

クラスタ化手順に基づいた不連続な輪郭線画像の線分近似

正員 渡辺 孝志[†] 正員 鈴木 一也[†]
 非会員 丹波 澄雄[†] 正員 横山 隆三[†]

Polyline Approximation of Discontinuous Contour Images Based on Clustering Procedure

Takashi WATANABE[†], Kazuya SUZUKI[†], *Members*, Sumio TANBA[†], *Nonmember* and Ryuhsou YOKOYAMA[†], *Member*

あらまし 本論文では輪郭線画像の線分近似問題を取り扱っている。従来提案されている線分近似手法のほとんどは輪郭線が連続している場合のみ適用可能であり、雑音等で輪郭線が至る所不連続となっているような画像にうまく対処できる手法として十分なものはまだ得られていない。本論文では、連続性が全く欠如している輪郭線画像に対しても適用可能な線分近似手法として、クラスタ化手順に基づいた新しい手法を提案している。具体的には、線分を分類単位とするハードクラスタリングまたはファジィクラスタリングを用いて画像中のエッジ点集合をクラスタ群に分割し、得られたクラスタごとに線分情報を抽出する手法を採用している。提案手法の効果を検証するための評価実験では、良好な結果が得られた。

キーワード：輪郭線画像，線分近似，クラスタリング，ファジィ，不連続

1. まえがき

輪郭線画像の線分近似処理は、図形の解析，認識，特徴抽出や情報圧縮などにおいて，基本的で重要な画像処理手段として広く利用されている⁽¹⁾。

しかしながら，従来の線分近似手法のほとんどは輪郭線の連続性を前提としており，(雑音等で品質が劣化している画像を処理する際に生ずる)輪郭線が至る所不連続となっているような画像にもうまく対処できる近似手法は，まだ確立されているとは言えない。

また，筆者ら⁽²⁾は，先に，相似変換不変な図形検出法としての一般化ハフ(Hough)変換の高速化手法を提案したが，この場合においても，(一般化ハフ変換がしばしば適用対象とするような)輪郭線が至る所不連続となっている画像に対処できる線分近似手法を見出すことが検討課題として残されていた。

輪郭線が連続している場合には輪郭線を追跡することによって，許容誤差内に収まるように輪郭線を逐次

的に区分して線分近似することが可能である⁽³⁾。これに対して，輪郭線が至る所不連続となっている場合には，輪郭線そのものの検出が難しく，一つの線分で近似し得る輪郭点の範囲を指定することはかなり困難な問題である。すなわち，後者の場合には線分近似問題が輪郭線の検出問題と不可分な形となっており，それだけ処理が厄介になっていると言える。

輪郭線が至る所不連続となっている場合にも適用できる線分近似手法としては，筆者らの知る限りでは，ファジィクラスタリングを用いたBezdekらの方法^{(4)~(6)}，ハフ変換を用いたMcKenzieらの方法⁽⁷⁾とPrincenらの方法⁽⁸⁾がある。しかし，前者ではクラスタ化基準に選んだ二つの評価関数の整合性に問題があり，後者でも精度の高い線分パラメータの推定が困難という問題があり，ともに複雑な輪郭線画像に適用するには改良すべき課題を抱えている。

本論文では，前者のクラスタ化手順を利用した線分近似手法の考えを発展させ，連続性が全く欠如している複雑な輪郭線画像に対しても適用可能な，改良された線分近似手法を提案する。具体的には，線分を分類単位とするクラスタ化基準を新たに採用し，これに輪

[†] 岩手大学工学部情報工学科，盛岡市
 Faculty of Engineering, Iwate University, Morioka-shi, 020 Japan

郭線をより安定的にかつ高速に線分近似するための諸工夫を付加したものを提案している。評価実験では、提案手法が良好な線分近似能力を有していることを確認した。

2. クラスタリングと線分近似問題

2.1 ハード/ファジィクラスタリング

今、クラスタ化対象とする有限データ集合を $X = \{x_1, x_2, \dots, x_n\}$ で表す。要素 x_k は k 番目のデータ点を表す N 次元実数ベクトルとする。 X をいくつかのクラスタに分けるものとし、そのクラスタ数を c ($2 \leq c < n$) とする。そして、次の式を満足する $c \times n$ 行列 $U = (u_{ik})$ を考える。

$$u_{ik} \in \{0, 1\} \quad (1 \leq i \leq c, 1 \leq k \leq n) \quad (1a)$$

$$\sum_{i=1}^c u_{ik} = 1 \quad (1 \leq k \leq n) \quad (1b)$$

$$\sum_{k=1}^n u_{ik} > 0 \quad (1 \leq i \leq c) \quad (1c)$$

u_{ik} はデータ点 x_k が i 番目のクラスタに含まれているか否かを表しており、写像 $u_i: X \rightarrow \{0, 1\}$ を

$$u_i(x_k) = u_{ik} \quad (2)$$

で定めると、 $\{u_1, u_2, \dots, u_c\}$ は X のハードクラスタリングを与える表現となる。このような行列 U の集合を M_c で表す。

次に、データ点 x_k が複数のクラスタに属し得るものと考えて、 u_{ik} をファジィ的に表すことにする。すなわち、 u_{ik} の条件式(1a)の代わりに

$$u_{ik} \in [0, 1] \quad (1 \leq i \leq c, 1 \leq k \leq n) \quad (1a')$$

を用いる。このとき、 u_{ik} はデータ点 x_k が i 番目のクラスタに属する程度を表すメンバシップ値を与える。写像 $u_i: X \rightarrow [0, 1]$ を同じく式(2)で定めれば、 $\{u_1, u_2, \dots, u_c\}$ は X のファジィクラスタリングを与える表現となる。このような行列 U の集合を M_{fc} で表す。明らかに、 $M_c \subset M_{fc}$ である。

2.2 クラスタリングによる線分近似

以下、 $N=2$ とし、データ集合 X には 2 値化された輪郭線画像のエッジ点全体を対応させるものとする。このとき、輪郭線を線分近似する問題は次のようなクラスタ化問題として定式化できる。すなわち、まず各クラスタが一つの線分で近似し得るエッジ点の集まりとなるように X をクラスタ化し、次に各クラスタから近似線分を抽出する。

クラスタの内容はクラスタ化基準で定まる。例えば、各クラスタ重心とデータ点との 2 乗距離和基準 J_0 を最

小化する FCM (Fuzzy c-Means) 法では、データ点は重心点の周りの固まりとしてクラスタ化される⁽⁴⁾。また、各クラスタの回帰直線(無限直線)とデータ点との 2 乗距離和基準 J_1 を最小化する FCL (Fuzzy c-Lines) 法では、データ点は回帰直線の周りの固まりとしてクラスタ化される⁽⁵⁾。

Bezdek ら⁽⁶⁾は、FCM 法と FCL 法を併用したクラスタ化基準として、 J_0 と J_1 の和

$$J_{01} = (1-\alpha)J_0 + \alpha J_1 \quad (0 < \alpha < 1) \quad (3)$$

を最小化する FCE (Fuzzy c-Elliptotypes) 法を提案し、これによって至る所不連続な輪郭線が直線で近似できることを示した。しかし、FCE 法では有限長であるべき近似線分が点と無限直線の組でとらえられているために、(1)複雑な輪郭線についてはうまく働かない、(2)近似結果が線分(有限長)でなく、直線(無限長)で与えられる、などの問題を抱えている。

2.3 FCL 法⁽⁵⁾

本研究では FCL 法を改良した線分近似手法について検討するので、以下に FCL 法の概略を述べる。

2 次元の実ベクトル空間 R^2 における通常のベクトルの内積、ノルム、距離をそれぞれ $\langle x, y \rangle = x^T y$, $\|x\| = \langle x, x \rangle^{1/2}$, $d(x, y) = \|x - y\|$ で表す。空間 R^2 内で、点 p を通り、方向ベクトル v をもつ直線は

$$L(p, v) = \{y \in R^2 \mid y = p + tv; t \in R\} \quad (4)$$

で表される。ここで、方向ベクトル v は $\|v\| = 1$ とする。また、直線 $L(p, v)$ と点 $x \in R^2$ との直交距離を

$$D(x, L(p, v)) = (\|x - p\|^2 - \langle x - p, v \rangle^2)^{1/2} \quad (5)$$

で表す。以下、 k 番目の点 x_k と i 番目の直線 $L_i = L(p_i, v_i)$ との距離を

$$D_{ik} = D(x_k, L_i) \quad (6)$$

と略記する。

今、全部で c 個の直線 $\{L_1, L_2, \dots, L_c\}$ を考え、その記述パラメータの組を

$$\underline{p} = (p_1, p_2, \dots, p_c) \quad (p_i \in R^2) \quad (7)$$

$$\underline{v} = (v_1, v_2, \dots, v_c) \quad (v_i \in R^2) \quad (8)$$

とおく。このとき、次に示す評価関数

$$J_1(U, \underline{p}, \underline{v}) = \sum_{k=1}^n \sum_{i=1}^c (u_{ik})^m (D_{ik})^2 \quad (9)$$

を考える。但し、 m は u_{ik} の重み付け係数 ($1 \leq m < \infty$) である。評価関数 J_1 は、点 x_k と直線 L_i との 2 乗距離値がメンバシップ値の m 乗によって重み付けされた和である。このとき、 X の最適ファジィクラスタリングを、 $J_1(U, \underline{p}, \underline{v})$ を最小化する $(U^*, \underline{p}^*, \underline{v}^*)$ における U^* として定める。

J_1 を最小化する条件としては次が知られている。
 [定理 1]⁽⁵⁾ $(\underline{p}, \underline{v})$ を一つ選んで固定し、 $\phi_1(U) = J_1(U, \underline{p}, \underline{v})$ とおく。また、 $1 < m < \infty$ とし、任意の i, k について $D_{ik} > 0$ とする。このとき、 $U^* = (u_{ik}^*)$ が ϕ_1 の極小点となるための必要十分条件は、任意の i, k について次式が成立することである。

$$u_{ik}^* = \frac{1}{\sum_{j=1}^c (D_{ik}/D_{jk})^{2/(m-1)}} \quad (10)$$

[定理 2]⁽⁵⁾ U を一つ選んで固定し、 $\phi_1(\underline{p}, \underline{v}) = J_1(U, \underline{p}, \underline{v})$ とおく。また、 $1 < m < \infty$ とする。このとき、 $(\underline{p}^*, \underline{v}^*)$ が ϕ_1 の極小点となるための必要十分条件は、任意の i について次式が成立することである。

$$p_i^* = \frac{\sum_{k=1}^n (u_{ik})^m x_k}{\sum_{k=1}^n (u_{ik})^m} \quad (11)$$

$$v_i^* = \xi_i \quad (12)$$

但し、 ξ_i は次のクラスタ内ファジィ共分散行列

$$\Sigma_i = \sum_{k=1}^n (u_{ik})^m (x_k - p_i^*)(x_k - p_i^*)^T \quad (13)$$

の最大固有値に対応する固有ベクトルである。

3. 線分を単位とするクラスタ化手順

3.1 クラスタ化基準 J_s

線分を $S(p, v, l)$ で表す。但し、 p は線分の中心点、 v は線分の方向ベクトル、 l は線分の半分の長さとする。このとき、

$$S(p, v, l) = \{y \in R^2 \mid y = p + tv; t \in [-l, l]\} \quad (14)$$

である。また、線分 $S(p, v, l)$ と点 $x \in R^2$ との距離を

$$\rho(x, S(p, v, l)) = \min\{d(x, y) \mid y \in S(p, v, l)\} \quad (15)$$

で定める。この距離は、点 x から直線 $L(p, v)$ への垂線の足 q が線分上にある場合には線分との直交距離になり、線分外にある場合には線分の端点からの距離となる (図 1)。従って、

$$\rho^2 = \begin{cases} \|x - p\|^2 - \langle x - p, v \rangle^2 & (|\langle x - p, v \rangle| < l) \\ \|x - p\|^2 - 2l|\langle x - p, v \rangle| + l^2 & (\text{その他}) \end{cases} \quad (16)$$

で計算できる。以下、 k 番目の点 x_k と i 番目の線分 $S_i = S(p_i, v_i, l_i)$ の距離を

$$\rho_{ik} = \rho(x_k, S_i) \quad (17)$$

と略記する。

今、全部で c 個の線分 $\{S_1, S_2, \dots, S_c\}$ を考え、その記述パラメータの組を前節と同様に、




図 1 エッジ点と線分との距離 ρ
 Fig. 1 The distance ρ between edge pixel and line segment.

$$\underline{p} = (p_1, p_2, \dots, p_c) \quad (p_i \in R^2) \quad (18)$$

$$\underline{v} = (v_1, v_2, \dots, v_c) \quad (v_i \in R^2) \quad (19)$$

$$\underline{l} = (l_1, l_2, \dots, l_c) \quad (l_i \in R^+) \quad (20)$$

とおく。但し、 R^+ は正数全体の集合である。このとき、次に示す評価関数

$$J_s(U, \underline{p}, \underline{v}, \underline{l}) = \sum_{k=1}^n \sum_{i=1}^c (u_{ik})^m (\rho_{ik})^2 \quad (21)$$

を考える。このとき、 X の最適ファジィクラスタリングを、 $J_s(U, \underline{p}, \underline{v}, \underline{l})$ を最小化する $(U^*, \underline{p}^*, \underline{v}^*, \underline{l}^*)$ における U^* として定める。

J_s を最小化する条件としては次が成立する。

[定理 3] $(\underline{p}, \underline{v}, \underline{l})$ を一つ選んで固定し、 $\phi_s(U) = J_s(U, \underline{p}, \underline{v}, \underline{l})$ とおく。また、 $1 < m < \infty$ とし、任意の i, k について $\rho_{ik} > 0$ とする。このとき、 $U^* = (u_{ik}^*)$ が ϕ_s の極小点となるための必要十分条件は、任意の i, k について次式が成立することである。

$$u_{ik}^* = \frac{1}{\sum_{j=1}^c (\rho_{ik}/\rho_{jk})^{2/(m-1)}} \quad (22)$$

定理 1 は距離 D_{ik} の定義によらず成立するので、定理 3 の証明は定理 1 と全く同様である。

もし、ある k について $\rho_{ik} = 0$ となる i が存在するときには、十分小さな正数 δ を用いて

$$\rho_{ik} = \delta \quad (23)$$

と置き換えて計算するものとする。

また、線分 $S(p_i, v_i, l_i)$ で l_i が無限長のとき、

$$L(p_i, v_i) = S(p_i, v_i, \infty) \quad (24)$$

$$D_{ik} = \rho_{ik} \quad (25)$$

$$J_1(U, \underline{p}, \underline{v}) = J_s(U, \underline{p}, \underline{v}, \infty) \quad (26)$$

となる。従って、定理 2 が次の形で成立する。

[定理 4] U を一つ選んで固定し、 $\phi_s(\underline{p}, \underline{v}) = J_s(U, \underline{p}, \underline{v}, \infty)$ とおく。また、 $1 < m < \infty$ とする。このとき、 $(\underline{p}^*, \underline{v}^*)$ が ϕ_s の極小点となるための必要十分条件は、 $(\underline{p}^*, \underline{v}^*)$ が式(11)、(12)で与えられることである。

3.2 J_s に基づくクラスタ化手順

定理3と定理4に基づいて、クラスタ化基準 J_s を最小化するための反復的なクラスタ化手順を導出しよう。

クラスタ化手順を導出する際に問題となるのは、定理4である。これは直線(無限長)に対するものであって、線分(有限長)に対するものではない。しかしながら、一つの与えられた U に対して、線分の中心点 p_i とそれを通過する線分方向ベクトル v_i の推定値として、式(11)と式(12)を用いることはまだ意味をもっている。問題は線分の長さ $2l_i$ を推定することであるが、これは、 $\{U, p_i, v_i\}$ と X を用いれば、次のようにして推定可能である。

今、直線 $L(p_i, v_i)$ が有効幅 $2w$ をもつものとするれば、対応する線分における l_i の候補値としては

$$l_i' = \max_k \{ |\langle x_k - p_i, v_i \rangle| \mid D_{ik} \leq w \} \quad (27)$$

が考えられる。しかし、 $D_{ik} < w$ は $\rho_{ik} < w$ を意味しないので、これでは本来の線分から遠く離れた点も含めてしまい、線分長が不当に長くなる危険がある。そこで、式(13)で与えられるファジィ共分散行列 Σ_i の最大固有値を λ_i とすれば、これは l_i を分散の形で評価したものと解釈できる。すなわち、区間 $[-l_i, l_i]$ 上における一様分布の分散は $l_i^2/3$ であるので、線分上にエッジ点が一樣に分布していると仮定すれば、 $l_i^2/3 = \lambda_i$ である。従って、 l_i の候補値として

$$l_i'' = (3\lambda_i)^{1/2} \quad (28)$$

が考えられる。そこで、 l_i の推定値として

$$l_i^* = \min\{l_i', l_i''\} \quad (29)$$

を採用するものとする。

以上から $m > 1$ で J_s を最小化するクラスタ化手順として次が得られるが、これを原型 FCS (Fuzzy c-Segments) 法と呼ぶことにする。

〈原型 FCS アルゴリズム〉 ($1 < m < \infty$)

(手順1) m ($1 < m < \infty$) と c ($1 < c < n$) を固定する。

(手順2) $U^{(0)} \in M_{rc}$ を初期化する。

(手順3) $U^{(0)}$ と式(11), (12), (29)を用いて、 $(\underline{p}^{(0)}, \underline{v}^{(0)}, \underline{l}^{(0)})$ を計算する。

(手順4) $(\underline{p}^{(0)}, \underline{v}^{(0)}, \underline{l}^{(0)})$ と式(22)を用いて、 $U^{(1)}$ を計算する。

(手順5) 適当な基準を用いて、 $U^{(0)}$ と $U^{(1)}$ を比較する。例えば、適当な小正数 ϵ を選んで比較式を

$$\max_{i,k} \{ |u_{ik}^{(0)} - u_{ik}^{(1)}| \} \leq \epsilon \quad (30)$$

とし、これが成立すれば処理を終了し、それ以外では

$U^{(0)} = U^{(1)}$ として手順3に戻る。 (手順完)

また、 $m=1$ の場合に J_s を最小化するクラスタ化手順として次が得られるが、これを原型 HCS (Hard c-Segments) 法と呼ぶことにする。

〈原型 HCS アルゴリズム〉 ($m=1$)

(手順1) $m=1$ とし、 c ($1 < c < n$) を固定する。

(手順2) $U^{(0)} \in M_c$ を初期化する。

(手順3) $U^{(0)}$ と式(11), (12), (29)を用いて、 $(\underline{p}^{(0)}, \underline{v}^{(0)}, \underline{l}^{(0)})$ を計算する。

(手順4) $(\underline{p}^{(0)}, \underline{v}^{(0)}, \underline{l}^{(0)})$ と次式を用いて、 $U^{(1)}$ を計算する。

$$u_{ik}^* = \begin{cases} 1 & (\rho_{ik} = \min_j \{\rho_{jk}\}) \\ 0 & (\text{その他}) \end{cases} \quad (31)$$

(手順5) $U^{(0)}$ と $U^{(1)}$ を比較して、 $U^{(1)} = U^{(0)}$ ならば処理を終了し、それ以外では $U^{(0)} = U^{(1)}$ として手順3に戻る。 (手順完)

この節のはじめに述べたように、定理4は十分長い線分に対しては成立するが、短い線分に対しては必ずしも成立しない。更に、上記の二つのアルゴリズムが厳密な意味で J_s の極小点に収束するための条件はまだ明らかではない。しかしながら、両アルゴリズムは物理的に意味が明確な量を計算しており、次章で述べるような改良を付け加えることで、ともに準最適解に収束することが期待できる。実際に、このことは後の5.で述べる検証実験で確認される。

4. 線分近似手法の改良

4.1 適応化による改良

前章で述べた二つの線分近似手法(原型 FCS 法, 原型 HCS 法)によって得られる結果は、必ずしも対象とする輪郭線の有効な線分近似を与えるとは限らない。なぜならば、解が J_s の極小点となっても最小点であるとは限らないし、クラスタ数 c を事前に適切な値に設定することも極めて困難であるからである(c の値が適切でない場合には、得られるクラスタは意味のないものになりやすい)。

そこで、クラスタ化手順が終了した段階で、得られた線分群が輪郭線を適切に線分近似しているかどうかを判断することにしよう。ここではその判断基準として線分とエッジ点との単純なマッチングを用いる。これは、線分と輪郭線の整合度合いを、図2に示すように、線分と輪郭線との交差する割合によって定めるものである。すなわち、線分 S_i のマッチング度 Q_i を




図2 線分マッチング度
Fig. 2 Segment matching rate.

$$Q_i = \frac{\text{線分 } S_i \text{ にマッチングしたエッジ点数}}{\text{線分長 } 2l_i \text{ の画素数換算値}} \quad (32)$$

で定める。但し、上式の分子は線分の有効幅を $2w$ とした場合にその有効幅内にあるエッジ点の数である。

このとき、適当なしきい値 σ_1 に対して

$$\min_j \{Q_j\} > \sigma_1 \quad (33)$$

を満足するならば、得られた線分群は対象とする輪郭線を正しく近似していると判断できる。

もし、 $\{Q_j\}$ の中でしきい値 σ_1 より小さいものがあるば、そのときの線分群は輪郭線を適切に線分近似していないことになる。この場合には、

$$Q_i = \min_j \{Q_j \mid Q_j < \sigma_1\}$$

となる線分 S_i に対して、その線分を中心点で2分割して、クラスタ(線分)数を1増やして再度クラスタリングをやり直すことにする。これを式(33)が成立するまで繰り返す、線分数を増やしていくものとする。これによって、処理対象画像に適応した形でクラスタ数 c を自動的に調整できる。

4.2 高速化による改良

上記の適応化を採用する場合の最大の問題点は処理時間である。予備実験の結果から、次のような問題点が明らかとなった。

- (1) エッジ点数とクラスタ数が増えると、反復1回分の計算でもかなりの時間がかかる。
- (2) 収束までにかかなりの反復回数を要する。
- (3) 適応化によりクラスタ化処理をやり直すので、対象画像が複雑になるほど処理時間がかかる。

ここでは、このような問題点の解決策として、前述した線分のマッチング度を利用することを考える。すなわち、式(33)が成立しない場合は再度クラスタ化処理をやり直すことになるが、その際に得られた線分群の中には適切なものも含まれていると考えられる。そこで、適当なしきい値 σ_2 ($\geq \sigma_1$) に対して、

$$Q_i \geq \sigma_2$$

となった線分は対象輪郭線を適切に近似しているものとし、その線分と線分に近似されたエッジ点は次のクラスタ化処理から取り除くことにする。そのためには、該当するエッジ点とクラスタに処理済みのフラッグを立てるだけでよい。

これによって、エッジ点数とクラスタ数を削減できるので、上記(1)の問題に対処できる。また、処理対象の規模も小さくなるので、上記(2)、(3)の問題もかなり改善され得ると考えられる。

4.3 改良された線分近似アルゴリズム

原型 FCS 法に適応化と高速化の二つの改良を加えた線分近似アルゴリズムを次に示す。

<改良型 FCS アルゴリズム> ($1 < m < \infty$)

(手順1) m ($1 < m < \infty$) を固定し、 c ($1 < c < n$) を小さい値に選ぶ。

(手順2) $U^{(0)} \in M_{fc}$ を初期化する。

(手順3) 各エッジ点と各クラスタのフラッグ値を0にセットする。

(手順4) フラッグ値が0となっているエッジ点とクラスタに対してのみ $U^{(0)}$ と式(11)、(12)、(29)を用いて、 $(\underline{p}^{(0)}, \underline{v}^{(0)}, \underline{l}^{(0)})$ を計算する。

(手順5) フラッグ値が0となっているエッジ点とクラスタに対してのみ、 $(\underline{p}^{(0)}, \underline{v}^{(0)}, \underline{l}^{(0)})$ と式(22)を用いて、 $U^{(1)}$ を計算する。

(手順6) 適当な基準を用いて、 $U^{(0)}$ と $U^{(1)}$ を比較する。例えば、比較式を式(30)とし、これが成立すれば手順7に行き、それ以外では $U^{(0)} = U^{(1)}$ として手順4に戻る。

(手順7) 得られた $(\underline{p}^{(0)}, \underline{v}^{(0)}, \underline{l}^{(0)})$ に基づいて、フラッグ値が0となっているエッジ点とクラスタに対してのみ、各線分 $S_i = S(p_i^{(0)}, v_i^{(0)}, l_i^{(0)})$ のマッチング度 Q_i を計算する。しきい値 σ_1 に対して、式(33)が成立すれば処理を終了し、そうでなければ手順8に行く。

(手順8) しきい値 σ_2 に対して、 $Q_i \geq \sigma_2$ となるすべてのクラスタのフラッグ値を1にセットし、その分だけ c を減ずる。また、その線分にマッチングしたすべてのエッジ点のフラッグ値を1にセットする。そして、

$$Q_i = \min_j \{Q_j \mid Q_j < \rho_1\}$$

となる線分 S_i に対して、その線分を中心点で2分割して c を1増やし、そのフラッグ値を0にセットする。次に、フラッグ値が0となっているエッジ点とクラスタに対してのみ、式(22)を用いて $U^{(0)}$ を計算して、手順4に戻る。 (手順完)




図3 評価実験に用いた画像

Fig. 3 The pattern used in the experiment. (a) the original pattern, (b) the input pattern to the test.




図4 改良前の手法による近似結果

Fig. 4 The results by the unmodified methods. (a) the FCE method, (b) the original FCS method, (c) the original HCS method.

原型 HCS 法に適応化と高速化の二つの改良を加えることで改良型 HCS 法が得られるが、それは改良型 FCS 法と同様にして得られるので詳細は省略する。

5. 実験と検討

5.1 実験結果

提案手法の有効性を検証するために評価実験を行った。使用計算機は三洋 MPS-020-03 である。

実験では、図 3 (a) に示す十和田湖パターンから輪郭点をランダムに間引きして作成した、図 3 (b) に示す画像をテスト画像に選んだ。画像サイズは 256×256 画素であり、そのエッジ点数は 179 点である。

図 4 (a), (b), (c) に、FCE 法、原型 FCS 法、原型 HCS 法による適用結果を示す。使用パラメータは、 $m=2$ (FCE 法, FCS 法), $c=20$, 収束判定値 $\epsilon=0.01$, $\alpha=0.9$ (FCE 法),

$$w = \begin{cases} 1 \text{ 画素} & (l < 10 \text{ 画素}) \\ 2 \text{ 画素} & (10 \text{ 画素} \leq l < 20 \text{ 画素}) \\ 3 \text{ 画素} & (20 \text{ 画素} \leq l) \end{cases}$$

である。これらの手法はクラスタ数 c の値に非常に敏感である。実際、 $c=10, 15, 25$ の場合についても実験を行ったが、適切な値 (この場合は $c=20$ 前後) を外れると線分近似結果はあまりよくない。これは、この種のクラスタ解析法の一般的傾向と言える。




図5 改良型 FCS 法による近似結果

Fig. 5 The results by the modified FCS method: (a) $\sigma_1 = \sigma_2 = 0.35$, (b) $\sigma_1 = \sigma_2 = 0.45$.




図6 改良型 HCS 法による近似結果

Fig. 6 The results by the modified HCS method: (a) $\sigma_1 = \sigma_2 = 0.35$, (b) $\sigma_1 = \sigma_2 = 0.45$.

次に、改良型 FCS 法の適用結果を図 5 に示す。初期クラスタ数を $c=3$ とし、しきい値 $\sigma_1 = \sigma_2 = 0.35$ の結果を図 5 (a) に、 $\sigma_1 = \sigma_2 = 0.45$ の結果を図 5 (b) に示す。その他のパラメータは図 4 と同様である。

同じく、改良型 HCS 法の適用結果を図 6 に示す。初期クラスタ数を $c=3$ とし、しきい値 $\sigma_1 = \sigma_2 = 0.35$ の結果を図 6 (a) に、 $\sigma_1 = \sigma_2 = 0.45$ の結果を図 6 (b) に示す。

これらの結果から、改良型 FCS 法と改良型 HCS 法では、それぞれの原型法に比べて、より適切な線分近似結果が得られていることがわかる。特に、短い線分が安定して検出されるようになってきている。これは適応化による効果である。また、一般に FCS 法は HCS 法よりも多くのエッジ点をまとめて、より長い線分として近似する傾向が強い。これはファジィ性の効果である。なお、実験では、行列 U の初期値はランダムに設定した。ファジィな場合、各 k ごとに区間 $[0,1]$ の一様乱数を c 個発生させ、正規化して $\{u_{ik}\}$ を得た。この方が、一様に $u_{ik} = 1/c$ とするよりも、一般に良い結果が得られた。

各手法の処理時間をまとめて表 1 に示す (但し、 $\sigma_1 = \sigma_2 = 0.35$ とする)。ここで、適応型とは原型 FCS 法または原型 HCS 法に適応化だけの改良を加えたものを言う (すなわち、高速化の改良は加えていない)。これから、高速化の効果は FCS 法において著しいことがわかる (約 10 倍の高速化である)。なお、適応型 FCS 法では線分

表1 処理時間の比較

	FCE法	原型 FCS法	原型 HCS法	適応型 FCS法	適応型 HCS法	改良型 FCS法	改良型 HCS法
c (線分数)	20	20	20	21	21	15	22
反復回数	21	31	13	355	111	213	109
処理時間 (秒)	91	69	21	909	99	101	85




図7 別の評価画像での近似結果

Fig. 7 The results for another pattern : (a) the input pattern to the test, (b) the result by the modified FCS method, (c) the result by the modified HCS method.

数が $c=21$ なのに対して、改良型 FCS 法では $c=15$ と減少している。一般に長い線分は前者では c の増加と共に短くなるが、後者では初期段階で長いまま検出されて固定されるために、 c はより小さい値にとどまりやすい。

また、別のテスト画像に対する適用結果を図7に示す。(a)のテスト画像はテレビカメラで入力し、微分処理と細線化処理を施した後、間引きを行って得たはさみの画像である(画像サイズ 512×512 画素)。初期クラスタ数 $c=3$ 、しきい値 $\sigma_1 = \sigma_2 = 0.45$ の条件下での改良型 FCS 法による適用結果を(b)に、同じく改良型 HCS 法による適用結果を(c)に示す。

以上から、提案手法(改良型 FCS 法と改良型 HCS 法)の有効性とアルゴリズムの正当性が一応示されたものと考えられる。

5.2 検討

(1) FCE法との比較

FCE法のクラスタ化基準 $J_{01} = (1-\alpha)J_0 + \alpha J_1$ では、 J_1 が主要な項であり、 J_0 はクラスタ間を分離させるための補助項として作用する。しかし、このような組合せで輪郭線を近似させることには無理がある。例えば、

重心から離れた直線上の点や近似2直線が近接する場合において J_0 は意味をもたなくなる。従って、複雑な形状に追従する能力は期待できない。また、近似結果が無限直線となることも、線分近似という立場では不都合である。これに対し、提案手法では線分に基づいた基準 J_s の採用により安定な線分近似が可能であり、近似結果も線分そのもので得られるので、FCE法よりは優れていると言えよう。評価実験の結果もこれらの主張を裏づけている。

(2) 提案手法の問題点

提案手法の利点は、ハフ変換に基づく線分近似手法と比較して、使用メモリ量が少ない、処理がパラメータ空間でなく画像空間で行えるので細かな工夫を加えやすい、などである。

逆に、提案手法の最大の問題点は耐雑音性にある。クラスタ化段階でエッジ点は近接する線分に統合されていくが、その際に該当する線分を形成しないエッジ点も統合される可能性がある。その結果、1本の線分の近傍に雑音としてのエッジ点が多数偏在する場合には、近似線分はかなり誤差の大きいものになる。また、二つの線分が平行して近接する場合には、これらは統

合されてしまい、2本の線分としては検出しがたい点も問題である。これらの問題はクラスタ解析に基づく手法に固有な問題と言えるが、その対策は今後の課題としたい。

また、本論文では、提案手法の原理的な可能性の検証を主目的としたので、検証に用いた実験画像も比較的簡単なもので済ませた。提案手法はまだ原理的な可能性を立証した段階にとどまっており、実用化のためには、実際の画像で評価実験を行って改良を加えていくことが必要である。

6. むすび

本論文では、輪郭線図形の線分近似手法として、線分との距離を分類基準に選んだクラスタ化手法に基づく方法を提案した。本手法は、(1)輪郭線が全く不連続な場合にも対処できる、(2)従来の FCE 法よりも安定した線分近似結果が得られる、などの特徴を有している。評価実験により提案手法の原理的な正当性と有効性は立証できたものと考えますが、まだ可能性を示しただけであり、今後検討すべき課題も多い。特に、雑音が多数存在する場合の線分検出力の向上、処理速度の更なる改善、などが挙げられる。

謝辞 評価実験に御協力頂いた本学工学部情報工学科相馬孝志技官に感謝する。

なお、本研究の一部は文部省科学研究費(一般研究(C))によることを付記する。

文 献

- (1) 高木幹雄, 鳥脇純一郎, 田村秀行編: “画像処理アルゴリズムの最新動向”, 新技術コミュニケーションズ(1986).
- (2) 渡辺孝志, 石戸橋真: “線分近似による一般化ハフ変換の高速化と任意図形検出”, 信学論(D-II), **J74-D-II**, 8, pp. 995-1003 (1991-08).
- (3) Ramer U. E.: “An iterative procedure for the polygonal approximation of plane curves”, *Comput. Vision, Graphics, & Image Process.*, 1, pp. 224-256 (1972).
- (4) Bezdek J. C.: “Pattern recognition with fuzzy objective functions”, Plenum, New York (1981).
- (5) Bezdek J. C., Coray C., Gunderson R. and Watson J. J.: “Detection and characterization of cluster substructure I. Linear structure: fuzzy c-lines”, *SIAM J. Appl. Math.*, **40**, 2, pp. 339-357 (1981).
- (6) Bezdek J. C., Coray C., Gunderson R. and Watson J. J.: “Detection and characterization of cluster substructure II. Fuzzy c-varieties and convex combinations thereof”, *SIAM J. Appl. Math.*, **40**, 2, pp. 358-372 (1981).
- (7) McKenzie D. S. and Protheroe S. R.: “Curve description using the inverse Hough transform”, *Pattern Recognition*, 23, 3/4, pp. 283-290 (1990).

- (8) Princen, J., Illingworth, J. and Kittler, J. “A hierarchical approach to line extraction based on the Hough transform”, *Comput. Vision, Graphics, & Image Process.*, 52, pp. 57-77 (1990).

(平成3年9月20日受付, 4年1月20日再受付)

渡辺 孝志



昭44東北大・工・通信卒。昭46同大大学院修士課程了。昭47(株)日立製作所入社。昭55東北大学院博士課程了。工博。同年岩手大・工・情報助手。現在、同助教授。この間、パターンの学習認識、集積回路のCADシステム、セル構造オートマトン、画像処理の研究に従事。情報処理学会、計測自動制御学会、日本リモートセンシング学会各会員。

鈴木 一也



平1岩手大・工・情報卒。平3同大大学院修士課程了。同年ソニー・マグネ・プロダクト(株)入社。在学中は画像処理の研究に従事。

丹波 澄雄



昭58岩手大・工・情報卒。昭60同大大学院修士課程了。同年同大・工・情報助手。この間、リモートセンシングの研究に従事。日本リモートセンシング学会、情報処理学会、計測自動制御学会、IEEE各会員。

横山 隆三



昭39東北大・工・電気卒。昭41同大大学院修士課程了。昭44ロチェスター大大学院博士課程了。Ph.D. 昭45東北大・工・電気助手。昭47岩手大・工・電子助教授。現在、同情報教授。この間、自動制御、システム工学、画像処理、リモートセンシングの研究に従事。情報処理学会、計測自動制御学会、日本ME学会、日本リモートセンシング学会、写真測量学会、日本地熱学会、IEEE各会員。