

相対的類似性の概念に基づく濃淡画像の領域分割

横矢直和 浅野哲夫 田中幸吉
(大阪大学・基礎工学部・情報工学科)

1. まえがき

パターン認識の分野の中で、近年、画像認識あるいはシーンアナリシスと呼ばれる多くの研究がなされている。与えられた画像内の物体を認識するためには物体を背景から識別する必要がある。その方法として、(1)縁の検出あるいは縁の追跡を行なうものと、(2)画像を個々の物体に対応したいくつかの領域に分割するものがある。なお、これらはデータ圧縮としての役割をも担っている。

我々は物体識別のためのアプローチとして(2)の領域分割法(領域解析法)を採用したが、この方法の特徴は画像の構造を明らかにすることにあると考えられる。領域解析法として、従来より種々の発見的な方法が提案され、最近では領域分割の段階においても認識対象に関する簡単な事前情報(セマンティックス)を利用することが考えられている^[6]。しかしながら、生のデータに直接このような事前情報を適用するのは困難であり、局所的な情報に基づく領域分割の必要性が失われた訳ではない。むしろ逆に、セマンティックス導入の基礎として、より正確でかつ一般性をもった方法の開発が要求される。

本報告で扱う領域分割法は一般に、Region Growing^[7]と呼ばれる方法の一種である。この種の方法は、まず画像を最小の構成要素に分割し、次に隣接した要素間の非類似度(又は類似度)を計算し、同一性の見い出された要素を順次統合していった、最終的に画像全体を個々の物体に対応した領域に分割しようというものである。

従来の方法では、同一性の判定の際

に、濃度や色彩等、画像の特徴関数に対して定義される非類似度をあらかじめ与えられた閾値と比較するという方法が多く用いられていた^[2]が、この方法には1つの困難な問題がある。即ちこの場合、最適な閾値は、認識対象となる画像クラス、画像状態(照明状態や写真の場合の現象状態、また画像入力装置の劣化などの影響によるコントラストの差異)、あるいは量子化レベル数などに強く依存するので、極端な場合には、入力画像が変ればその都度閾値を調節しなければならないということにもなりかねない。また、これらの閾値は経験的に定められることが多い。従って、このような閾値に基づいた領域分割法は一般性、融通性に欠けるといふ欠点をもっている。これは閾値による判定自体が絶対的な類似性の概念に基づいていることに起因していると考えられる。

以上述べた従来の手法に対して、我々の提案する手法では、相対的な類似性(環境を考慮した類似性)の概念を導入することによって閾値による判定を極力避けている。また本手法ではクラスリングの手法を積極的に利用している。特に溝口、志村^[8]によって提案されたクラスマ検出アルゴリズムは、点密度としてのポテンシャルと各点での環境を考慮して経験的な要素を排除した斬新な技法であり、人間の視覚にかなり忠実なクラスターを形成することに成功しているので、本手法においてもその基本的な思想を取り入れている。

本報告で提案する領域解析法は、(1)領域拡張部及び(2)領域統合部から成

り、それぞれ以下に述べる思想に基づいてアルゴリズムが構成されている。

(1) 領域拡張部では、領域の中心部と推測される要素を出発点として、相互に類似した近傍要素を可能な限り統合し領域を構成するという操作を画像が完全に分割されるまで繰り返し実行する。

(2) 領域統合部では、(1)で得られた分割結果に対して、隣接領域の相互類似性を濃度の平均値と標準偏差に基づく条件によって判定し、条件を満足する場合には領域間の統合を行なう。

2. 諸定義

〔定義1〕 処理段階での画像の基本構成単位を要素または点と呼び、 $V, V(i, j), (i, j)$ などの記号で表す。なお対象とする画像は量子化されたデジタル画像である。

〔定義2〕 各点の局所情報は画像関数⁽⁷⁾(又は特徴関数)で与えられる。関数値は一般に n 次元ベクトルである。例えば、白黒濃淡画像の場合には $n=1$ であり、色彩画像の場合には $n=3$ である。以下点 V における画像関数の値を $P(V)$ で表す。本報告では、実験に用いた入力画像の関係上一応白黒濃淡画像を仮定しているので、 $P(V)$ は点 V における濃淡レベルを表しているが、色彩画像への拡張は容易である。

〔定義3〕 点 $V_0 = V_0(i, j)$ に対して、次式で定義される矩形領域 $W_n(V_0)$ 又は $W_n(i, j)$ を点 V_0 を中心とする大きさ n の窓(Window)と呼ぶ。

$$W_n(i, j) = \bigcup_{\substack{\alpha, \beta = -n \\ \alpha, \beta = n}} \{ (i+\alpha, j+\beta) \}$$

この窓の面積(要素数)を $|W_n(i, j)|$ で表す。Fig. 1は大きさ1の窓 $W_1(i, j)$ を示したものである。

$(i-1, j-1)$	$(i-1, j)$	$(i-1, j+1)$
$(i, j-1)$	(i, j)	$(i, j+1)$
$(i+1, j-1)$	$(i+1, j)$	$(i+1, j+1)$

Fig. 1 窓 $W_1(i, j)$

〔定義4〕 点 (i, j) の4連結近傍 $N_4(i, j)$ 及び8連結近傍 $N_8(i, j)$ を次のように定める。

$$N_4(i, j) = \{ (i-1, j), (i+1, j), (i, j-1), (i, j+1) \}$$

$$N_8(i, j) = N_4(i, j) - \{ (i, j) \}$$

〔定義5〕 2点 V_a, V_b について $V_a \in N_4(V_b)$ 又は $V_a \in N_8(V_b)$ であるとき、それぞれ V_a は V_b に4連結又は8連結の意味で接しているという。

〔定義6〕 点集合 $R = \{ V_1, V_2, \dots \}$ について、

$$N_4(V_i) \cap R \neq \emptyset \quad \text{for } \forall V_i \in R \quad \text{又は}$$

$$N_8(V_i) \cap R \neq \emptyset \quad \text{for } \forall V_i \in R$$

という条件が成り立つとき、それぞれ点集合 R は4連結である、又は8連結であるといひ、特に4連結点集合を領域と呼ぶ。

〔定義7〕 2点 $V_a(i, j), V_b(i+d, j+\beta)$ 間の非類似度を $d(V_a, V_b)$ 又は $d((i, j), (i+d, j+\beta))$ で表す。具体的な定義は後に述べるが、 $d(V_a, V_a) = 0, d(V_a, V_b) \geq 0$ 及び $d(V_a, V_b) = d(V_b, V_a)$ を基本条件とする。

〔定義8〕 (単方向類似性) 点 V_0 の $W_n(V_0)$ 内での n -近傍⁽⁸⁾(n -neighbor) $\mathcal{N}_R(V_0)$ を次のように定める。

$$\mathcal{N}_R(V_0) = \{ V_x \mid V(V_x; V_0) \leq n, V_x \in W_n(V_0) \}$$

$$\text{但し, } V(V_x; V_0) = \{ \{ V_y \mid d(V_0, V_y) < d(V_0, V_x), V_x, V_y \in W_n(V_0) \} \}$$

である。

明らかに($n \geq 0$ のとき) $V_0 \in \mathcal{N}_R(V_0)$ であり、また $|\mathcal{N}_R(V_0)| \geq n+1$ である。即ち、点 V_0 の n -近傍 $\mathcal{N}_R(V_0)$ とは、 V_0 と V_0 を中心とする窓内の各点について V_0 との非類似度の小さい順に並べた時の $n+1$ 番目までの点の集合である。但し、 $n+1$ 番目が複数個存在する場合にはそれらすべてを含める。

ここで $V_b \in \mathcal{N}_R(V_a)$ なる関係は「 V_a から見て V_b は V_a に比較的似ている」ことを意味する。 n の値の決定については後に論じる。

[定義9] (双方向類似性) 点 v_0 の $W_n(v_0)$ 内での n -隣接点集合 (n -adjacent set) $\Omega_R^*(v_0)$ を次のように定める。

$$\Omega_R^*(v_0) = \{v_x \mid v_x \in \Omega_R(v_0), v_0 \in \Omega_R(v_x)\}$$

ここで $v_b \in \Omega_R^*(v_a)$ なる関係は「 v_a, v_b は互いに比較的似ている」ことを意味する。

基本的な概念は以上に述べた通りであるが、実際のアプローチにおいては n 点間の n -隣接性を効率よく調べるために次のように定義される $\xi_R(v)$ という量を用いている。

[定義10] 点 v_0 に対して $\xi_R(v_0)$ を次のように定める。

$$\xi_R(v_0) = \max_{v_x \in \Omega_R(v_0)} d(v_0, v_x)$$

[命題1] n 点 v_a 及び $v_b \in W_n(v_a)$ について次の関係が成り立つ。

$$v_b \in \Omega_R(v_a) \iff d(v_a, v_b) \leq \xi_R(v_a)$$

(証明略)

[命題2] n 点 v_a 及び $v_b \in W_n(v_a)$ について次の関係が成り立つ。

$$v_b \in \Omega_R^*(v_a) \iff d(v_a, v_b) \leq \min\{\xi_R(v_a), \xi_R(v_b)\}$$

(証明) 定義9と命題1より

$$v_b \in \Omega_R^*(v_a) \iff v_b \in \Omega_R(v_a), \text{ かつ } v_a \in \Omega_R(v_b)$$

$$\iff d(v_a, v_b) \leq \xi_R(v_a) \text{ かつ } d(v_b, v_a) \leq \xi_R(v_b)$$

ここで定義7の基本条件 $d(v_a, v_b) = d(v_b, v_a)$ より命題2を得る。(証明終)

[定義11] 点 v_0 の n -境界値 $\delta_R(v_0)$ を次のように定める。

$$\delta_R(v_0) = \frac{1}{|W_n(v_0)|} \sum_{v_x \in W_n(v_0)} d^*(v_0, v_x)$$

但し、 $d^*(v_0, v_x)$ は $d(v_0, v_x) \leq \min\{\xi_R(v_0), \xi_R(v_x)\}$ のとき0、それ以外のとき $d(v_0, v_x)$ を値にもつ。

この定義より、関数 d が正確に非類似性を反映したものであるならば、境界値の大小によって点の位置を推定することができる。即ち境界値が大きな点は境界付近の点、または孤立点であり、

境界値が小さな点は境界から離れた(領域内部の)点であると考えられる。

3. 相対的類似性

この章では、前章で定義した諸量を用いて、相対的類似性の概念を閾値による判定に基づく絶対的類似性の概念と比較させながら説明する。

まず、閾値による絶対的類似性に基づく手法では、 n 点 v_a, v_b (但し、 $v_b \in W_n(v_a)$) が次の条件を満すとき、これら n 点を「似ている」と判定する。

$$(\text{判定条件 I}) \quad d(v_a, v_b) \leq \theta$$

但し、 θ は適当に与えられる閾値である。この判定条件の形より、この判定方法では「 v_a が v_b に似ている」ならば「 v_b も v_a に似ている」ということになる。この意味において絶対的類似性は無向的である。

これに対して、本報告で用いている相対的類似性は定義8からも明らかのように有向的であるといえる。即ち、 $v_b \in \Omega_R(v_a)$ のとき「 v_a から見て v_b は v_a に似ている」と解釈する。そして n 点 v_a, v_b の間に双方向の類似性が成り立つときのみ、即ち

$$(\text{判定条件 II}) \quad v_b \in \Omega_R(v_a) \text{ かつ } v_a \in \Omega_R(v_b)$$

が成り立つときのみ、これら n 点を「似ている」と判定する。この判定条件を $\xi_R(\cdot)$ を用いて書き直すと次のようになる。

$$(\text{判定条件 II}^*)$$

$$d(v_a, v_b) \leq \min\{\xi_R(v_a), \xi_R(v_b)\}$$

次に環境の問題について考察しよう。従来の領域解析法(テキストャー解析を除く)においては、濃淡レベルがほぼ一様であるか、又は滑らかに変化している部分を領域と見做すという基本仮定を置き、極端な場合には、実験においてもこの基本仮定を許容し得る範囲の画像を選び、それでも処理が困難な場合には事前情報を利用することが多かった。従来の手法がこのような基

本仮定を設定せざるを得なかった理由は、閾値を定める際に環境をうまく反映させることができなかつたことにあると筆者らは推察する。これに対して本手法で用いる $\delta_k(i)$ は点 i の周囲の濃淡レベルの変化の割合に応じて値をとるように定義されているので、周囲の環境を比較的良好に反映していると考えられる。

4. 各種の問題点

4.1 窓の大きさ n の決定

窓の大きさ n の値としては、1以上の整数値が考えられる。このうち $n \geq 3$ の場合には中心点 v_0 の n -隣接点集合 $\Omega_R^*(v_0)$ が v_0 の8連結近傍の点を全く含まず、 v_0 と距離が2以上離れた点のみから構成されるというような状況が考えられる。このような状況は $v_0 \in \Omega_R^*(v_0)$ ならば v_0 と v_0 を同一領域内の点、と見做す本手法の基本的な考え方からすれば不都合な状況である。これを避けるために本報告では $n=1$ を仮定し、以後 $w_i(v)$ を単に $w(v)$ で表すことにする。

4.2 非類似度 d の具体的な定義

2点 $v_a(i, j)$ と $v_b(i+d, j+\beta)$ の非類似度 $d(v_a, v_b)$ に関係する量として、2点間の距離 $\sqrt{\alpha^2 + \beta^2}$ と濃淡レベルの差 $|P(v_a) - P(v_b)|$ とがある。

筆者らは、非類似度を表す関数は次のような性質をもつことが望ましいと考えた。

(a) n -隣接性が量子化レベル数及び画像のコントラストに依存しない。

(b) 基本的には濃淡レベルの差を優先させ、濃淡レベルの差が等しい場合には距離を考慮する。

以上の性質を有する関数として次式を採用する。


$$d(v_a, v_b) = \sqrt{\alpha^2 + \beta^2} + |P(v_a) - P(v_b)|$$

4.3 類似性の強度 n の最適値決定


n の値としては一応0から8まで考えられるが、ほぼ3~5が適当であり、

この値は量子化レベル数等に依存しない。


Fig. 2 (a), (b), (c) は人工パターンに対してそれぞれ $n=3, 4, 5$ の各場合について n -近傍を形成したものである。図において、格子点上の数字は濃淡レベルを表わしている。点 v_a から v_b への矢印は $v_b \in \Omega_R(v_a)$ という関係を表わしており、特に双方向矢印は太線で示されている。



(a) $n=3$



(b) $n=4$



(c) $n=5$

Fig. 2 人工パターンに対する n -近傍の形成例。

Fig. 2の結果だけでは n の最適値を特定することはできないが、いくつかの例について実験を行なった結果、人間の視覚に近い分割を得るためには、 $n=4$ が最適であるという結論を得ている。

4.4 雑音除去

どの程度の大きさの孤立領域を雑音と見做すべきかは微妙な問題であるが、

本方法では面積1の孤立領域を雑音と見做して適当な処理を施している。従って、後に述べる領域拡張アルゴリズムの適用結果には面積1の領域は含まれない。Fig.2(b)はこのような孤立領域を含んでいないが、実際の画像データについて領域拡張を行なうと、多数の孤立微小領域が生じ、それが後続する処理の能率を低下させる原因となる。

5. 領域拡張プロセス

以下に述べる領域拡張アルゴリズムは、基本的には左隣接してあれば同一の領域に入っていると見做すという考え方に基づいている。しかしながらこの方法では、本来2つに分かれるべき領域がどこか一か所だけ左隣接の関係で結合されているために一つの領域に統合されてしまうという危険性がある。これは、環境を考慮しているとは言うものの、 3×3 というかなり小さな枠の中の点しか考慮に入れていないからである。そこで、以下に述べるアルゴリズムにおいては、より広い環境を考慮したのと近似的に等価であると考えられる技法を導入している。先にも述べたように4連結である点の集合のみを領域として認めるという立場をとっているのだ。その点についても十分な配慮をしている。

まず、アルゴリズムの中で用いている変数について説明しておく。

1. NR : 領域の名前(番号)を表す変数である。また NR の最終値は形成された領域の個数を表している。ステップ $R18$ で $NR := NR - 1$ としているのはそのためである。
2. $S(V)$: 点 V が属する領域の名前を表している。属する領域が決定されていない場合には値0をもち、決定された次第、領域名として自然数を値にもつ。
3. $STACKA$: このスタックは既に領域 NR に属すると決定された点に左

隣接しており、まだどの領域に属するかが決定されていない点(領域拡張の候補点)を蓄えるためのものである。

4. $STACKB$: このスタックは、一連の判定条件により領域 NR に加えることを棄却された点を蓄えるためのものである。このスタックに蓄えられた点は後でもう一度だけ条件が試される。そのために、候補点 V がどちらのスタックから取り出されたかを示すために変数 $STATE$ を用いている。

5. $NPT(NR)$: 領域 NR に属する点の個数(面積)を示す。

次に領域拡張アルゴリズムを示す。

[領域拡張アルゴリズム]

- $R1$: (初期設定) N の値を定める。画像内の各点 V について $S_R(V), \delta_R(V)$ を計算する。各点 V について $S(V) := 0$ とする。 $NR := 1$ 。
- $R2$: $STACKA := \emptyset$ (空スタック)。 $STACKB := \emptyset$ 。 $NPT(NR) := 0$ 。
- $R3$: $S(V_0) = 0$ かつ $\delta_R(V_0) = \min \{ \delta_R(V) \mid S(V) = 0 \}$ である点 V_0 を領域 NR の拡張出発点に選ぶ。 $S(V_0) := NR$ 。 $NPT(NR) := NPT(NR) + 1$ 。
- $R4$: $V_a \in N_4(V_0)$ かつ $\Omega_R^*(V_a) \cap S_{NR} \neq \emptyset$ である点 V_a を $STACKA$ の上から順に詰める(以後この操作を点 V_0 に関するスタック操作と呼ぶ)。但し、 $S_{NR} = \{ V \mid S(V) = NR \}$ である。
- $R5$: $STACKA$ が空であれば $STATE := 0$ とし、 $STACKA$ の一番底の要素 V を取り出した後 $R7$ へ。 $STACKA = \emptyset$ ならば次の $R6$ へ。
- $R6$: $STACKB$ が空であれば $STATE := 1$ とし、 $STACKB$ の一番底の要素 V を取り出した後 $R7$ へ。 $STACKB = \emptyset$ ならば $R16$ へ。
- $R7$: $S(V) = 0$ ならば次の $R8$ へ。 $S(V) \neq 0$ ならば $R5$ へ。
- $R8$: 以下の 1)~3) の条件のうち、少

なくとも 1 が成り立てば, $S(V_x) := NR$, $NPT(NR) := NPT(NR) + 1$ とし, 点 V_x に関するスタック操作を行なった後 R5 へ.

[判定条件]

- 1) $|\Omega_R^*(V_x)| = 2$.
- 2) $|\Omega_R^*(V_x) \cap S_{NR}| \geq 2$.
- 3) $\exists V \in N_3(V_x)$ に対して,
 $P(V) = P(V_x)$ かつ
 $S(V) = NR$.

R9: 点集合 $N_3(V_x) \cap \Omega_R^*(V_x)$ に属する点の中で $d(V_x, \cdot) + C \cdot \delta_R(\cdot)$ の値を最小にする点 V_y を選ぶ.

R10: $S(V_y) = NR$ ならば $S(V_x) := NR$, $NPT(NR) := NPT(NR) + 1$ とし, 点 V_x に関するスタック操作を行なった後 R5 へ.

R11: $S(V_y) > 0$ かつ $S(V_y) \neq NR$ ならば $S(V_x) := S(V_y)$, $NPT(S(V_y)) := NPT(S(V_y)) + 1$ とし, R5 へ.

R12: (この場合 $S(V_y) = 0$ である) 集合 $\Omega_R^*(V_x) \cap S_{NR}$ に属する点 V_x を選ぶ. ステップ R8 の条件よりこのような点は必ず 1 個だけ存在する.

R13: $D_{yz} := 1 + |P(V_y) - P(V_x)|$ とする. $\lambda_r \cdot D_{yz} \leq \min\{\xi_R(V_y), \xi_R(V_x)\}$ ならば次の R14 へ, そうでなければ R15 へ.

R14: $S(V_x) := NR$, $NPT(NR) := NPT(NR) + 1$ とし, 点 V_x に関するスタック操作を行なう.

さらに, $\exists V \in N_4(V_y)$ について, $V \in S_{NR}$ であれば $S(V_y) := NR$, $NPT(NR) := NPT(NR) + 1$ とし, 点 V_y に関するスタック操作を行なった後に R5 へ.

R15: (点 V_x を領域 NR に加えることを棄却)

STATE = 0 ならば STACKB に V_x を加えた後 R5 へ. STATE = 1 ならばそのままの状態でも R5 へ.

R16: $NPT(NR) = 1$ ならば次の R17 へ, そうでなければ $NR := NR + 1$ とし

て R18 へ.

R17: (雑音処理) 領域 NR を構成する点 V_a について, 点 V_a の 4 連結近傍の点の中で $d(V_a, \cdot) + C \cdot \delta_R(\cdot)$ の値を最小にする点 V_s を選ぶ,

$S(V_a) := 0$, $P(V_a) := P(V_s)$,
 $\xi_R(V_a) := \xi_R(V_s)$, $d_R(V_a) := d_R(V_s)$ とする.

さらに, $S(V_s) > 0$ ならば

$S(V_a) := S(V_s)$, $NPT(S(V_s)) := NPT(S(V_s)) + 1$ とする.

R18: $S(V) = 0$ である点が存在すれば R2 へ. そうでなければ $NR := NR - 1$ として停止.

END

なお, 各ステップにおいて行き先が明確に指定されていない場合には, それに続くステップに進むものとする.

次にアルゴリズムの動作について述べる. この領域拡張アルゴリズムではなるべく領域の中心に近いと推測される点から順次拡張を行なって行く. そのためにステップ R3 で, 境界値 δ_R が最小である点 V_0 を領域拡張の出発点に選んでいる.

さて, 領域 NR に r -隣接している点 V_x が拡張の候補点として取り出されると, この点について一連の判定条件が試される. アルゴリズムにおいては簡単に判定できる条件から順に配置されている. 最初の判定はステップ R8 でなされる. このステップにおける条件が成り立つ場合を Fig. 3 に示す.




Fig. 3 ステップ R8 の条件 (1), (2) を満足する場合

Fig. 3 の破線で囲まれた点の集合は既に領域 NR に属することが決定され

た部分, 即ち, SNR である。また, 双方向矢印のみが示されている。図より, これらの場合には点 V_x を領域 NR に加えることに問題はないであろう。また, 条件 (3) は自明であるので図では省略した。

これらの条件がいずれも満たされない場合には, ステップ R9 において, 候補点 V_x に最も似ており, しかも領域の中心部に近い ($\delta_R(\cdot)$ の値が小さい) 点 V_y を選ぶ。ステップ R10 はこの点 V_y が領域 NR に属している場合であり, ステップ R11 は V_y が NR と異なる領域に属している場合である。点 V_y がどの領域にも属していない場合 ($S(V_y) = 0$ のとき) には, ステップ R12 で V_x に近一隣接しており, かつ領域 NR に属する点 V_x を選ぶ。このような点 V_x はただ 1 個存在し, 明らかに $V_x \neq V_y$ である。Fig. 4 はこのような状況を示している。




Fig. 4 ステップ R12 における状況


ステップ R13 では, 点 V_y の環境と点 V_x の環境を比較している。即ち, 点 V_y の環境が点 V_x を許容し得る範囲 ($\lambda_r \cdot D_{yz} \leq \xi_R(V_y)$) にあり, かつその逆も成り立つ ($\lambda_r \cdot D_{xz} \leq \xi_R(V_x)$) ならば, V_x を領域 NR に加える。

さらに, このとき点 V_y が SNR に 4 連結していれば, V_y も領域 NR に加える。

ステップ R13 の条件が満足されない場合には候補点 V_x を領域 NR に加えず棄却する。

ステップ R17 は面積 1 の孤立微小領域に対する処理であり, ステップ R18 はアルゴリズム停止の判定部分である。

最後に, ステップ R13 において用いるパラメータ λ_r について説明しよう。まず, $\lambda_r = 0$ とするとステップ R13 の条件は必ず成り立つ。したがって, この場合には近一隣接性だけを判定条件として領域を拡張して行くのと同じ効果をもつ。一方, λ_r を十分大きくするとステップ R13 の条件は成り立たなくなり, 画像はかなり多くの領域に分かれることになる。以上述べたことから, λ_r というパラメータは一種の調節機能をもっていることが理解されよう。人間は画像を大雑把に見ることもできるし, また目の分解能の範囲内で詳しく見ることもできる。これと同じことが物体認識においても言える。例えば, 海が写っている写真が与えられたとき, 海の波を検出するべきかどうかは, セマンティックスの問題ではなく, むしろ画像を処理しようとする人間の目的・意図に関する問題である。したがって領域分割アルゴリズムは人間の



(a) 自然風景 (b) 細胞

Fig. 5 入力画像

意図を反映し得る機能をもつべきである。筆者らはこのパラメータ λ_r を導入することによってある程度それに成功したと考えている。


実験で用いた二種類の異なるタイプの入力画像を Fig. 5 に示す。これは、ライン・プリンタによって 8 レベルに濃淡打ちしたものである。(a) は大雑把に見て、空、山、羽より構成された自然風景であり、(b) は子宮癌組織中の正常な細胞の顕微鏡写真である。

次に本アルゴリズムの実験結果について述べる。

Fig. 5 の両画像に対して本アルゴリズムを適用したときの領域分割結果を Fig. 6 (a), (b) に示す。意味のない微小領域をいくつか含んでいるけれども、ある程度人間の視覚に近い分割結果を得ていると考えられる。

6. 領域統合プロセス

前章で示した領域拡張による分割結果に対する領域間の統合について述べる。



(a) 自然風景
 $n = 4$
 $\lambda_r = 0.8$

(b) 細胞
 $n = 4$
 $\lambda_r = 0.8$

Fig. 6 領域拡張による分割結果

前章で述べた領域拡張アルゴリズムが局所的な類似性のみ注目して領域を拡張して行くのに対して、本章で述べる領域統合アルゴリズムは領域間の大局的な類似性に注目して隣接領域の統合を行なう。

領域統合の判定部分で用いる領域の特徴は濃淡レベルの平均値、標準偏差及び領域面積である。

次に領域統合アルゴリズムの概要を示す。

[領域統合アルゴリズム]

M1: 領域拡張アルゴリズムによって形成された各領域 R について、領域内での濃淡レベルの平均値 $\mu(R)$ 、標準偏差 $\sigma(R)$ 及び面積 $|R|$ を計算する——これらは実際には領域拡張の過程で計算されている——。

M2: 次の条件を満たす隣接領域対 R_i, R_j ($R_i < R_j$ とする) が存在すれば、次の M3 へ。存在しなければ停止。

[判定条件]

$$|\mu(R_i) - \mu(R_j)| \leq \min \left\{ \left(1 + \lambda_m \cdot \frac{|R_j|}{|R_i|}\right) \cdot \sigma(R_i), \left(1 + \lambda_m \cdot \frac{|R_i|}{|R_j|}\right) \cdot \sigma(R_j) \right\}$$

M3: 領域 R_j を R_i に統合し、 R_i の濃淡平均値、標準偏差及び面積を修正した後 M2 へ。

END

このアルゴリズムにおいても相対的類似性の概念が用いられている。但し、3章では隣接要素に注目しているのに対して、ここでは隣接領域に注目している。

ステップ M2 の統合判定条件は次の二条件に分解される。

$$(a) |\mu(R_i) - \mu(R_j)|$$

$$\leq (1 + \lambda_m \cdot \frac{|R_j|}{|R_i|}) \cdot \sigma(R_i) \quad \text{かつ}$$

$$(b) \quad |\mu(R_j) - \mu(R_i)|$$


$$\leq (1 + \lambda_m \cdot \frac{|R_i|}{|R_j|}) \cdot \sigma(R_j)$$

このように書き直すと、ここでもやはり双方向の類似性に基づいていることが理解されよう。しかも統合に際して領域の大きさ（面積）を考慮するように工夫されている。

パラメータ λ_m は面積を考慮する度合いを反映する量である。

Fig. 7 は、Fig. 6 に示した領域拡張結果に対して本アルゴリズムを適用したときの領域分割結果である。

Fig. 8 は Fig. 7 の各領域をそれぞれの平均濃淡レベルで Fig. 5 と同様に濃淡打ちしたものである。



(a) 自然風景
 $\lambda_m = 0.0$

(b) 細胞
 $\lambda_m = 0.0$

Fig. 7 領域統合による分割結果


7. むすび

本報告において、筆者らは事前情報や種々の要因に依存する経験的な閾値を用いない（本方法で用いたパラメータを、 λ_r, λ_m は量子化レベル数及び個々の画像のコントラストの程度等に比較的独立して決定できる）領域解析法を提案し、本方法が領域分割（物体識別）に関する人間の視覚にほぼ忠実であることを実験によって確かめた。

実験では 64 レベルに量子化された 64×64 の画像を用い、処理時間（CPU 時間）は Fig. 5 から Fig. 8 までで約 2 分であった（使用計算機は FACOM-230/45S である）。

現在、筆者らは処理時間を短縮するために次のような手法を検討中である。

- (1) 領域の拡張速度を上げるために、領域分割に適した——領域内部



(a) 自然風景

(b) 細胞

Fig. 8 分割結果からの画像の再構成

での平滑化及び境界部分での鮮鋭化が可能である——前処理フィルターを開発する。

- (2) τ -隣接性を決定する $\xi_k(\cdot)$ を近似量によって置き換える。
- (3) 領域拡張過程の階層化。

本方法の応用分野として、物体識別以外に両眼視画像から距離情報を抽出する問題なども考えている。

最後に、本研究に対して有益な御助言をいただいた当研究室の田村進一助教授、工博・北橋忠宏助手並びに Fig. 5(b) の試料を御提供下さったミュンヘン工科大学・Marko 教授下の画像処理グループの方々に感謝する。また、プログラムの作成とアルゴリズムの検討に協力してもらった本研任・大入保均氏に感謝する。

参考文献

- (1). J.L. Muerle and D.C. Allen : Experimental evaluation of techniques for automatic segmentation of objects in a complex scene. In *Pictorial Pattern Recognition* pp 3-13, Thompson, Washington, 1968.
- (2). C. Brice and C. Fennema : Scene Analysis Using Regions, *Artificial Intelligence* 1, 205-226, 1970.
- (3). T. Pavlidis : Segmentation of Pictures and maps through functional approximation, *Computer Graphics and Image Processing* 1, 360-372, 1972.
- (4). S.L. Horowitz and T. Pavlidis : Picture segmentation by a directed split-and-merge procedure, *Proc. Second Int. Joint Conf. Pattern Recognition*, 424-433, 1974.
- (5). 棟上昭男 : 領域分割による図形の特徴抽出 情報処理学会第16回大会講演予稿集 No. 302 1975.
- (6). Y. Yakimovsky and J. Feldman : A semantics based decision region analyzer, *Proc. Third Int. Joint Conf. Artificial Intelligence* 580-588, 1973.
- (7). S.W. Zucker : Region Growing : Childhood and Adolescence, *Computer Graphics and Image Processing* 5, 382-399, 1976.
- (8). 満口理一郎, 志村正道 : 階層構造を用いたクラス検出アルゴリズム, *信学論* vol. 59-D, no. 7 451-458, 1976.

(9). A. Rosenfeld : *Picture Processing by Computer*, Academic Press, 1969.

(10). 横矢直和, 浅野智夫, 田中幸吉 : 相対的類似性の概念に基づく濃淡画像の領域分割, 関西電子工業振興センター, 情報処理研究会, 1977. 1. 26.

◇