

パタン認識における決定木の最適化方法とその評価†

折田 三弥彦^{††} 小林 芳樹^{††} 高藤 政雄^{††}
三島 忠明^{††} 太田 秀夫^{†††}

本論文では、パタン認識で頻りに用いられる決定木について、新しい最適化の指標を定義づけ、さらに、その指標に基づく具体的な最適化の方法と、実験による評価結果について述べている。すなわち、決定木による認識で問題にされる最大（最悪）あるいは総合（平均）の認識時間を短縮するために、(1)推定深さ、およびその総和で示される特徴量の分類性能に対する評価尺度を導入し、これを最小にする特徴量を順次、木の節に割り当てる特徴量の選択方法を提案する。さらに、(2)一つの特徴量による分類を、限界にまで容易に進めることができるクラス分け方法を提案し、(3)上記特徴量の選択方法と併用することにより、認識時間を容易に短縮できることを示した。

1. ま え が き

画像処理技術はリモートセンシング、医療等に適用され発展を続けてきたが、その応用範囲は一般産業、特に工業分野における目視検査や仕分け等の自動化を目的とした、いわゆる視覚認識の分野へも拡大されようとしている。ところが、視覚認識のアプリケーションは多種多様であることから、そのソフトウェア開発には莫大な労力を必要とするため、いまだ画像処理技術が一般産業に浸透するまでに至っていない。そこで、対象をカメラなどで教示するだけで、分類、あるいは検査が実現できるようなシステム、いわゆる学習型のパタン認識システムが開発されるようになった^{1),2)}。

このようなシステムにおける認識方法の多くは、パタンの幾何学的な特徴量の抽出、判定、分岐を繰り返す、いわゆる決定木による方法である²⁾。決定木による認識の正答率は、理論上最も良いといわれる最尤法に比べても低下は見られず³⁾、しかも最尤法で行うような加乗算の必要もないため処理速度が速いという特徴があるが、いまだ実用面で要求される認識速度を十分に満たしているとはいえない。本論文では、決定木の最適化によって、認識の所要時間の短縮を試みている。

2. パタン認識と決定木

文字や図形、あるいは機械部品を認識する際には、その都度、プログラムを開発しなければならないが、いわゆる学習型のパタン認識システムはそのような手間を省くために、認識対象を単にカメラなどで教示するだけで認識（または分類）のシーケンスを自動的に作成するようにしたものである。教示に際しては、対象の面積や周囲長、あるいは平均濃度等の特徴量を多数抽出する。これらの特徴量は一般に、視野内での対象の位置、傾き、照明の変化等によってばらつくため、対象ごとに複数回抽出し、その分布、例えば、平均値と分散値を記憶する。次に、これらのデータを用いて、対象を分類するためのシーケンスである決定木を作成するものである。

決定木に使用する特徴量の計算時間は、値の判定や分岐に要する時間に比較して非常に大きい。そのため、決定木による認識時間はほとんど特徴量の計算時間で占められている。そこで、できるだけ計算時間の短い特徴量で誤分類の少ない決定木を設計することが一般に望まれる。しかし、決定木をさらに高速化するには、特徴量の計算時間だけでなく、その分類性能も考慮した最適化が必要である。例えば、計算時間が長くても、多数の対象が分類できるような特徴量が存在すれば、そのような特徴量を優先することを考える必要がある。また、将来的には、特徴量の計算はハードウェアが進むため、計算時間のばらつきは緩和されていく。したがって、今後は特徴量の計算時間よりは、むしろ分類性能を重視した最適化が必要となってくるものと考えられる。一方、決定木による認識時間には、総合（平均）と最大（最悪）の認識時間があ

† A Method for Optimization of Decision Tree and Its Experimental Evaluation by MIYAHIKO ORITA, YOSHIKI KOBAYASHI, MASAO TAKATOO, TADAOKI MISHIMA (Hitachi Research Laboratory, Hitachi, Ltd.) and HIDEO OTA (Oomika Works, Hitachi Ltd.).

†† (株)日立製作所日立研究所

††† (株)日立製作所大みか工場

り、いずれを指標に決定木を最適化するかは応用ごとに異なる。したがって、最適化方法もそれぞれの認識時間に対応して2種類必要である。

ところで、決定木の最適化に関する研究は従来から種々行われている^{4)~8)}。文献4)および5)は、超長方体の集合として表現された特徴空間を2分岐決定木に変換する方法を提案している。これらは、計算時間や分類性能には着目しておらず、単に比較の回数だけを問題にしている。しかし、文献5)は総合のみならず最大の比較回数についても最適化を検討している。文献6)は、画像検索に用いる決定木を、特徴量の計算時間を考慮して最適化しているが、分類性能を考慮していない。なお、文献6)に文献4)や5)で用いているようなDP法を導入すれば、結果的に分類性能をも考慮した決定木を作ることができると考えられる。しかし、このような方法によると、非常に多くの決定木を作り出すので膨大な時間を要する。そのため、認識対象が頻繁に変更される製造や検査ラインには適さない。文献7)は文献6)と同様に、決定木をルート(根)から順次、作成していく方式を取っており、計算時間のほかに、分類性能の点からも最適化を試みている。しかし、総合の認識時間だけを最適化の指標にしており、また、各特徴量における分類の最適化も行っていないため、十分とは言えない。なお、文献8)は、文献4)、5)、7)などの理論展開や具体的なアルゴリズムを取りまとめたものである。

本論文では、文献7)のように、決定木をルートから順次、作成していく方式を取り、その際、特徴量の分類性能および計算時間を考慮した最適化を試みる。文献7)と異なる点は、①総合および最大の両認識時間の最適化を考えていること、および②一つの特徴量における分類に関しても最適化を考えていることである。

なお、ここでは任意の二つの対象は必ずある一つの特徴量で分類できることを前提としている。したがって、文献4)で行っているように、ある二つの対象を、多次元の特徴空間で分類するという事はしない。この前提は文献6)や7)と同様であり、実用上問題はないと考えられる。

以下、分類性能による最適化方法を示し、次に計算時間も考慮する方法を示す。

3. 決定木の最適化方法の検討

3.1 アプリケーションと認識時間

一般産業、特に工業分野で使用するパターン認識シス

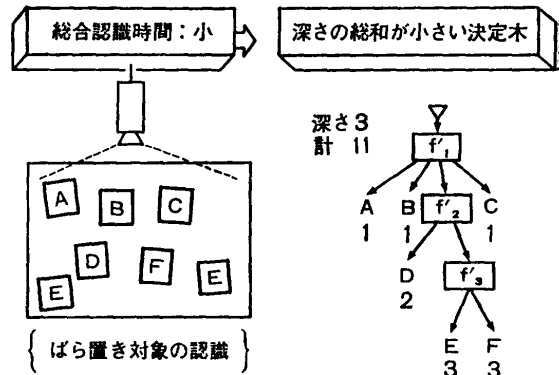


図1 総合認識時間の短縮

Fig. 1 Optimization for total recognition time.




図2 最大認識時間の短縮

Fig. 2 Optimization for maximum recognition time.

テムのアプリケーションは大きく二つのタイプに分かれると考えられる。第一のアプリケーションは、図1に示すようなばら置きされた対象を認識するものである。この場合には、対象AからFのすべてを認識するまでに要する総合の認識時間が問題になるため、各特徴量の計算時間および対象の出現頻度(または生起確率)が一様であると仮定したときの決定木としては、全対象に至るまでに抽出する特徴量の個数、すなわち全対象に対する分岐の深さの総和が最小になる決定木が適している。その決定木は例えば、図に示した決定木のように、ある特定の対象について分岐の深さが深くても、他の大多数について浅い決定木になると考えられる。

一方、第二のアプリケーションは図2に示すように、ベルトコンベア上の対象を1個ごとに認識する場合である。このような場合、対象を1個ごとに認識することから、対象AからF個々の認識時間の最大値がベルトコンベアの手速を決定することになる。したがって、決定木としては、各対象に対する分岐の深さの最大値、すなわち最大深さが最も浅い決定木が適していることになる。その決定木は例えば、図に示した決

定木のように、前述の深さの総和が大きくても、特に深い箇所がなく、一様に浅い決定木になると考えられる。

以上述べたように、上記各々のアプリケーションで必要とされる決定木は相反する性質を持つため、それぞれに適した決定木を作る必要がある。

3.2 特徴量の選択方法

深さの総和、あるいは最大深さについて、最良の決定木を得るには、考えられるだけの決定木をすべて作ってみるという方法がある。しかしそれは莫大な時間を要するため、一般の検査や仕分けのラインに導入する小型のシステムには適さない。そこで図3に示すように、深さの総和を小さくするために『推定深さの総和』、そして最大深さを浅くするために『推定深さ』という評価尺度を最小にする特徴量を順次、木の節に割り当てる特徴量の選択方法を提案する。

今、クラス {A~F} という決定木の節に対して、特徴量 {f₁~f_n} が準備されており、そのいずれか一つを割り当てるものとする。そこで、上述の評価尺度は、選択の対象となる特徴量 {f₁~f_n} で、クラス分けを仮に一度ずつ実行して得られる結果から、以後の決定木を推定することにより求められる。例えば、特徴量 f_i によるクラス分けで、新しいクラス {A, B}, {B, C, D}, {E, F} が得られたとする。そこで、これらのクラスについて決定木が最も深くなる場合、すなわち、各節では常に、ある二つの対象しか分類できないというような二分岐の決定木を仮定する。する

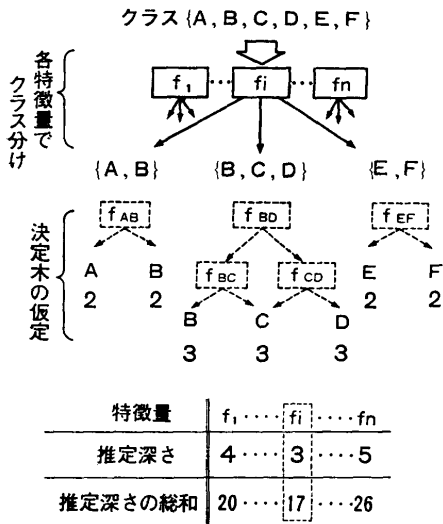


図3 特徴量選択方法

Fig. 3 Method for selecting measurable features.

と、図中点線で示すように、各クラスの対象数は、仮定上の節を通過するごとに1ずつ減少していき、結局、特徴量 f_i から数えて各クラスの対象数と等しい深さの決定木ができることになる。上記の推定深さの総和および推定深さとは、それぞれこの仮定した決定木の深さの総和および深さの最大値のことである。すなわち、特徴量 f_i の推定深さの総和 TD_i および推定深さ MD_i は次式で求められる。

$$TD_i = \sum_{j=1}^{N_i} M_{ji} \quad (1)$$

$$MD_i = \max_{1 \leq j \leq N_i} \{M_{ji}\} \quad (2)$$

ただし、

i, j: i, j=1, 2, 3...

TD_i: 特徴量 f_i の推定深さの総和

MD_i: " 推定深さ

N_i: 特徴量 f_i のクラス分けで生じた下位クラスの数

M_{ji}: 特徴量 f_i のクラス分けで生じた j 番目の下位クラスに所属する対象の数

そこで、このようにして求められる推定深さの総和を最小にする特徴量、例えば f_i (f_i に対する推定深さの総和が 17 で、f₁~f_n のうち最小であると仮定する) を、図1の第一番目の節に割り当て、新しく生じた下位のクラスについても、推定深さの総和が最小になる特徴量を選択し、以後同様に行うことにより、深さの総和が小さい決定木を容易に得ることができる。

また一方、推定深さを最小にする特徴量、例えば f_i (f_i に対する推定深さが 3 で、f₁~f_n のうち最小であると仮定する) を、図2の第一番目の節に割り当て、以後同様に行うことにより、こんどは最大深さが小さい決定木を得ることができる。

3.3 クラス分け方法

決定木の各節で、より多くの対象が分類できれば、それだけ深さの総和や最大深さは浅くなる。したがっ




図4 クラス分け方法

Fig. 4 Method for classification.

て、一つの特徴量による対象の分類、すなわちクラス分けを最適化することも決定木の最適化にとって重要である。そこで、ここでは分類を限界にまで進めるクラス分け方法を提案する。

今、図4に示すように、AからFの各認識対象の頻度分布がある特徴量について得られたとする。ここで、最適なクラス分け（あるいは分類）とは、分布が重ならない（誤分類の確率が十分小さい）二つの対象を必ず異なったクラスに所属させることであると考えられる。したがって、このようなクラス分けは、分布の重ならない二つの対象を任意に選択してクラス分けを行い、そして新しく生じた下位のクラスについても同様に繰り返すことによっても可能である。例えば、対象AとCを選択して、クラス {A, B, C, D, E, F} を {A, B, D, E, F} および {B, C, D, E, F} に分類する。そして、新しく生じたクラス {A, B, D, E, F} について、さらに対象AとDを選択して同様に分類するという操作を繰り返すことで分類を限界にまで進めることができる。しかし、この方法は膨大な木を発生させるため、取扱いが面倒な上に記憶容量も要するという問題がある。そこで、一般的には対象が存在しない箇所を捜し出してそこにしきい値を設けて分類するという方法が取られる。このような方法によると、対象DとEの間にしきい値①が設けられ、クラス {A, ..., F} が {A, ..., D} および {E, F} に分類される。なお、分布が存在する箇所でも分類するように試みるものもあるが⁶⁾、分類を限界にまで進めるものではない。そこで、本方法は、対象がいかに複雑に分布していても木を構成することなく、しかも最少本数のしきい値で分類を限界にまで進めるところに特徴がある。すなわち、しきい値①に加えて、対象AとCの間にしきい値②を設け、{A, ..., F} を、{A, B}, {B, C, D}, {E, F} に分類するものである。以下に本方法の具体的手順を示す。

今、上位のクラス {対象1, ..., 対象N} を特徴量 f_i でクラス分けする場合を考える。なお、特徴量の分布はすべて単峰性であると仮定する。

(i) 対象 $k=1, 2, \dots, N$ について以下を繰り返す。

(ii) まず、

$$\mu_{ki} > \mu_{ji} \quad (3)$$

ただし、 $j: j \neq k, j=1, 2, \dots, N$

μ_{ki}, μ_{ji} : 対象 k および対象 j の特徴量 f_i における平均値

および、

$$E(k, j, i) < e(k, j) \quad (4)$$

ただし、 $E(k, j, i)$: 対象 k と対象 j が特徴量 f_i において互いに誤認識される確率

$e(k, j)$: 対象 k と対象 j が互いに誤認識される確率の許容値

を満足するすべての対象 j を求め、さらにこれらの対象について、(4)式左辺が最大になる対象 J を求める。なお、(3), (4)式を満たす対象 j が存在しない場合は k を更新してステップ(ii)に戻る。

(iii) 次に、

$$\mu_{ji} > \mu_{ji} \quad (5)$$

ただし、 $j: j \neq J, j=1, 2, \dots, N$

および、

$$E(j, J, i) < e(j, J) \quad (6)$$

を満足するすべての対象 j を求め、さらにこれらの対象について(6)式左辺が最大になる対象 K を求める。

(iv) 最後に、 $K=k$ ならば、対象 K と対象 J の間にしきい値を設定する。一方、 $K \neq k$ ならば、 k を更新してステップ(ii)に戻る。

なお、4章で述べる試作システムでは、(4)および(6)式は簡単のためにそれぞれ次式に従っている。

$$(\mu_{ki} - 3\sigma_{ki}) - (\mu_{ji} + 3\sigma_{ji}) > 0 \quad (4)'$$

$$(\mu_{ji} - 3\sigma_{ji}) - (\mu_{Ji} + 3\sigma_{Ji}) > 0 \quad (6)'$$

ただし、 $\sigma_{ki}, \sigma_{ji}, \sigma_{Ji}$: 対象 k, j, J の特徴量 f_i における各標準偏差

また、対象 K と対象 J の間に設けるしきい値 T_{KJ} は次式で求めている。

$$T_{KJ} = \frac{\mu_{Ki} \cdot \sigma_{Ji} + \mu_{Ji} \cdot \sigma_{Ki}}{\sigma_{Ji} + \sigma_{Ki}} \quad (7)$$

4. 決定木の最適化に関する実験による評価

3章で述べた特徴量選択方法、およびクラス分け方法による決定木の最適化の効果を確認するために、学習型のパターン認識システムを試作し、決定木の自動作成に関する実験を行った。表1に今回の実験で使用した特徴量の名称と、それぞれの機能の概略を示す。

識別対象としては表2に示すように、アルファベットの大文字およびフローチャートの図形20種類を選定し、双方とも黒地に白抜きのカード状のものを使用した。なお、2分木法⁹⁾によるプログラムも作成し、本方法と比較評価した。

図5および図6に、今回提案した方法で自動作成されたアルファベット認識の決定木例を示す。なお、木

表 1 実験に使用した特徴量一覧
Table 1 Features employed for experiments.

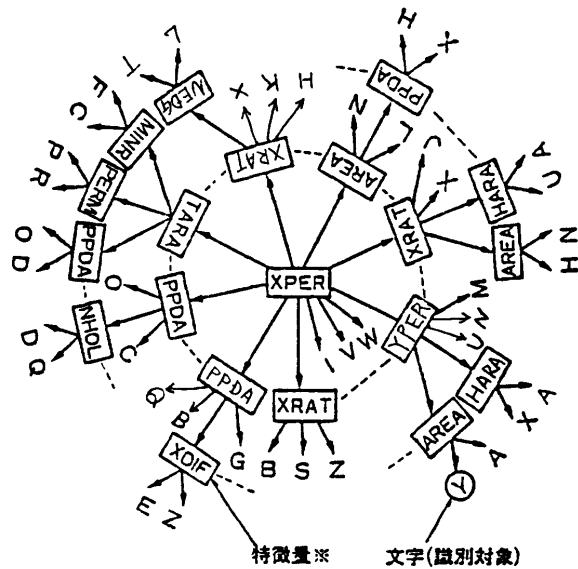
名称	内容
1	AREA 穴を含まない面積
2	TARA 穴を含む面積
3	HARA 穴の面積
4	NHOL 穴の数
5	PERM 穴を含まない周囲長
6	HPER 穴を含む周囲長
7	PPDA 形状係数 $PERM^2/TARA$
8	MAJR 主軸回りの最大モーメント
9	MINR 主軸回りの最小モーメント
10	XRAT モーメント比 $MAJR/MINR$
11	PRND 形状係数 $4\pi \times AREA/PERM^2$
12	XDIF X軸投影長さ
13	YDIF Y軸投影長さ
14	BARA $XDIF \times YDIF$
15	AREA/BARA
16	XPER X方向変化回数
17	YPER Y方向変化回数
18	NCEL 穴を含まない総画素数
19	DP 突出部分の数 (下方の突起数)
20	PM 穴を含む周囲長
21	NEDG 端点の数
22	NCRS 交点の数
23	NCNT 物体の数

表 2 実験方法
Table 2 Recognition objects for experiments.

項目	認識対象
I 文字認識	・アルファベット大文字 A~Z 26 種
II 図形認識	・フローチャート図形 △ ○ 等 20 種

の深さについてわかりやすくするために、等高線的に表記してある。また、図5は、ばら置き認識を想定した決定木、すなわち、推定深さの総和により作成されたもので、図6はベルトコンベア上の認識を想定した決定木、すなわち、推定深さにより作成されたものである。両者の決定木を比較すると、最大深さは等しいが、深さの総和は明らかに差が生じているのがわかる。すなわち、図5の例は深さのばらつきが大きく、しかも全体的に節が疎であるのに対して、図6の例では、ほとんどの対象の深さが等しく、しかも節が密であることがわかる。

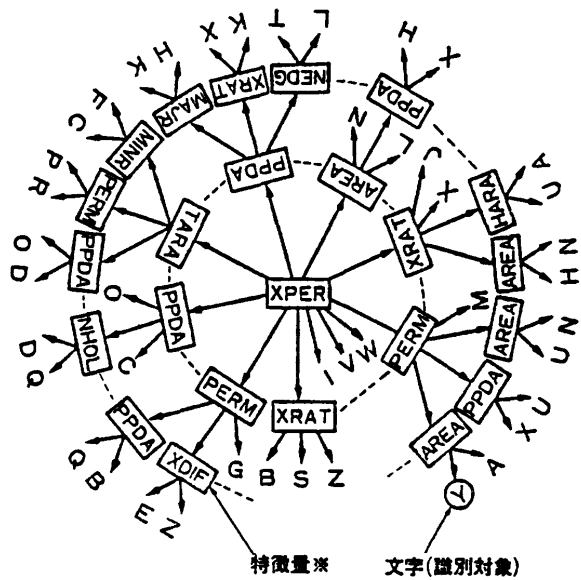
一方、表3の実験結果に示すように、今回の方法によるとアルファベットAからZのいずれを認識しても、最大でもわずか3個の特徴量しか使用しておら



※特徴量については表1を参照のこと。

図 5 推定深さの総和による決定木

Fig. 5 A decision tree optimized by presumptive total depth.



※特徴量については表1を参照のこと。

図 6 推定深さによる決定木

Fig. 6 A decision tree optimized by presumptive maximum depth.

ず、また、AからZのすべてを認識する場合においても61個、すなわち平均2.4個の特徴量で識別でき、従来に比較して約2倍の高速化が図られることが明らかとなった。また、フローチャート図形の場合も同様な結果が得られている。ところで、最尤法などのベク

表 3 実験結果
Table 3 Depth of decision tree made by experiments.

		最大深さ	深さの総和
I	文字認識	3 (7)	61 (122)
II	図形認識	3 (7)	47 (116)

注) ()内は従来方法による結果

トル演算による方法と今回の方法との比較が興味深いところであるが、ここでは具体的に検討していない。一般に、多次元空間による分類は、一次元の分類の組合せに比較して分類能力が優れると思われる。例えば、図5では12種類の特徴量で全対象を分類しているが、多次元の分類であれば、より少数種類の特徴量で分類可能と思われる。しかし、認識時間に関して本方法を上回るには、全対象を、ある2種類の特徴量で分類する必要がある。これはいかに多次元による分類が優れていても不可能と思われる。

なお、学習時に使用したサンプルを再び使用して認識実験を行ったところ、従来方法に比較して認識率の劣化は見られなかった(学習回数15および30回について行い、それぞれ正答率は両方法とも99.60%および99.90%であった)。

5. 特徴量の計算時間による重みづけ

上述した方法、および実験結果は、特徴量の計算時間および認識対象の出現の頻度がいずれも一律である場合を仮定している。しかし、現在のところ、特徴量の計算はソフトウェアに頼る面が多く、種類ごとに計算時間が大きくばらついている。例えば、表1のNo.9に示す主軸回りのモーメントは一般に、分類性能が高いが、計算時間が大きく、また、No.1に示す面積は分類性能はさほど高くないが、計算時間は非常に小さい(なお、試作したシステムでは、前者の計算時間を1とすれば、後者はその1/10である)。したがって、現状のシステムに適用する場合は、このような計算時間のばらつきをも考慮に入れて決定木を作成する必要がある。

そこで図7に示すように、上述した推定深さ、あるいは推定深さの総和に関して、特徴量の計算時間による重みづけを試みる。

まず、実際にクラス分けを実行する節については、その特徴量の計算時間を代入する。例えば、特徴量 f_i の計算時間が3であれば、その3を代入する。次に、クラス分けの結果から仮定する決定木の節について




図 7 計算時間の重みづけによる特徴量選択方法
Fig. 7 Method for selecting measurable features when the calculation time of each feature is unequal.

表 4 計算時間による重みづけの効果
Table 4 Effect made by the method for selecting features when the calculation time of each feature is unequal.

	深さ	認識時間(秒)
深さの総和	70 (63)	7 (14)
最大深さ	4 (3)	0.5 (0.7)

注) ()内は重み無し

は、どのような特徴量が適用されるかは不明であるが、 f_i 以外の特徴量であることは明らかであることから、この f_i を除いた特徴量の計算時間の平均値を代入する。例えば、他の特徴量の計算時間がすべて、6と8であれば、その平均である7を代入する。その結果、特徴量 f_i を適用したときの各認識対象に関する仮定上の認識時間がそれぞれ求まる(図中の決定木の葉、AからFの下にそれぞれ数値で示した)。そこで、これらの値を用いて、推定深さ、あるいは推定深さの総和を求め、これが最小になる特徴量を、決定木の節に順次、割り当てていけば、今度は単なる深さではなく、計算時間を考慮した決定木を作成できる。

表4に、以上述べた計算時間の重みづけによる決定木作成の実験結果を示す。なお、本実験結果の対象は表2に示したアルファベットの大文字であるが、表3

のものや教示回数や照明条件などは異なる。

本実験結果によると、深さの総和、および最大深さは、いずれも単なる深さは重みづけのない場合に比較して増加しているが、認識時間は大幅に短縮されているのがわかる。したがって、ここで提案する決定木の最適化方法は、特徴量の計算時間にばらつきのある場合にも適用できると考えられる。

6. むすび

文字や図形、あるいは機械部品の認識に頻繁に用いられる決定木について、新しい最適化の指標を定義づけ、さらに、その指標に基づく具体的な最適化の方法を提案し、実験によりその有効性を検証した。すなわち、決定木による認識で問題にされる最大あるいは総合(平均)の認識時間を短縮するために、(1)推定深さ、およびその総和で示される特徴量の分類性能に対する評価尺度を導入し、これを最小にする特徴量を順次、木の節に割り当てる特徴量の選択方法を提案した。さらに、(2)一つの特徴量による分類を、容易に限界にまで進めることができるクラス分け方法を提案し、(3)上記特徴量の選択方法と併用することにより、認識時間を容易に短縮できることを明らかにした。

参 考 文 献

- 1) Reinhold, A. G. and Vanderbrug, G.: The Autovision System, ROBOTICS AGE, Fall, pp. 22-28 (1980).
- 2) Agin, G. J. and Duda, O.: SRI Vision Research for Advanced Industrial Automation, Second USA-JAPAN Computer Conference, 5-4-1-5-4-5 (1975).
- 3) 稲村 実, 豊田弘道ほか: Binary Decision Treeによる多重分光画像の高速処理, 計測自動制御学会論文集, Vol. 15, No. 4, pp. 72-77 (1979).
- 4) Meisel, W. S. and Michalopoulos, D. A.: A Partitioning Algorithm with Application in Pattern Classification and the Optimization of Decision Trees, *IEEE Trans. Comput.*, Vol. C-22, No. 1, pp. 93-103 (1973).
- 5) Payne, H. J. and Meisel, W. S.: An Algorithm for Constructing Optimal Binary Decision Trees, *IEEE Trans. Comput.*, Vol. C-26, No. 9, pp. 905-916 (1977).
- 6) 柳原, 田村, 田中: 特徴抽出時間を考慮した最適分類木の一作成方法—例画像入力による類似画像検索への応用—, 信学論, Vol. J68-D, No. 6, pp. 1328-1335 (1985).
- 7) Swain, P. H. and Hauska, H.: The Decision Tree Classifier: Design and Potential, *IEEE Trans. Geoscience Electron.*, Vol. GE-15, No. 3, pp. 142-147 (1977).
- 8) Kanal, L. N. and Rosenfeld, A.: Progress in Pattern Recognition 2, in *Machine Intelligence and Pattern Recognition 2*, Vol. 1, Chap. 8, pp. 189-239, North-Holland, Amsterdam, New York, Oxford (1985).

(昭和61年1月13日受付)

(昭和61年10月8日採録)



折田三弥彦 (正会員)

昭和33年生。昭和57年金沢大学大学院修士(機械工学専攻)課程修了。同年(株)日立製作所に入社。以来日立研究所にて画像処理・人工知能の研究開発に従事。電子通信学会

会員。



小林 芳樹 (正会員)

昭和22年生。昭和46年京都大学工学部電気工学科卒業。同年(株)日立製作所に入社。以来日立研究所にて制御用計算機、グラフィック・ディスプレイ、画像処理の研究開発に従事。現在第10部主任研究員。電子通信学会会員。



高藤 政雄 (正会員)

昭和23年生。昭和46年信州大学工学部電気工学科卒業。昭和48年同大学院工学研究科修士課程修了(電気工学専攻)。同年(株)日立製作所に入社。以来日立研究所において計測制御システム、グラフィックディスプレイシステム、画像処理システムの研究開発に従事。現在第10部主任研究員。

**三島 忠明**

昭和 33 年生. 昭和 52 年山口県立徳山工業高等学校機械科卒業. 同年(株)日立製作所入社, 日立研究所に勤務. 現在, 画像処理技術およびその応用システムの開発に従事. 電子通信学会会員.

**太田 秀夫 (正会員)**

昭和 25 年生. 昭和 47 年東京工業大学工学部電子物理工学科卒業. 同年(株)日立製作所入社, 大みか工場勤務. 現在, 計算制御ソフト第一設計部主任技師. 交通関係の計算制御システム, 衛星画像処理システムの開発を経て, 現在, 画像処理, 画像認識システム開発取りまとめ業務に従事. 電気学会会員.