したメンバーシップ関数を持つ FCI と f_1, f_2 からなるモデルの各々に対して、 AIC の値を計算する。このようにして生成したモデルの中から、 AIC の値が最も小さくなるモデルを統合候補のモデルとして選択する。ステップ6.においては、統合前のモデルの AIC の値と統合候補のモデルを比較し、統合候補のモデルの AIC の値の方が小さい場合には、FCIの統合を実施する。このFCIの統合を AIC の値が減少しなくなるか、FCI数が2になるまで繰り返す。

以上のようにして、FCI生成アルゴリズムは最適な FCI を生成する。

4 IDF の評価

改良した IDF の評価として、サンプルデータを用いて数値実験を行なった。評価対象としては、従来の IDF と C4.5 を利用した。ここで、C4.5 とは、Quinlan⁽⁶⁾ によって提案された代表的な帰納学習アルゴリズムであり、論文⁽⁷⁾で比較の対象とした ID3 を改良したアルゴリズムである。

<4.1> 実験方法 比較実験を行なうにあたり、サンプルデータとして表3に示すデータを使用した。ここで、表3において、属性数の欄の () の値は数値属性の数を表しており、cleveland 以外のサンプルデータは数値属性性だけから構成されている。

実験の方法としては、初めに、サンプルデータを一様乱数で、学習用と評価用のデータに分ける。次に、学習用のデータに学習アルゴリズムを適用して、決定木形式の判断規則を生成する。この生成した決定木を利用して、評価用のデータの分類クラスを推論し、評価用のデータに対する正解率を評価する。この数値実験を各手法ごとに20回づつ

行ない、正解率及び決定木サイズを調査した。ここで、決定木サイズとは、決定木に含まれるノードの数を表している。すなわち、図1のファジィ決定木の場合、決定木サイズは9と与えられる。

学習アルゴリズムには、外部から設定するいくつかのパラメータがある。このパラメータを変化させると、異なった決定木が得られる。そこで、パラメータによる変動を踏まえた上で、決定木の性能を比較するために、パラメータを種々変化させて、決定木の性能を評価した。すなわち、IDFにおいては、最小確信度濃度及び最小占有率を変化させ、C4.5においては、最小事例数及び枝刈り率を変化させて、決定木の性能を評価した。

今までに行なってきた IDF の性能評価を通して、最小確信度濃度の方が最小占有率よりもファジィ決定木の性能に影響するという、経験則が得られている⁽⁷⁾⁽⁸⁾。そこで、IDFにおいては、ファジィ決定木の正解率が高くなるように最小確信度濃度を調整した後で、最小占有率を調整するという方針で、ファジィ決定木の正解率が高くなるようにパラメータを調整した。一方、C4.5における、最小事例数、枝刈り率といったパラメータは、最小確信度濃度、最小占有率といったパラメータにそれぞれ対応している。そこで、決定木の正解率が高くなるように最小事例数を調整した後で、決定木の枝刈り率を調整するという方針で、C4.5のパラメータを調整した。また、IDFがあいまいな境界を作成することに対応して、C4.5においては、境界付近の値に確率を導入した境界を作成するオプションを選択した。

<4.2> 実験結果 各サンプルデータの20回の実験に対して、正解率が最も高くなった場合の実験結果を表4に示す。このとき、表4の値は20回の実験の平均値を表している。

<4.3> 実験の考察 表4の実験結果を踏まえて、学習アルゴリズムの比較を行なう。

正解率

表4から分かるように、各サンプルデータに対する新 IDF

表 4 実験結果
Table 4 Experimental results.

		liver-disorders	iris	glass	cleveland
正解率	新 IDF	69.8%	96.8%	75.1%	82.2%
	旧 IDF	67.6%	85.6%	64.6%	75.5%
	C4.5	70.0%	95.6%	68.5%	79.4%
決定木サイズ	新 IDF	34.9	5.15	35.4	30.4
	旧 IDF	49.6	24.7	81.4	57.7
	C4.5	77.0	7.50	46.0	28.7

の正解率が旧 IDF の正解率よりも高くなっている。特に、iris、glass に関しては、10% 程度も改善されており、新しく導入したファジイ分岐判断項目の生成アルゴリズムの効果が顕著に表れている。glass の場合、分類クラス数が他のサンプルデータに比べて多く、旧 IDF では一番最初に選択した属性で過度な分割が行なわれている。このため、分割された各事例集合に含まれる事例数が少なくなり、判断規則の精度が劣化したと考えられる。また、iris の場合は分類クラス数はそれほど多くないが、与えられた属性でかなり十分な分類を行なえる問題である。このため、僅かな境界の違いが大きく正解率に影響しており、分布の平均値を基本として境界を定めただけの旧 IDF の手法では、十分な正解率が得られなかったと考えられる。

一方、C4.5 と新 IDF の正解率を比較してみると liver-disorders に関しては、僅かに C4.5 の正解率が高くなるものの、他のサンプルデータに関しては、新 IDF の方が高い正解率を与えている。特に、glass に関しては、IDF の有効性が顕著に表れている。C4.5 は最適な 2 分割を行なう境界を計算して、属性領域を分割している。しかしながら、分類クラス数が多い場合には、3 分割以上にした方がよい場合が多く、2 分割を基本にした手法では、冗長な領域を生成しやすくなる。このため、分割された各事例集合に含まれる事例数が少なくなり、判断規則の精度が劣化したと考えられる。

決定木サイズ

最適な正解率を与える場合の決定木のサイズに関しては、新 IDF の決定木サイズが旧 IDF の決定木サイズに比べて小さくなっている。特に、iris に関しては、1/4 程度に決定木サイズが改善されている。iris の場合、始めに選択した属性の分割で十分な分類クラスの識別ができておらず、4 つの属性をフルに活用した決定木を生成している。これに対して、新 IDF は、始めに選択した属性でかなり十分な分類クラスの識別ができており、2 つ程度の属性からなる決定木を生成している。すなわち、冗長な分割を AIC を基準にして統合することにより、優れた境界が生成されたため、新 IDF の決定木サイズが小さくなったと考えられる。

一方、C4.5 との比較を行なってみると、cleveland の場合を除いたサンプルデータに対しては、新 IDF の決定木サ

イズの方が小さくなっている。特に、liver-disorders に関しては、1/2 程度に決定木サイズが改善されている。liver-disorders は、分類クラス数が二つしかないものの、3 分割以上に分割する必要がある属性が存在している。このため、C4.5 の場合、同じ属性を用いて複数回分割する必要がある。このとき、冗長な分割が行なわれ、決定木サイズが大きくなっている。

正解率と決定木サイズの関係

決定木サイズが大きくなると、学習用のデータの分類性能は 100% に接近していく。しかしながら、決定木サイズが大きくなったとしても、必ずしも評価用のデータの正解率は上昇しない。これは、データの中にノイズが含まれていたため、過度の分割を行なうことにより、誤ったルールを生成したためと考えられる。IDF の場合、決定木サイズは、最小確信度濃度、最小占有率といったパラメータにより制御される。今回の実験では、正解率を向上させることを目的として、論文⁽⁷⁾⁽⁸⁾の実験から得られた経験則を利用して、パラメータの調整を行なった。しかしながら、パラメータをいくつに設定すれば、決定木サイズがいくつになる、生成した決定木がどの位の精度で分類クラスを識別するといったことに関しては、明確な基準が与えられていない。今後は、このパラメータを自動的に決定できるようにする必要がある。

5 まとめと今後の課題

今回の論文では、AIC を基準にして、冗長に分割された FCI を統合することにより、最適な FCI を生成する手法を提案した。また、提案した手法を IDF に組み込むことにより、IDF の改良を行なった。さらに、旧 IDF 及び C4.5 との比較実験を行ない、正解率及び決定木サイズの観点から改良した IDF の性能を評価した。この実験により、IDF が数値属性に対して、適切な領域を生成し、正解率の高い決定木を生成することが確認できた。

今後の課題としては、数値実験における属性の数は一桁と少ないため、それほど問題となっていないが、属性数に対して計算量は指数関数的に増大していくので、大規模な問題への適用に向けて、学習の高速化方法を検討していきたい。また、前節の考察のところでも述べたが、パラメー

タと決定木サイズ及び正解率との関係が明確化されていないので、検討していきたい。

(平成 8 年 1 月 24 日受付)

文 献

- (1) H. Akaike: "A New Look at the Statical Model Identification", *IEEE Trans. Automat. Contr.*, **19**, 716~723 (1974)
- (2) L. Breiman, J.H. Friedman, R.A. Olshen, and C.J. Stone: "Classification and regression trees", *Monterey, CA: Wadsworth and Brooks* (1984)
- (3) J. Cheng, U.M. Fayyad, K.B. Irani, and Z. Qian: "Improved decision trees: A generalized version of ID3", *Proceedings of the Fifth International Conference on Machine Learning*, 100~108, (1988)
- (4) B.A. Draper, C.E. Brodley, and P.E. Utgoff: "Goal-Directed Classification using Linear Machine Decision Trees", *IEEE Trans. on Pattern Anal. Machine Intell.*, **16**, 9, 888~893, (1994)
- (5) J.R. Quinlan: "Induction of Decision Trees", *Machine Learning*, **1**, 71~99 (1985)
- (6) J.R. Quinlan: "C4.5: Programs for machine learning", *Morgan Kaufmann*, (1992)
- (7) 櫻井 茂明・荒木 大: 「帰納学習によるファジィ決定木の生成」, 電学論 C, **113**, 7, 488~494 (平 5-7)
- (8) 櫻井 茂明・荒木 大: ファジィ帰納学習アルゴリズム IDF の評価, 情報処理学会人工知能研究会, **95**, 23, 183~190 (平 7-3),
- (9) 坂本 慶行: 「カテゴリカルデータのモデル分析」, 共立出版, (昭 60)
- (10) L.A. Zadeh: "Fuzzy Sets", *Information Control*, **8**, 338~353 (1965)
- (11) L.A. Zadeh: "Fuzzy set as a basis for a theory of possibility", *Fuzzy Sets and Systems*, **1**, 1, 3~28 (1978)

荒木 大

(非会員) 1986 年大阪大学工学部通信工学科卒業。1988 年同大学大学院工学研究科博士前期課程修了。同年、(株) 東芝入社。現在、同社研究開発センター、システム・ソフトウェア生産技術研究所において、計画型エキスパートシステム、知識獲得支援技術の研究と応用システムの開発に従事。1996 年より大阪大学大学院工学研究科博士後期課程情報システム工学専攻に在学中。情報処理学会、人工知能学会、IEEE 各会員。

櫻井 茂明

(正員) 1989 年東京理科大学理学部応用数学科卒業。1991 年同大学大学院理学研究科数学専攻修士課程修了。同年、(株) 東芝入社。現在、同社システム・ソフトウェア生産技術研究所において、機械学習の研究及び開発に従事。情報処理学会、人工知能学会各会員。