

## 2 能動的カラー画像処理システムの開発研究

### (1) 高次局所自己相関特徴を用いた濃淡画像の認識

電子部 佐藤辰雄

#### 1 はじめに

画像による認識や計測などを行う場合、その対象とする画像としてこれまでは2値画像が多く使われてきたが、最近では性能向上のため濃淡画像を使う必要が指摘されている。濃淡画像が2値画像より情報量が多いことから、より複雑な対象、より複雑な問題、より高精度な計測等への適用が期待できるからである。しかし、情報量が増える分だけ計算量や計算時間が増えてしまうので認識や計測の方法が問題となる。

画像計測やパターン認識は以前から多くの研究がなされており、また、産業分野などでは実際に適用されている例もかなりある。これらの多くは、その課題ごとの画像の特性に着目し、画像中の対象の縁どりを切り出して真円度がどうか慣性モーメントがどうかといったような、有効と思われる方法を（ヒューリスティックに）次々と適用して、決定木を構成するといった逐次的な手法をとっており、処理時間が長い、課題ごとにプログラムやアルゴリズムを開発しなおさなければならない、等々の問題があった。

この問題を解決するため大津等<sup>1</sup> [1, 2, 3, 4, 5, 6]は、高次局所自己相関と多変量解析に基づく2段階の特徴抽出方式を提案し、それを2値画像に適用して、適応学習型汎用画像計測認識システムを実現し、さまざまな画像認識や画像計測の課題について、その有効性を示した。これは、例となる画像とそれに対応する答とを示すことにより、システムがその課題に有効な特徴を適応的に学習できる、汎用性の

高い方法で、しかも並列処理であるため安価なパソコン等でも極めて高速に処理できる。また、赤穂等<sup>2</sup>はこの高次局所自己相関特徴を基に、対象の大小や回転に対して不変な特徴を構成する方法を提案し、手書き数字などの認識に応用した [7, 8]。

本研究では、この手法を濃淡画像が扱えるように拡張し、応用の例として、人の顔の識別の実験を行った。

ところで、人の顔の識別はそれ自体が一般の画像認識とは別の意味で興味のある問題であり、セキュリティなどの面で個人の識別のニーズは高く、多くの研究も行われている [9] etc.。ここでは顔画像の特性などといったこの問題に特有の性質とは一切関係なく、汎用の濃淡画像認識手法で実現したものであり、この手法がそのまま他の2値化困難な問題に適用できることはいうまでもない。

#### 2 パターン認識

パターン認識はパターン空間（複雑なパターンの集合）からカテゴリ空間（分類されたカテゴリの集合）への写像としてとらえることができ、その写像は、それぞれのカテゴリを最大限に分離するものであることが望まれる。

線形判別分析は、クラス内の分散を最小にし、クラス間の分散を最大にする線形写像を構成する多変量解析手法である。

線形判別分析に基づいて構成された線形写像を用いれば、適応性のある汎用のパターン認識システムを実現できる。

##### 2.1 線形写像と線形判別分析

$K$  クラス（カテゴリ） $\{C_k\}_{k=1}^K$  に分類される特

<sup>1</sup>電子技術総合研究所 知能情報部長

<sup>2</sup>電子技術総合研究所 情報科学部 情報数理研究室

徴ベクトル (パターン)  $x \in R^M$  があり、これを、より少ない次元数で、しかも、各クラス間の分離を最大限強調するような新しい特徴  $y \in R^N$  に写す線形写像

$$y = A'x, \quad (R^M \rightarrow R^N) \quad (1)$$

を線形判別分析に基づいて構成する。

最適な係数行列  $A$  は、固有値問題

$$\Sigma_B A = \Sigma_W A \Lambda, \quad A' \Sigma_W A = I_N \quad (2)$$

の解として求まる。ここに、 $N$  は判別空間の次元で  $N \leq \min(K-1, M)$ 、 $\Sigma_B$  および  $\Sigma_W$  はそれぞれ次式で定義されるクラス間共分散行列、クラス内共分散行列である。

$$\begin{aligned} \Sigma_B &= \sum_{k=1}^K \omega_k (\bar{x}_k - \bar{x}_T) (\bar{x}_k - \bar{x}_T)' \\ \Sigma_W &= \sum_{k=1}^K \omega_k \Sigma_k \\ \Sigma_k &= \mathbf{E}_{C_k} (x - \bar{x}_k) (x - \bar{x}_k)' \quad (k = 1, \dots, K) \\ \bar{x}_k &= \mathbf{E}_{C_k} x \quad (k = 1, \dots, K) \\ \bar{x}_T &= \mathbf{E} x \\ \omega_k &= \frac{n_k}{n} \end{aligned}$$

$\mathbf{E} C_k$  及び  $\mathbf{E}$  はそれぞれ、クラス  $C_k$  の平均、及び全平均。

$n_k$  はクラス  $C_k$  に含まれるサンプルの個数で  $n = \sum_{k=1}^K n_k$  である。

<sup>3</sup>未知パターンベクトルと各クラスの標準パターンベクトルとの距離を調べ、最も近いクラスに識別する。

<sup>4</sup>大津等は特徴抽出に要請される基本的条件として次の3点が重要とした。

- C1: 位置に関する不変性 (対象が画面内のどこにあってても結果が同じになる)
- C2: 画面に関する加法性 (画面内に複数の対象があれば、全体の特徴は個々の対象の特徴の和になる)
- C3: 学習による適応性 (例を示すことで適応的に学習できること)

## 2.2 線形判別分析に基づくパターン認識の手順

1. 学習サンプルとして与えられた特徴ベクトルを使って固有値問題を解く。
2. 固有値問題の解として得られた固有ベクトルを使って未知の計測パターンを判別空間にマッピングする。
3. 判別空間上で、何らかの識別ルールに基づいて識別する。ここでは各クラスの学習サンプルの平均ベクトルと計測パターンのベクトルとのユークリッド距離を計算し、距離最小のルール (*Minimum Distance Decision, MDD*)<sup>3</sup>で識別した。

## 3 高次局所自己相関特徴

### 3.1 高次自己相関関数と高次局所自己相関特徴

自己相関関数は並行移動に対して不変であることが知られている。その高次への拡張が高次自己相関関数である。一般に  $N$  次自己相関関数 [10] は変位ベクトル  $\{a_1, a_2, \dots, a_N\}$  に対して次のように定義される。

$$x_N(a_1, a_2, \dots, a_N) = \int f(r) f(r+a_1) \dots f(r+a_N) dr \quad (3)$$

高次自己相関関数は次数や変位のとりかたによって無数にあるが、画面に対する加法性<sup>4</sup>を満たすため局所領域に限定しなければならない。

ここでは簡単のため次数を2までとし参照点  $r$  近傍の3x3局所領域に限定する (図1)。すると変位のとり方は並行移動により同値となるパターンを除いて25種となる (図2)。




図1: 変位のとり方

各パターンに対応する特徴は、図2で参照点とその周りの1のある画素の値の積和を全画面にわたって走査することにより計算される。具体的には、次数に応じて次のように表される。

1. 0次:  


$$x_0 = \int f(r) dr \quad (4.1)$$

2. 1次:  

$$x_1(a) = \int f(r)f(r+a) dr \quad (4.2)$$

3. 2次:  

$$x_2(a_1, a_2) = \int f(r)f(r+a_1)f(r+a_2) dr \quad (4.3)$$



注) \*印は don't care である

図2：2次迄の独立なマスクパターンの例

3.2 入力画像を平均値で割って正規化した画像の高次局所自己相関特徴

画像  $f(r)$  の面積を  $s$  として次のように表される。

1. 0次:  

$$\tilde{x}_0 = 1 \quad (5.1)$$

2. 1次:  

$$\tilde{x}_1(a) = \frac{s}{x_0} x_1(a) \quad (5.2)$$

3. 2次:  

$$\tilde{x}_2(a_1, a_2) = \frac{s^2}{x_0^2} x_2(a_1, a_2) \quad (5.3)$$

(但し、 $\tilde{x}_{0-2}$  は  $s$  で正規化してある。)

ここで  $x_0, x_1, x_2$  は(4.1~4.3)式による。

3.3 入力画像と入力画像の平均値との差分画像の高次局所自己相関特徴

画像  $f(r)$  の面積を  $s$  として次のように表される。

1. 0次:  

$$\tilde{\tilde{x}}_0 = 0 \quad (6.1)$$

2. 1次:  

$$\tilde{\tilde{x}}_1(a) = \frac{x_1}{s} - \left\{ \frac{x_0}{s} \right\}^2 \quad (6.2)$$

3. 2次:  

$$\tilde{\tilde{x}}_2(a_1, a_2) = -\frac{x_2}{s} + \frac{x_0}{s} \left\{ \frac{x_1^\dagger}{s} + \frac{x_1^{\ddagger} + x_1^{\text{†††}}}{s} \right\} - 2 \left\{ \frac{x_0}{s} \right\}^3 \quad (6.3)$$

(但し、 $\tilde{\tilde{x}}_{0-2}$  は  $s$  で正規化してある。)

ここで  $x_0, x_1, x_2$  は(4.1~4.3)式による。

また{†, ††, †††}は  $x_2$  が例えば図3(a)の時、それぞれ図3のようなものである。




図3：特別な1次のパターンの例

4 画像ピラミッドと特徴スケール空間

4.1 画像の解像度

高次局所自己相関特徴などの局所の特徴を用いたパターン認識を行う場合、その認識対象によっては、解像度が細かすぎると認識にとってあまり重要でない細かな違いのみをとらえたり、逆に解像度が粗すぎると重要な特徴をぼかしてしまったりする可能性がある。つまり、認識対象ごとに最適な解像度があると考えられる。

4.2 画像ピラミッド

種々の解像度の画像データをまとめて扱う表現法として画像ピラミッドがある。

画像ピラミッドは、1枚の画像を異なる解像度で表現した画像データの集合であり、図4に示すように最初の画像を最も高い解像度とし、その中の小領域の画像から新しい画像の1画素を得るような写像を再帰的に定義していくことで構成される。

ここでは、この写像として最も簡単な2x2領域の算術平均を用いた。




図4：画像ピラミッド

この種々の解像度の画像それぞれから高次局所自己相関特徴を抽出し、全部まとめて一つの特徴として扱うことで、一種の特徴スケール空間が構成される。その中には高解像度による精細な特徴から低解像度による大まかな特徴まで含まれるため、これをパターン認識に使えばより高い性能が実現できると考えられる。

5 実験と結果

実験対象としては、2値画像ではうまくいかないとされる対象の例として人の顔を識別する問題を取り上げた。使用した顔画像の例を、図5に示す。

5.1 高次局所自己相関特徴による濃淡画像の認識

表1：各特徴ごとの認識率と判別力

特徴の種類	認識率	判別力	備考
入力画像から直接に特徴抽出	86.7%	1.57	4.1~4.3式
画像を平均値で割って正規化	96.7%	1.72	5.1~5.3式
平均値との差分画像	100%	1.95	6.1~6.3式

<sup>5</sup>判別力は次式で定義したものを使った。

$$\eta = \frac{\Delta}{tr(\tilde{\Sigma}_T^{-1}\tilde{\Sigma}_B)} = \sum_{i=1}^N \frac{\lambda_i}{\lambda_i + 1}$$

ここで $\tilde{\Sigma}_T$ ,  $\tilde{\Sigma}_B$ はそれぞれ判別空間での全共分散行列およびクラス間共分散行列、 $\lambda_i$ は固有値である。

3節に述べた特徴それぞれについて、判別分析に基づく認識実験を行った。結果は、認識率と判別力<sup>5</sup>で評価した。実験結果を表1に示す。

5.2 画像のスケールと画像ピラミッド

実験はまず解像度の影響を調べるため、入力された画像から縦横(1/2)ずつ縮小した7種類の解像度の画像を作成し、それぞれの画像から計算した高次局所自己相関特徴を使って認識の実験を行い認識率と判別力を調べた。画像ピラミッドの例を、図6に、結果を、図7に示す。

次に画像ピラミッド全体から計算した特徴を使って同じように認識率と判別力を調べた。認識率は100%で、判別力は1.917であった。

6 まとめ

簡約化された局所自己相関マスクに基づいた高次局所自己相関特徴を連続値で計算し、これを初期特徴とした濃淡画像パターン認識について研究を行った。

濃淡画像からの特徴抽出は、まづ何も操作を行っていない入力画像から高次局所自己相関特徴を求め、これを基に、正規化画像から特徴抽出した場合、および差分画像から特徴抽出した場合に相当する高次局所自己相関特徴を、画像を直接操作することなく、最初に求めた高次局所自己相関特徴を使って簡単な代数演算によって構成する方法を検討し、その性能を評価した。結果は、画像を正規化したり、平均値との差分をとるなどの操作を加えた方が、認識率、判別力ともに改善が見られた。

局所の特徴を用いてパターン認識などを行う場合での性能を最大にする最適な解像度について、ここでは画像ピラミッドを用いて特徴のスケール空間を構成しこれを調べた。その結果、認識率、判別力はスケールによって変化していて、中程度の解像度で最適と思われるピークがあった。また、画像ピラミッドから抽出した特徴全体を1つの特徴として扱えば、かなり性能が良いこともわかった。

簡単な応用の例として、人の顔の識別問題を取り上げ、ビデオ入力装置を備えたワークステーション上で画像認識システム [11] を構成した。

今後は、これらの研究を踏まえて、より実際的な




図5：顔画像の例




図6：画像ピラミッドの例




図7：スケールの違いによる認識率と判別力の変化

場面に応用するとともに、まだ改善すべき点が考えられるので(例えばカラー化など)、そちらも研究を進めていきたい。

最後に、本研究は中小企業庁の補助金により大分県地域技術起し事業の中の1テーマとして行ったものである。

本研究の機会を与えて下さった大分県・工業技術院研究交流センターの橋本所長、ならびに電子技術総合研究所の田村情報科学部長に感謝します。また、御指導頂いた大津知能情報部長と栗田主任研究官、および御討論下さった情報数理研究室の皆様感謝します。

### 参考文献

- [1] 大津、島田、森：N次自己相関マスクによる図形の特徴抽出、信学技報、PRL78-31(1978)。
- [2] 大津：パターン認識における特徴抽出に関する数理的研究、電総研研究報告、第818号(1981)。
- [3] N.Otsu and T.Kurita: A new scheme for practical, flexible and intelligent vision systems, Proc.IAPR Workshop on Computer Vision, pp. 431-435 (Tokyo, Oct. 1988)。
- [4] 大津：適応学習型汎用画像計測認識システム、映像情報、21、No. 5、pp.41-46(1989)。
- [5] 大津、栗田：並列学習型高速画像理解の一方、画像理解の高度化と高速化シンポジウム講演論文集(1989)。
- [6] 栗田、大津：高次局所自己相関特徴に基づく適応的画像計測、第4回産業における画像センシング技術シンポジウム講演論文集(1989)。
- [7] 赤穂、佐藤、関田、梅山、大津：高次自己相関関数を用いた図形の位置・大小および回転不変な特徴量の構成、電子情報通信学会春季全国大会(1991)。
- [8] 佐藤、赤穂、関田、梅山、大津：位置、大小および回転不変な特徴によるパターン認識、電子情報通信学会春季全国大会(1991)。
- [9] Matthew Turk and Alex Pentland: Eigenfaces for Recognition, Journal of Cognitive Neuroscience, (1990)。
- [10] J.A.Mclaughlin and J.Raviv: Nth-order autocorrelations in pattern recognition, Inf.and Cont. 12, pp121-142 (1968)。
- [11] T.Kurita, N.Otsu, T.Sato: A Face Recognition Method Using Higher Order Local Autocorrelation and Multivariate Analysis, 11th IAPR International Conference on Pattern Recognition, (1992, to be appeared)。