

### 実時間形状認識とロボット制御への適用

廣田, 薫 / Hirota, Kaoru / 荒井, 良徳 / 蜂巢, 史良 /  
HACHISU, Shiroh / Arai, Yoshinori

---

(出版者 / Publisher)

法政大学工学部

(雑誌名 / Journal or Publication Title)

法政大学工学部研究集報 / 法政大学工学部研究集報

(巻 / Volume)

23

(開始ページ / Start Page)

105

(終了ページ / End Page)

121

(発行年 / Year)

1987-03

(URL)

<https://doi.org/10.15002/00003964>

# 実時間形状認識とロボット制御への適用

廣田 薫\*・荒井良徳\*\*・蜂巢史良\*\*\*

## Real Time Pattern Recognition and its Application to Robot Control

Kaoru HIROTA\*, Yoshinori ARAI\*\* and Shiroh HACHISU\*\*\*

### Abstract

A robot-arm system which is able to manipulate a moving object on a belt conveyor at a various speed is built. This system consists of two parts. The first part is related to recognizing patterns in real time. In this part, a method of constructing a discriminant tree is proposed, where three newly defined measures called effectiveness, importance and applicability, are introduced. The robot-arm-system is able to recognize the shape and the size of moving patterns on a belt conveyor based on the discriminant-tree. The second part is to replace(grasp and put)a moving object based on fuzzy-inference rules with the aid of image processing technique, which has already been reported. So fuzzy recognition part is mainly reported in this paper.

The whole system is controlled by only one 16-bit-personal-computer, and works in real time. It also allows a human-like, flexible movement. The advantages of the proposed method are the reduction of processing time and the availability of low level devices, which have not been realized by other methods.

### § 1. はじめに

探索に関する研究は、人工知能研究の初期から、その中核として盛んに研究されてきた<sup>1)2)</sup>。その応用分野としては、自然言語理解、情報検索、ゲーム、専門家システム、シーンアナリシス、ロボット等、数多く見いだせる。これらの探索に関する研究では、①状態空間から探索空間を明らかにし、最適に解を導くような探索木を生成する。②探索木より最適に解にたどりつく。という2つのプロセスが重要になる。

この探索木の一種に、パターン認識における識別木(決定木)というものがある。この識別木は、ある特徴量つまり作用素により、パターンを区別していき(枝分かれ)、終端節点に個々のパターンを配置するものである。この識別木によるパターン認識は、動画像実時間認識の基礎的手法として従来より用いられてきた。しかし、その識別木の生成は、有る程度経験的に行われる場合が多かった。

識別木は1度生成されてしまえば、解を得るための探索に工夫の入る余地はなく、木に従っ

---

\*電気工学科計測制御専攻

\*\*CSK総合研究所AI商品開発部AIツール開発課

\*\*\*大学院電気工学専攻

て解が求められる。このパターン認識でいう識別木を、知識工学でいう探索木という立場で論じた研究はあまりなく、識別木より特徴量等に重点を置いたものが殆どであった<sup>34)</sup>。

ここでは、状態空間から探索空間を明らかにし、最適に解を導くような探索木を生成する、という考え方にに基づき、識別木を探索木的一种と見なして、効率良い識別木を生成するアルゴリズムを新たに提案する。また、本形状認識アルゴリズムでは、ファジィ論理を用いることにより柔軟性を、また画像処理技術により実時間での形状認識を実現した。

作用素である特徴量は数多く考えられるが、その中から機能的に必要な十分な特徴量を選び出し、それらをうまく適用して、効率の良い識別木を生成する。必要な情報は、識別したいパターンの各々に対する出現頻度と各特徴量の値、および用いた特徴量の処理時間である。

さらにここでは、大きさという定量化しにくい概念を判断させる方法について、ファジィ論理<sup>56)</sup>を採用した。

このアルゴリズムを用いた形状認識、大きさの認識を実際にも実現し、移動するマークのパターン認識に応用した実験結果も報告する。実際の実験は、ベルトコンベア上に物体およびマークを載せて移動させ、5自由度垂直多関節型ロボットアームにより、特定の物体を掴み取り特定のマーク上に置き換えるシステムに、パターン認識を併用して運用実験を行った。

移動物体を把握するアルゴリズムおよび応用例は既に筆者らが開発し、一応の成果を得た<sup>7-12)</sup>。今回は、さらに移動目標マーク上に物体を置く動作を付け足し、さらに、物体およびマークのパターン認識も試みたわけである。移動物体置換ロボットシステムは、移動目標物の速度およびハンドからの距離というあいまい情報から、ハンドの移動量をファジィ推論によって算出することにより、ロボットアームを制御している。あいまい情報の表現には、従来から用いられているmembership概念<sup>56)</sup>に、既に我々が確率集合論の拡張ファジィ表現で提案したvagueness概念も導入している<sup>13)</sup>。

## § 2. 画像処理による目標認識

本節ではITVカメラによりとらえた目標パターンを認識する方法を述べる。ここでは目標パターンの大きさと形状の2つの組合せを考え、単独でも両方でも認識可能なようにした。大きさの認識方法は、人間の場合を考慮し、実面積のみでなく、外接長方形の面積も加味して判断させた。

形状認識では、従来より動画像パターン認識の基礎手法として用いられている識別木を用いた。従来は、適当な特徴量を組み合わせて構成する識別木において、生成する際の特徴量の選択および適用順はその際の状況により経験的に決める場合が多かった。ここでは、パターンのカテゴリを決定すれば、用意した特徴量の中から処理時間と識別能力を加味して効率よい識別木を生成することのできるアルゴリズムを新たに提案する。

ただし、認識される目標パターンは、十分な大きさを持ち、適当にサンプルしても特にその基本的性質を失うことのないものとした。このことは、提案する理論上の制約ではなく、処理時間を向上するための配慮である。

### 2.1 大きさの認識

物理的な大きさは、面積に置き換えて定義可能である。しかし、人間が通常用いている大きさは、厳密な面積ではなく、もっと概念的なものである。

ここでは大きさの認識に、面積のみでなく、外接長方形(パターンに外接する長方形)の面積も見かけの大きさとして考慮にいった。実際には、その評価尺度として面積密度を用いた。

具体的には、大きさを大・中・小の3種類とし、大・小に関してFig. 1のようにファジィラベルを考える。横軸は面積であり、適当にスケールしておく。ここで面積が  $a$  以下または  $d$  以上のものならば、無条件に小さい、大きいとし、 $b$  以上  $c$  以下ならば中(普通)であるとする。面積が  $a \sim b$  間にある時は、まずそのmembership値  $\mu$  を求める。同じ面積でも、面積密度  $\alpha$  が小さいときは大きく見えるので、面積密度  $\alpha$  と比べmembership値  $\mu$  が大きければ、大きさは中、小さければ小とする。面積が  $c \sim d$  間にある時は、 $\alpha$  と比べて  $\mu$  が大きいとき大、小さいとき中とする。

つまり、membership値が1でなくて、明確に大、小と区別できない場合のしきい値に面積密度を適用したわけである。




Fig.1 Fuzzy labels of size

### 2.2 各種特徴量の検討

画像処理における特徴量は様々提案されている。以下に、ここで用いるのにおよそ適当と思われる特徴量、もしくはそれを算出するのに必要な情報について簡単に述べる。これらは、従来から用いられていた特徴量、さらに改良したもの、新たに今回提案したものである。

画像上の座標はFig. 2のように右に  $x$  軸正(0~255)、下に  $y$  軸正(0~239)とした。また背景は黒っぽく、目標は白っぽいものとし、背景と目標の識別のために、あらかじめ実験により一

定のしきい値を設定した。また、取り込んだ画像には、ある程度の雑音は許されるものとして、プログラム上で工夫した。

### (1) 外接長方形

以下の特徴量を算出する際に必要となる情報である。目標パターンの左、上、右、下端を通る垂直および平行線で囲まれた長方形を外接長方形と呼ぶ。

実際のプログラムでは、まず左端は、 $x=2n$ ライン( $n=0, \dots, 127$ )上を $y$ 軸負方向( $y=239-2m$ ( $m=0, \dots, 119$ ))に探索をし、しきい値により目標らしき画素(白っぽい)を見つけ出す。この見つかった画素が雑音でないかを確認するために、この付近の画素を調べ、有る程度の大きさをもっているならば、目標と判断し左端 $A(x_l, y_l)$ とする。もし雑音であるならば、さらに探索を進めて行く。右端 $B(x_r, y_r)$ は、 $x=255-2n$ ライン( $n=0, \dots, 127$ )上を $y$ 軸正方向( $y=2m$ ( $m=0, \dots, 119$ ))に探索して行き、同様に決定する(Fig. 2(a)参照)。次に上、下端 $C(x_u, y_u), (x_d, y_d)$ は、左右端内で同様に1画素おきに探索して行くD(Fig. 2(b)参照)。




Fig.2 Circumscribed rectangle of an observed pattern

### (2) アスペクト比

縦横比とも呼ばれる形状認識に有効な従来から用いられている特徴量で、(1)外接長方形により次式のように求められる。

$$\text{アスペクト比} = |y_u - y_d| / |x_r - x_l|$$

### (3) 周辺分布

目標パターンの座標軸への射影を求め、その強度分布の波形で示される情報。従来より用いられており、文字認識ではストローク分布とも呼ばれている。(Fig. 3参照)

- (4)  $x$  平均長さ :  $x$  最大長さ,  
 $y$  平均長さ :  $y$  最大長さ

(3)周辺分布より、 $x$ ( $y$ )方向の平均長さ $x_{\text{mean}}$ ( $y_{\text{mean}}$ )と $x$ ( $y$ )方向の最大長さ $x_{\text{max}}$ ( $y_{\text{max}}$ )の比で示す特徴量。

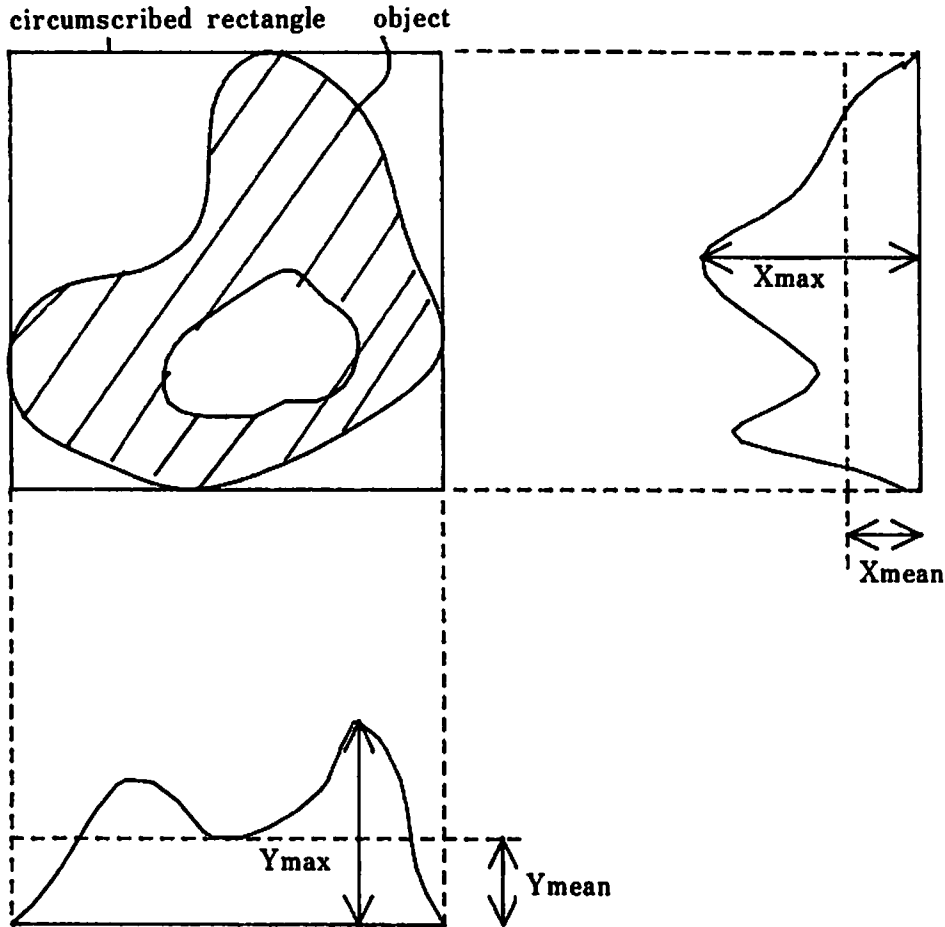


Fig.3 Marginal distribution of an observed pattern

(5) 面積(画素数)

通常は写し出された目標パターン部分の全ての画素数を計数して面積とする。大きさに関与し、形状には直接的には関与しない特徴量である。ここでは処理時間短縮のため、次のように簡略化して求める。まず、外接長方形内で適当数の画素をサンプルし、目標パターンであった割合を求める。次に外接長方形の面積( $|y_u - y_d| \times |x_r - x_l|$ )にこの割合を乗じて、面積とした。

(6) 面積密度

(5)で求めた面積と、(1)で求めた外接長方形の面積との比で示す特徴量。

(7) 重心

大きさ、形状認識に直接的には関与しない情報である。面積を求める際には目標部分の座標値を足し合わせ、足した回数で割れば求めることができる。(座標は $(x_c, y_c)$ とする。)

(8) x方向偏り, y方向偏り

(7)重心が、(1)外接長方形内でx(y)方向にどのくらい偏っているかを示す特徴量。各々、 $|x_c - x_l| / |x_r - x_l|$ ,  $|y_c - y_u| / |y_d - y_u|$ で計算される。

## (9) 周 長

写し出された目標パターンの輪郭の長さで示される情報である。ここでは、各画素を正方形と見なし、1画素の1辺を長さ1として、輪郭線を成す画素の回りの辺の数を周長とした。ただし、1画素1画素によって構成される輪郭線では無く、(5)面積でサンプルした、間引きされた画素構成の輪郭により周長を求めた。

## (10) 周 面 比

(9)周長と(5)面積の情報により、周長<sup>2</sup>/面積で示される従来より用いられている特徴量である。

## (11) x 軸周辺分布分散, y 軸周辺分布分散

(3)周辺分布において、x、y 軸各々に対しての分散で示される特徴量。

## 2.3 形状認識における特徴量の選択アルゴリズム

本節では識別したいパターンのカテゴリが示されたとき、用意した特徴量の中から、効果的な物を必要なだけ選び出すアルゴリズムを提案する。

今、識別したい $m$ 個のパターンカテゴリを $C_1, \dots, C_i, \dots, C_m$ , 用意した $n$ 個の特徴量を $F_1, \dots, F_j, \dots, F_n$ とする。さらに、各々のパターンカテゴリの出現頻度を $p_1, \dots, p_i, \dots, p_m$ , 各々の特徴量の算出(処理)時間を $t_1, \dots, t_j, \dots, t_n$ とし、これらを求めておく。ここで出現頻度 $P$ は特に確率でなくても、例えば主観確率のような $\sum p_i \neq 1$ のものでも良いとする。例えば全てのパターンが同じ出現頻度の場合、 $p_1=1/m, p_2=1/m, \dots$ ではなく、 $p_1=1, p_2=1, \dots$ でもよいわけである。これは、出現頻度を、あくまでも頻度の1つの評価尺度として考えるからである。

以上4種類の情報は、認識システムの情報を示すものである。特徴量およびその処理時間は、プログラム開発者により与えられ、システム設計者には特に直接関係するものではない。形状認識システム設計者は、現れるパターンの全てと、その各々に対する出現頻度のみを与えてやれば良い。

## 2.3-1 パターンカテゴリと特徴量

さて、これらの4種類の認識システム状態情報が準備されたら、次に、用意された各々の特徴量が個々のパターンに対してどのような値を取るかを調べる必要がある。

まず、ある特徴量 $F_j$ (この例の場合 $F_1$ )に注目し、示された全てのパターンカテゴリについて特徴量分布を求める(Fig. 4参照)。ここで、1つのカテゴリの特徴量分布(membership)の値が幅を持っているのは、見る方向による変化や誤差等を含んでいるからである。例えば、細長い物は、縦に見ると横に見るのではアスペクト比は互いに逆数関係になる。回転を許すならば、その両者間を特徴量とすれば良い。つまり、そのパターンに対して取りうる特徴量が結果として幅を持つことになる。(最大・最小の間で離れている場合も考えられる。)この特徴量分布により、特徴量 $F_j$ によって、個々のパターンが他のどのパターンと識別できるかを調べる。

### 2.3-2 判別表

例えば5個のパターン $C_1 \sim C_5$ に対する特徴量 $F_1$ の分布の例をFig. 4に示す。この特徴量分布により、特徴量 $F_1$ によって個々のパターンが他のどのパターンと判別できるかを調べる。例えばFig. 4の場合では、 $C_1$ は $C_3$ とは判別可能であるが、 $C_2$ 、 $C_4$ 、 $C_5$ とは識別不可能である事が、membership関数の重なりによって分かる。




Fig.4 An example of distribution map of Feature  $F_1$

この特徴量分布の図からTable 1のような判別表が書ける。この判別表は、注目する2つのmembership関数の交点の値を1から引いた数値で表すものとする。従って2つのmembership関数が完全に離れていれば判別可能つまり1、完全に重なっていれば判別不可能0とする。2つのカテゴリが判別可能かどうかは、それぞれのmembership関数の交差部の谷の深さによって決まる。

### 2.3-3 特徴量の効果度

例えば、判別表で同じ数値の場合でも程度があり、それも考慮することにする。つまり、重なりがなく判別可能であっても、微妙な差で重なりが無いのか、はっきりと分かれているのかで、優劣を付ける必要がある。例えば $C_2$ と $C_3$ 、 $C_2$ と $C_4$ はどちらも判別可能ではあるが、前者ははっきりと、後者は微妙な差で判別される。従って注目する2つのmembership関数の離れ具合を数値化すれば良い。Fig. 4において、全ての特徴量の幅を $a$ 、高さを1とする。つまり総面積を「 $a \times 1 = a$ 」とする。次に2つのmembership関数の谷(逆三角形もしくは逆向きの台形)の面積を $b$ とする。そして式(1)によって判別の有効尺度 $e'$ を定義する。

$$e' = b/a \tag{1}$$

判別不可能なもの(表中0)は、 $e' = 0$ と考えれば良い。このようにして式(1)により計算した結果は、Table 2のようにまとめられる。これら全ての数値を総和した $E_1$ を、注目している特徴量 $F_1$ がどの程度有効であることを示す評価関数として用いる。ここでは、この判別の有効尺度を示す評価関数 $E_1$ を新たに効果度と名付ける。



Table 1 Discriminant table of Feature F<sub>1</sub>

	C <sub>5</sub>	C <sub>4</sub>	C <sub>3</sub>	C <sub>2</sub>	C <sub>1</sub>
C <sub>1</sub>	0.2	0.29	1	0.6	
C <sub>2</sub>	0	1	1		
C <sub>3</sub>	1	0.2			
C <sub>4</sub>	0.86				
C <sub>5</sub>					

Table 2 Effectiveness of Feature F<sub>1</sub>

	C <sub>5</sub>	C <sub>4</sub>	C <sub>3</sub>	C <sub>2</sub>	C <sub>1</sub>
C <sub>1</sub>	.005	.0145	0.25	.045	
C <sub>2</sub>	0	0.25	.575		
C <sub>3</sub>	0.45	.005	e'		
C <sub>4</sub>	.129				
C <sub>5</sub>					

$E_1 = \sum e' = 1.7235$

2.3-4 重要度

次に、各特徴量がどの程度重要であるかを考える。効果度は、用いた場合の効果の程度(有効尺度)であった。しかし、例えば同程度の効果であるならば、処理時間の短い特徴量を採用した方が効率が上がる。また、各パターンの出現頻度も問題で、頻度の高いパターンを判別できる特徴量の方がより効率が上がる。

今、前述の5個のパターンC<sub>1</sub>, ..., C<sub>5</sub>の場合において、各々の出現頻度p<sub>1</sub>, ..., p<sub>5</sub>を1, 2, 3, 4, 5とする。そこで、Table 2中に示した効果度E<sub>1</sub>の各要素10個に対し、出現頻度および処理時間を考慮した重要さi'を次式により計算し、Table 3のようにまとめる。

$$i' = e' \times p \quad (2)$$

ただし、pは2つのパターンの出現頻度を加えたもので、例えば(C<sub>1</sub>, C<sub>3</sub>)パターンのi'は、

$$\begin{aligned} i'_{(1,3)} &= e'_{(1,3)} \times (p_1 + p_3) \\ &= 0.25 \times (1 + 3) \\ &= 1 \end{aligned} \quad (3)$$

と計算される。このようにして求めた全てのi'を総和したΣi'に対し、処理時間を考慮して、特徴量F<sub>1</sub>の重要さの評価尺度I<sub>1</sub>を次式により算出し、

$$I_1 = \Sigma i' / t_1 \quad (4)$$

これを特徴量F<sub>1</sub>の重要度と名付けた。

Table 3 Importance of Feature F<sub>1</sub>

		P <sub>b</sub> 5	4	3	2	1
		C <sub>5</sub>	C <sub>4</sub>	C <sub>3</sub>	C <sub>2</sub>	C <sub>1</sub>
P <sub>a</sub>						
1	C <sub>1</sub>	0.03	.0725	1.0	.135	
2	C <sub>2</sub>	0	1.5	2.875		
3	C <sub>3</sub>	3.6	.035	i'		
4	C <sub>4</sub>	1.161				
5	C <sub>5</sub>					

$\Sigma i' = 10.4075$   
 $t_1 = 1$   
 $I_1 = 10.4075$

### 2.3-5 必要最小限の特徴量集合の選択

さて、今考えなければならないのは、用意された特徴量で、与えられた全てのパターンを個別に識別できるか否かであり、もし冗長ならば必要十分な効率の良い特徴量を選択する必要がある。特徴量の効率の良さ、つまり重要さは、重要度によって順位付可能となった。そこで、この順に適用していき、必要かつ十分なものを選び出すことを考えよう。

どのパターン同士も判別可能である時、それらの特徴量の組合せは十分であるとする。そこで、各特徴量の判別表を重ね合わせていくことを考える。重ね合わせながら、大きい方の値に更新していき、最終的に全ての場所が1で埋まれば良いわけである。重ね合わせる順序は、重要度Iの順位に従っていけば良く、その途中で1つも数値を更新できなかった特徴量は必要で無いことが分かる。全てが1(あるいは1に近い数値)になるまで重ね合わせ、全て1で埋まった時点で採用されたものが、必要十分な効率良い最小限の特徴量集合である。

このようにして、新しく提案した効果度、重要度および、判別表の重ね合わせにより、あるパターンカテゴリ集合の各々を識別するのに必要十分かつ効果的な最小限の特徴量集合を選択する事ができる。効果的とは、ある特徴量により、出現頻度のより高い物をより明確に判別することを意味し、必要十分な特徴量集合とは、それらのみで全てのパターンを識別可能な最小限の特徴量集合をいう。

### 2.4 形状認識における識別木の生成アルゴリズム

本節では、前節で求めた必要十分な特徴量をうまく適用し、効率の良い識別木を生成するアルゴリズムを新たに提案する。

効率良い識別木を構成するには、出現頻度の高い物をよりよく判別し、かつ、処理時間の短い特徴量から順に適用する必要がある。すでに得られている特徴量集合は、必要十分なものであり、もはやその効果の程度を考慮に入れる必要はない。

今、前節の5つのパターンを識別するのに必要十分な特徴量が $F_1, \dots, F_j, \dots, F_k$ の $k$ 個であり、その処理時間は $t_1, \dots, t_j, \dots, t_k$ とする。さて、各特徴量がパターンをどのように分けるかを再度考えてみよう。前節では、例えば、 $C_1$ や $C_2$ 等の個々のパターンカテゴリについて考えた。ここでは、特徴量によりどのようなグループのパターンを識別ができるかを考える。つまり木がどのようにのびていく(枝分かれしていく)かを考える。

特徴量 $F_1$ による特徴量分布図(Fig. 4)に再び注目する。この図から、特徴量 $F_1$ がどのような値を取ったらどのパターンに属するかが次のように分かる。

- ①  $2a \sim 1a \rightarrow C_2 \text{ or } C_5$
- ②  $1a \sim 2b \rightarrow C_1 \text{ or } C_2 \text{ or } C_5$
- ③  $2b \sim 4a \rightarrow C_1 \text{ or } C_5$
- ④  $4a \sim 5b \rightarrow C_1 \text{ or } C_4 \text{ or } C_5$

- ⑤ 5b~1b → C<sub>1</sub> or C<sub>4</sub>
- ⑥ 1b~3a → C<sub>4</sub>
- ⑦ 3a~3b → C<sub>3</sub> or C<sub>4</sub>
- ⑧ 3b~4b → C<sub>4</sub>

つまり、測定した特徴量が①2a~1a間にあれば、そのパターンはC<sub>2</sub>かC<sub>5</sub>であることがわかる。もし識別木の根でこの特徴量F<sub>1</sub>による判断が用いられたならば、8つの枝ができるわけである (Fig. 5参照)。

次に識別木の根にどの特徴量を実際に適用するかを決定する。これを決定するにあたって、その評価尺度として新たに適応度A<sub>j</sub>を定義し、この値の高いものを採用することにする。適応度A<sub>j</sub>は、識別したいパターンカテゴリを識別する際の効率を示す尺度であり、出現頻度を考慮した識別具合、および処理時間を加味して算出される。

実際の適応度A<sub>j</sub>の計算例を、前述の例を用いて以下に示す。

まず、個々のパターンに注目した(1)~(5)において、Table 1に注目する。C<sub>1</sub>~C<sub>5</sub>の出現頻度は各々1, 2, 3, 4, 5である。そこでTable 1の各要素を、両パターンの出現頻度同士を乗じたものに判別表(Table 1)の数値つまり判別具合を乗じたものa'に変える (Table 4参照)。例えばC<sub>1</sub>とC<sub>4</sub>に注目すればその値a'<sub>1,4</sub>は

$$a'_{1,4} = (1 \times 4) \times 0.29 = 1.16$$

となる。このようにして得られた表中の数値a'の総和を処理時間t(=t<sub>1</sub>=1)で除し、これを特徴量F<sub>1</sub>に対する適応度A<sub>1</sub>と定義する。

同様に、各々全ての特徴量に対して適応度を算出する。そして、最も適応度の大きい特徴量を根に採用すれば良い。

根に採用された特徴量がF<sub>r</sub>であり(ここでは上で適応度A<sub>1</sub>の計算に用いた特徴量F<sub>1</sub>とする)、そのグループ化が、

$$C_2 \text{ or } C_5 / C_1 \text{ or } C_2 \text{ or } C_5 / C_1 \text{ or } C_5 / C_1 \text{ or } C_4 \text{ or } C_5 / C_1 \text{ or } C_4 / C_4 / C_3 \text{ or } C_4 / C_4 \quad (5)$$

であったとする。すると識別木はFig. 5のようになる。8つの枝の先の節には、終端ではないものもあり、さらに枝分かれが必要である。そこで、それらの節に対してさらに考察を進める。例えばまず左端の {C<sub>2</sub>, C<sub>5</sub>} に注目したとする。各々の特徴量に対し、C<sub>2</sub>, C<sub>5</sub>についてのみ考慮したグループ化を考え、これらに対し、同様に適応度A<sub>j</sub>を求める。このように、根以外の節

Table 4 Applicability of Feature F<sub>1</sub>

		Pb 5	4	3	2	1
Pa		C <sub>5</sub>	C <sub>4</sub>	C <sub>3</sub>	C <sub>2</sub>	C <sub>1</sub>
	1	C <sub>1</sub>	1	1.16	3	1.2
2	C <sub>2</sub>	0	8	6		
3	C <sub>3</sub>	15	2.4	a'		
4	C <sub>4</sub>	17.2		Σa' = 54.96		
5	C <sub>5</sub>			t <sub>1</sub> = 1		
				A <sub>1</sub> = 54.96		

に適用する特徴量を選ぶ場合も、同様に適応度 $A_j$ を計算してやるが、全てのパターンを識別するのではないことに注意しなければならない。つまり、適応度を計算する際に、要素 $a'$ の表を、各節毎に必要なパターンのみ注意到して作り直していく。

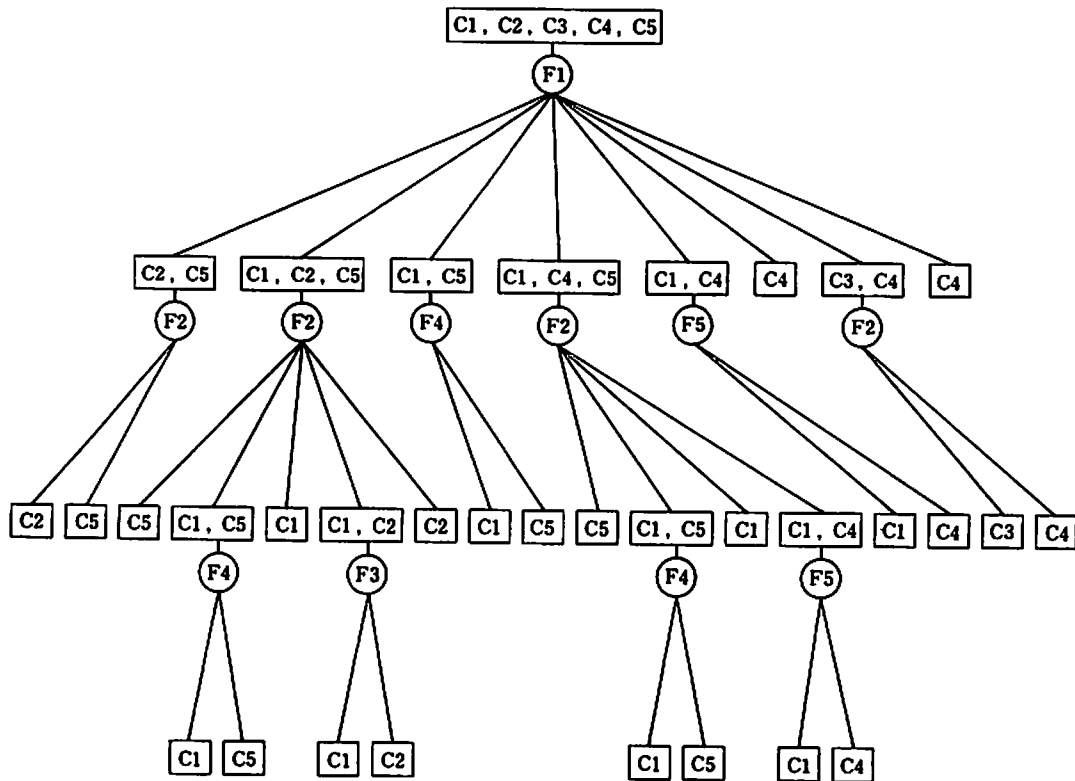


Fig.5 An example of discriminant tree

このようにして、節毎に適応度 $A_j$ を算出しながら、適切な特徴量を採用していき、全ての終端がパターン1個のみになるまで繰り返しながら識別木を生成する。生成された識別木は枝数の多い物となりうるが、かなり効率の良いものであることが期待される。

### § 3. あいまいさの取り扱い

ここでは、“目標”の速度およびハンド—目標間の距離という2つのあいまいな状況情報に対して、どこにハンドをもっていったらよいかという出力情報を推論する方法を用いた。これら2種類のあいまい状況情報のメンバーシップ関数は前もって定義し、24個の制御規則をELSEで結合した制御規則全体から求まるファジィ関係も予め計算して記憶しておく。ベグネス関数の形も予め決めておく。ファジィ関係を基にファジィ推論した予想移動量の確実さは、速度が速くて距離が遠いほど減ると考えられ、ベグネス関数の値の大小を基にハンドの移動を途中でとめ、再度ファジィ推論を行うものとした。(詳細は文献11, 12参照)

#### § 4. 移動目標の認識および物体置換ロボットシステムの運用実験とその結果

移動物体(目標マークまたは物体)の認識と移動物体設置を組み合わせたロボットシステムの運用実験結果を報告する。ベルトコンベアにより運ばれる移動物体の上からみた2次元形状を識別し、2台のロボットアームで処理する。1台のロボットアームで、指定された特定のものを掴み上げ作業台に置く。もう1台は作業台から物体を掴み取り、同じベルトコンベアで運ばれてくる移動マークパターンを識別し、指定された特定の目標マーク上に、掴んだ物体を置く。物体およびマークパターンは、予め特定のパターンを各々指定してやる。

システム構成は、5自由度の垂直多関節型ロボットアーム三菱製RM501(ムーブマスターII)2台、ITVカメラとしてSONY製CCDカメラ(XC-37)1台、256×240画素で各画素が64階調(6 bits)の分解能を持つ画像入力装置edec(株)製ED-1161(IMAGE PC)およびカメラの画像を表示する画像モニター、そしてシステム全体を制御する16bitsのパソコンNEC製PC-9800および周辺機器(キーボード、モニター、8inchフロッピーディスク装置)から成る。また物体および目標マークは、可変速産業用ミニベルトコンベア(三和コンベア(株)製)により、1方向に移動される。

実際のプログラムは、N88-日本語BASIC(86)(MS-DOS版)およびアセンブラ言語で制作した。

目標マークパターンの認識では、その処理速度の向上により、移動するマークパターンの認識も可能になる。

実際に用いた物体および目標マークのパターンの種類は、Fig. 6に示した12種類である。図中のPの値は出現頻度である。またこれらのパターンの内、1から4は物体の上から見た形状も兼ねるが、他は目標マークのみのパターンである。これらのパターンの設定方向は1方向に限定し、回転は許さないものとした。勿論カメラから目標マークまでの距離は一定である。

形状認識は、2.2節に従って行われる。特徴量は9種類を用意し、その各々の処理時間と共にTable 5に示す。各々のパターンに対する各特徴量は、大きさの違う相似系のパターン3個を10回実測し、その最小・最大間をもとにし、そのパターンの特徴量分布を設定した。

この識別木によって、ベルトコンベア上を流れる物体( $C_1 \sim C_4$ )および目標マーク( $C_1 \sim C_{12}$ )は、その大きさおよび形状共に、ほぼ確実に認識できた。

ベルトコンベアは速度が最大秒速3cm程度以下の可変速度で、物体およびマークを運ぶ。ロボットはCCDカメラを用いて必要な情報を取得し、推論計算を行い、十分に接近した時点で、物体を掴み取るか置く。十分な接近とは、移動物とハンド間の距離が小さい事を言い、その範囲は目標物の速度および、掴む時、置く時によって適切に調節される。

システムの全体図をPhoto 1に、運用実験の一例をPhoto 2に示す。この例では(1)~(3)の間が掴み取る作業で、推論したステップは2回であった。掴み取った物体は2台のロボットアーム

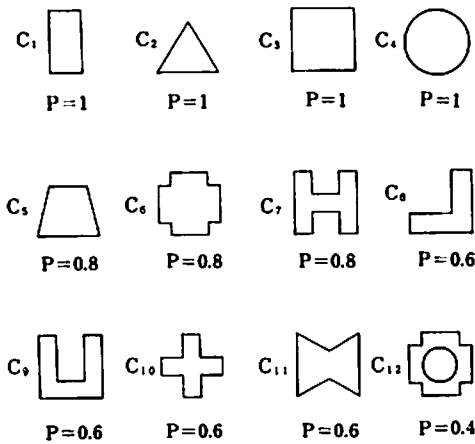


Fig.6 12 pattern categories  
(C<sub>1</sub>~C<sub>4</sub>: objects. C<sub>5</sub>~C<sub>12</sub>: marks)

Table 5 Given features and their computing time in recognition process

computing time(sec)	F <sub>1</sub> aspect ratio	F <sub>2</sub> variance of marginal distribution on x-axis	F <sub>3</sub> variance of marginal distribution on y-axis
	0.25	0.808	0.807
	F <sub>4</sub> x-mean : max length	F <sub>5</sub> y-mean : max length	F <sub>6</sub> area density
	0.778	0.60	0.59
	F <sub>7</sub> circum-area ratio	F <sub>8</sub> CG offset in x-axis direction	F <sub>9</sub> CG offset in y-axis direction
	1.04	0.59	0.59

の中央にある作業台に置く。また(4)~(7)の間が物体をマークの上に設置する作業である。ロボットは作業台から物体を掴み取り、特定のマークが流れてくるのを待ち、掴んだ物体を目標マーク上に置いた。






Photo 1 overview of the robot system


また、数値例をTable 6に示す。実際には十分接近したという範囲は、目標の速度により適度に調整されるが、この例において、物体を掴み取る、或は物体を設置する、どちらの場合においても十分接近したという範囲は、2~24mmであった。第4ステップでは、vaguenessが0.3であり、予測した地点の70%の所でハンドを移動した後に第5ステップにはいり、推論を繰り返した。第6ステップ終了時において2mm(=(154)-(152)mm)となり十分に接近し、この例では物体を掴んだわけである。




(1)



(2) step 1




(3) step 2




(4) step 3




(5)




(6)




(7)




(8)




(9) step 4




(10) step 5



(11) step 6



(12) step 7



(13)

Photo 2 an example of robot movements

追従時のロボットの移動先は、カメラが十分物体をとらえられるように(アームによって移動物が隠れないように)、予測した地点より手前(x軸負方向に60mm)に、またベルトコンベアより上方(z軸正方向45mm)に位置するように誘導した。

ベルトコンベアの速度が約3cm/秒以上になったりすると、最後まで追従され得ないこともあるが、それ以下であればパターン認識も含めほぼ確実に処理可能であった。繰り返しステップ数については、掴むまたは置く動作を3から15ステップ程度で完了した。また、カメラを移動式にし、その視野を広げることによりベルトコンベアの速度は、最大5cm/秒程度まで追従できることが既に実験により確認されている。

Table 6 An example of experimental result

step	1	2	3
hand posi	(16, 0, 498)	(435, -131, 250)	(435, -147, 145)
object posi	(495, -54, 100)	(495, -109, 100)	(495, -144, 100)
next posi	(495, -131, 100)	(495, -147, 100)	
vagueness	0	0	[grasping]

step	4	5	6	7
hand posi	(160, 0, 498)	(216, 170, 247)	(265, 218, 145)	(265, 154, 145)
mark posi	(325, 298, 100)	(325, 249, 100)	(325, 208, 100)	(325, 152, 100)
next posi	(325, 243, 100)	(325, 218, 100)	(325, 154, 100)	
vagueness	0.3	0	0	

(325, 152, 120)
(325, 152, 100)
[putting]

posi. = (X, Y, Z) mm

hand posi. : present position of hand  
 object/mark posi. : present position of object/mark based on imagery data from CCD-camera  
 next posi. : estimated next position of object/mark based on P\*  
 (calculated by fuzzy inference using L\* and V\*)

in step 1~3 and 5~7

next posi. - hand posi. in the next step = 60  
 (in order not to shade the object/mark from CCD camera)  
 hand posi. in the next step - next posi. = 45  
 (in order not to touch the belt-conveyor)



## § 5. 終わりに

可変速度のベルトコンベア上に運ばれてくる物体をカメラでとらえ、パターン認識(大きさおよび形状認識)手法により指定された物体を選出し、ファジィ制御を併用する事により物体を掴み取り、さらに、ベルトコンベア上の特定のパターン上に、掴み取った物体を同様な方法で置くシステムを構築した。

人間が通常用いている概念的な大きさや形状を認識するのに、ファジィ論理を用いた。

形状認識においては、認識したいパターンを限定する事により、数多く用意した特徴量の中から、必要十分(最小限)な効率良い物を選び出し、効率良い識別木を生成するアルゴリズムを提案し、12種類のパターンを認識する実験も行った。このアルゴリズムを用いることにより、試行錯誤で特徴量を選んだり、識別木への適応順を考えたりする必要はなくなる。またパターンに回転や組み合わせ等の柔軟性を持たせることも可能にした。生成された識別木は効率良いものとなり特徴量のプログラムにも依存するが、実時間で処理可能である。

移動物体置換では、ファジィ制御を導入することによって、扱う情報はあいまいなものでも良い。通常は処理時間やメモリが問題となる実時間画像処理においても、比較的低レベルの機器構成で処理可能にした。またアルゴリズムも人間思考型の理解しやすいものとなった。さらにvagueness概念の導入により、何回かの繰り返し動作は必要であるが、柔軟な人間思考型の動作のファジィ制御が実現できた。

今回のロボットアームシステムでは、目標物の移動速度は最大でも毎秒3cm程度に限定される。しかしロボット自体の動作範囲は狭く、また特別なハードも備わっていない比較的低レベルの計算機を用いたシュミレーション実験の速度としては、十分満足の行く結果であった。また、パターン認識部分において、識別木の枝はかなりの数になってしまうが、より厳密な識別と言う点で満足のいくものと思われる。評価関数(効果度、重要度、適応度)の算出では、他のより効率の良いものも存在する可能性があるので、識別木を知識工学で言う探索木として捕らえた議論を今後検討する価値がある。

## 参 考 文 献

- 1) Barr and Feigenbaum eds.: The handbook of artificial intelligence.
- 2) E.Rich: 人工知能, マグロウヒルブック(株), 廣田, 宮村訳.
- 3) 高野: 形状固有値をもちいた凸平面図形の一認識手法, 計測自動制御学会論文集, 16-2, p222(1980).
- 4) 高野: 複雑な図形の輪郭形状認識への一提案, 自動制御学会論文集, 19-3, p381(1981).
- 5) L.A.Zadeh: Fuzzy Sets, Inf. and Control 8, pp. 338/353(1965).
- 6) L.A.Zadeh: Outline of a New Approach to the Analysis of Complex System and Decision Process, IEEE Trans., SMC-3, pp. 28/44(1973).

- 7) K.Hirota, Y.Arai and W.Pedrycz : Robot Control Based on Membership and Vagueness, Approximate Reasoning in Expert Systems, M.M.Gupta et al. eds., North Holland, pp. 621/635(1985).
- 8) 廣田, 荒井, 池津 : 画像からのあいまい情報を用いたロボット制御, 法政大学工学部研究集報, 21, pp. 55/76 (1985).
- 9) 廣田 : あいまい制御知能ロボット, マグロウヒルブック(1985).
- 10) 廣田, 荒井 : 画像処理を用いたあいまい知能ロボット, 法政大学工学部研究集報, 22, pp. 107/118(1986).
- 11) 廣田, 荒井, 蜂巢 : ファジィ論理による移動目標認識および移動物体置換ロボットシステム, 第2回ファジィシステムシンポジウム講演論文集, pp. 15/22(1986).
- 12) K.Hirota, Y.Arai, S.Hachisu : Moving Mark Recognition and Moving Object manipulating in Fuzzy Controlled Robot, Control Theory and Advanced Technology, Mita Press(Tokyo) (invited paper), vol. 2, No. 3, pp. 399/418(1986).
- 13) K.Hirota : Extended Fuzzy Expression of Probabilistic Sets, Advances in Fuzzy Set Theory and Applications, M.M.Gupta et al. eds., North Holland, pp. 201/214(1979).