

平均場アニーリング法 (MFA) を用いた テクスチャ画像の領域分割

†阿南泰三, ‡工藤博幸, †斉藤恒雄

†筑波大学工学研究科, ‡筑波大学電子・情報工学系

本研究では統計的推定法によるテクスチャ画像のセグメンテーションを検討する。領域の連結性とテクスチャをマルコフ確率場でモデル化し、弛緩法を用いて各画素に対して最適なラベル付けを行う。弛緩法は平均場近似アニーリングという手法を適用する。

統計的推定法は画像モデルのパラメータが事前に与えられていなければセグメンテーションを行うことができないという問題がある。パラメータをサンプルデータなしに観測画像だけから推定することは非常に困難である。本論文では観測画像だけからパラメータ推定とセグメンテーションを行う手法について述べる。

Textured Image Segmentation Using Mean Field Annealing

†Taizo Anan, ‡Hiroyuki Kudo, and †Tsuneo Saito

† Doctoral Program in Engineering, University of Tsukuba

‡ Institute of Information Sciences and Electronics, University of Tsukuba

Tennoudai 1-1-1, Tsukuba 305, Japan

This paper proposes an unsupervised image segmentation algorithm. The framework of modeling the textured images by using the two level MRF and then applying the maximum a posteriori estimation for the image segmentation has been developed by various researchers. Their algorithms require that parameters of the models are known prior to the image segmentation. The purpose of this paper is to develop a segmentation algorithm, where the image model parameters are estimated from the observed image by using the expectation maximization (EM) algorithm and the segmentation is performed by using a relaxation algorithm called Mean Field Annealing.

1. まえがき

近年、コンピュータによる画像認識の研究が盛んになっている。画像認識を行う場合には、まず画像から対象物領域を抽出する必要がある。このための手法は画像のセグメンテーションと呼ばれている。セグメンテーションには領域の平均的な明るさのみを用いる手法と明るさの空間的变化パターン(テクスチャー)を用いる手法の二つがある。後者の問題はテクスチャー・セグメンテーションと呼ばれており、航空写真、レーダ画像、超音波画像などの処理に応用できる重要な問題である。従来、ヒューリスティックなテクスチャー・セグメンテーション手法が数多く検討されてきたがこれらの手法では不十分な場合が多く、より数学的に厳密な統計的推定法の考え方に基づく手法が検討されてきている。本研究では、統計的推定の考え方に基づくテクスチャー・セグメンテーション手法を検討する。領域の連結性に関する先験的知識を表現するため、多値マルコフ確率場(MRF)を採用する。また、テクスチャーはガウス・マルコフ確率場(GMRF)を用いてモデル化する。セグメンテーションは各画素に事後確率を最大にするラベルを付加することによって行う。この定式化においては、セグメンテーションは組合せ最適化問題となり、有効な最適化手法が必要である。本研究では比較的少ない計算量で妥当な解が得られる弛緩法を採用する。従来、この種の問題に用いる弛緩法としてICM(Iterative Conditional Mode)とSA(Simulated Annealing)が提案されている。しかし、ICMは評価関数の局所的な最小解にトラップされやすく、SAは計算量が多いという問題がある。本研究ではICMとSAの長所を兼ね備えた手法として平均場アニーリング(MFA)に基づくセグメンテーション手法を提案する。

統計的推定法に基づくセグメンテーション手法の大きな問題がモデル・パラメータの推定である。観測画像が与えられていてかつ、各テクスチャーが存在する領域が既知であればテクスチャーのパラメータは最尤(ML)推定によって容易に得ることができる。しかし、現実の問題としてほとんど多くの場合、与えられるのは観測画像のみである。この場合、領域モデルとテクスチャー・モデルの両方のパラメータを自動的に推定し、セグメンテーションを行うのは非常に困難である。本研究ではEMアルゴリズムを用いてパラメータ推定とセグメンテーションを同時に行う手法を提案する。

2. MAP推定によるセグメンテーション

事後確率最大(MAP)推定の考え方に基づけば、テクスチャー・セグメンテーションは次のように定式化できる。 Ω を2次元平面上の $M \times M$ の格子とする($\Omega = \{(i, j), 1 \leq i, j \leq M\}$)。 Ω 上の位置を $r = (i, j)^T, r \in \Omega$ で表す。また観測画像の各画素の画素値(グレイレベル)を y_r 、テクスチャーラベルを $s_r = e_k$ ($k = 0, 1, 2, \dots, M-1$)とする。但し e_k は k 番目の成分が1でその他の成分は0の列ベクトルである($e_1 = [1, 0, 0, \dots, 0]^T$)。観測画像 $Y = \{y_r\}$ が与えられたとき、最も確からしいラベル $S = \{s_r\}$ を求める問題がセグメンテーションである。MAP推定では次の評価関数を最大にするラベル S を最適

解として求める。

$$P(S|Y) = \frac{P(S)P(Y|S)}{P(Y)} \quad (1)$$

ここで $P(S)$ はラベルに関する先験的知識を表し、事前確率と呼ばれる。領域を離散マルコフ確率場によりモデル化すれば、着目する画素 r の二次の対象な近傍の画素の集合を N_r とすれば $P(S)$ は次の条件付き確率によって決定される。

$$p^{reg}(s_r = e_k | s_v, v \in N_r) = \frac{1}{Z} \exp[-U^{reg}(s_r = e_k | s_v, v \in N_r)] \quad (2)$$

$$Z = \sum_{k=0}^{M-1} \exp[-U^{reg}(s_r = e_k | s_v, v \in N_r)] \quad (3)$$

$$U^{reg}(s_r | s_v, v \in N_r) = -\beta \sum_{v \in N_r} V(s_r | s_v) = -\beta N(s_r | s_v, v \in N_r) \quad (\beta > 0) \quad (4)$$

$$V(s_r | s_v) = \begin{cases} 1 & s_r = s_v \\ 0 & s_r \neq s_v \end{cases} \quad (5)$$

但し、 β は領域の連結性を制御するパラメータである。一方、 $P(Y|S)$ は S を与えたとき、 Y が観測される確率を表す。テクスチャーをGMRFでモデル化すれば、 $P(Y|S)$ は次の条件付き確率によって決定される。

$$p^{lex}(y_r | y_v, v \in N_r, s_r = e_k) = \frac{1}{\sqrt{2\pi\sigma^2}(s_r)} \exp\left[-\{y_r - \sum_{v \in N_r} c_v(s_r)y_v\}^2 / 2\sigma^2(s_r)\right] \quad (6)$$

但し、 c_v は画素間の相関を表す係数、 σ^2 は確率場を駆動する雑音の分散である。

3. MFAによる最適化

ICMとSAの長所を兼ね備えた手法としてMFA(Mean Field Annealing)によるセグメンテーション・アルゴリズムを提案する。MFAはSAを決定論的に近似する最適化法であり、以下の原理に基づいている。

式(1)を次のように書き換える。

$$P(S|Y) = \frac{1}{Z} \exp(-U(S|Y)) \quad (7)$$

ここで $U(S|Y)$ は S が最適解のとき最小値をとる関数である。MFAでは温度パラメータ T を導入した次の確率密度関数を考える。

$$P_T(S|Y) = \frac{1}{Z} \exp(-U(S|Y)/T) \quad (8)$$

$P_T(S | Y)$ は $T \rightarrow 0$ の極限において、

$$P_T(S | Y) = \begin{cases} 1 & \text{if } L \text{ is optimum;} \\ 0 & \text{otherwise.} \end{cases} \quad (9)$$

となる。従って T を十分小さい値にしたときの確率密度 $P_T(S)$ のサンプルを求めれば $U(S)$ を最小とする S となっている。確率密度 $P_T(S)$ に関する S の平均値を $\langle S \rangle$ とする。平均値の定義から、

$$\langle S \rangle = \sum_S S P_T(S | Y) \quad (10)$$

である。 $T \rightarrow 0$ の極限において、明らかに $\langle S \rangle$ と $U(S)$ を最小とする S は一致する。従って T を十分小さい値にして $\langle S \rangle$ を求めれば、 $U(S)$ を最小とする S となっている。 $\langle S \rangle$ は以下のようにして求めることができる。今、仮に各画素毎のラベルの生起確率を $p(s_r)$ として式 (8) の結合確率密度を次のように近似する。

$$P_T(S | Y) \doteq \prod_r p(s_r) \quad (11)$$

この近似と式 (8) の結合確率密度関数との類似性を調べるため、Kullback の情報量を用いて次の評価関数を定義する。

$$H = \sum_{s_1} \sum_{s_2} \cdots \sum_{s_N} \prod_r p(s_r) \times \log \frac{\prod_r p(s_r)}{P_T(S | Y)} \quad (12)$$

subject to

$$\sum_{s_r} p(s_r) = 1 \quad (13)$$

式 (12) は $\prod_r p(s_r)$ の近似が $P(S | Y)$ に近づくほど大きくなる。このことは式 (12) が増大する方向に各画素に対して適当な操作を施せば求める確率分布、つまりセグメンテーションを解が正しくなる方向に行うことができるということの意味している。式 (12) を最大化するために、画像をラスタ走査して各画素 s_r において $p(s_r)$ 以外の確率を現在の値に固定し、 $p(s_r)$ を式 (12) が最大になるように更新する。但し、式 (13) の拘束条件を考慮に入れて式 (12) を次のように書き換える。

$$H_2 = \sum_{s_1} \sum_{s_2} \cdots \sum_{s_N} \prod_r p(s_r) \times \log \frac{\prod_r p(s_r)}{P_T(S | Y)} + \lambda \left(\sum_{s_r} p(s_r) - 1 \right) \quad (14)$$

H_2 を最大にする各 $p(s_r)$ は次式で得られる。

$$\frac{\partial H_2}{\partial p(s_r = e_k)} = 0 \quad (15)$$

よって

$$\begin{aligned} \frac{\partial H_2}{\partial p(s_r = e_k)} &= \log p(s_r = e_k) \\ &- \sum_{s_1} \cdots \sum_{s_{i-1}} \sum_{s_{i+1}} \cdots \sum_{s_N} p(s_1) \cdots \\ &p(s_{i-1}) p(s_{i+1}) \cdots p(s_N) \\ &\times \log P_T(S; s_r = e_k | Y) \\ &+ F(\lambda) = 0 \end{aligned} \quad (16)$$

式 (16) の右辺第二項は $\log P_T(S; s_r = e_k | Y)$ の期待値であり、 F は s_r とは独立な関数である。式 (16) より $p(s_r = e_k)$ は次式で与えられる。

$$p(s_r = e_k) = \exp(-F(\lambda)) \exp E[\log P_T(S; s_r = e_k | Y)] \quad (17)$$

式 (17) の右辺の第一項はラグランジュの未定係数であり、拘束条件を満たすように決めると次式のようにになる。

$$\exp(-F(\lambda)) = \sum_{k=0}^{M-1} \exp(E[\log P_T(S; s_r = e_k | Y)]) \quad (18)$$

よって式 (12) を最大にする $p(s_r)$ は次式で与えれば良い。

$$p(s_r = e_k) = \frac{1}{\sum_{k=0}^{M-1} \exp E[\log P_T(S; s_r = e_k | Y)]} \times \exp E[\log P_T(S; s_r = e_k | Y)] \quad (19)$$

以上により、各画素 s_r がラベル e_k を持つ確率を反復的に求めることによりセグメンテーションを、目指す確率分布 $P_T(S | Y)$ に近づけることができるということが示された。また、 MFA は温度パラメータ T を適当に操作することによって評価関数の局所的解にトラップされにくいという利点をもっている。式 (12) を次のように変形して

$$H = \sum_r \sum_{s_r} p(s_r) \log p(s_r) - \sum_{s_1} \cdots \sum_{s_N} \prod_r p(s_r) \log P_T(S | Y) \quad (20)$$

但し、

$$\log P_T(S | Y) = -\frac{1}{T} U(S | Y) - const$$

ここで式 (20) の右辺第一項はエントロピーを示している。 T が大きくなると右辺第一項、つまりエントロピーは増大し、第二項は温度パラメータ T によって凹凸性が弱くなり解が局所的解にトラップされにくい。逆に T が小さくなるとエントロピーは減少し、第二項は凹凸性が強くなり最適解を求めるのは難しくなる。そこで最初は T を大きな値にセットして徐々に温度を下げながら解を求めることによって局所的解

を極力避けようとするのが *MFA* の戦略である。以上のように *MFA* は *SA* よりも収束が速く *ICM* よりも局所的解にトラップされにくいという利点をもっている。*MFA* は特に画像のような組合せ最適化問題に適した手法であると思われる。

4. パラメータ推定

以前に述べたように統計的な手法による画像のセグメンテーションは画像をある確率モデルで代表させる。ところが一般にその確率モデルは1~複数のパラメータを含んでおり、そのパラメータの値を知ることが必要である。複数のテキストチャータからなる画像をセグメントするにはまず、それぞれのテキストチャータのパラメータの値を知る必要がある。一つの方法として、それぞれのテキストチャータのサンプルデータからパラメータを推定する方法がある。それが与えられない場合は最適なセグメンテーションの結果が必要になる。例えばタイプ1のテキストチャータのパラメータの値が知りたいときにはセグメントされた画像からタイプ1のテキストチャータから構成されている領域からデータをサンプリングすればよい。このように統計的推定による手法を用いた場合、サンプルデータが与えられないときは、セグメントするために確率モデルのパラメータが必要となり、パラメータを推定するためにはセグメントされた画像が必要になる。実際に実世界の画像からはサンプルデータを得ることが困難で、観測画像のみからパラメータとセグメンテーションをおこなう手法が必要になると思われる。そこで本研究では *EM* アルゴリズムに基づいた手法を提案し、この問題の解決を試みる。まず最初にサンプルデータからテキストチャータのパラメータを推定する方法について述べ、次に観測画像のみからパラメータを推定する *EM* アルゴリズムと本研究でのそのインプリメントについて述べる。

< 1 > サンプルデータが与えられた場合

観測画像 Y が一種類のテキストチャータから構成されているとき、パラメータ推定は *ML* (Maximum Likelihood) 推定により次のように定式化できる。いま、未知パラメータの集合を θ とすると、 θ を与えたもとの Y が観測される条件付き確率 $P(Y | \theta)$ を定義する。このとき次式を満足する θ をパラメータの推定値であるとする。

$$\theta_{ML} = \underset{\theta}{\operatorname{argmax}} P(Y | \theta) \quad (21)$$

式(21)を数学的に解くことは困難なことが知られている。しかし、いくつかの近似解法が知られている。本論文では *Besag* の最大擬似尤度 (*MP L*) 法を用いる。*MP L* 法では $P(Y | \theta)$ を次のように近似する。

$$P(Y | \theta) \doteq \prod_{\tau} p^{\operatorname{ex}}(y_{\tau} | y_v, v \in N_{\tau}, \theta) \quad (22)$$

式(22)の対数を各々のパラメータについて偏微分したものをゼロとおくことによって、パラメータの推定値を得ることができる。

< 2 > 観測画像からパラメータを推定する場合

ML 推定でパラメータを推定するためには観測画像のセグメンテーション S が与えられていなければならない。セグメンテーション S が未知の場合、パラメータを推定するのは困難である。このような不完全データから *ML* 推定を使ってパラメータを推定するための反復アルゴリズムが期待値最大化 (*EM*) アルゴリズムである。*EM* アルゴリズムは次の二つのステップからなっている。

$$\begin{aligned} [E - \text{step}] : & Q(\theta_H, \theta_L | \theta_H^k, \theta_L^k) = \\ & E[\log P(L, \theta_H) + \log P(Y | L, \theta_L) | Y, \theta_H^k, \theta_L^k] \\ [M - \text{step}] : & (\theta_H^{k+1}, \theta_L^{k+1}) \\ & = \underset{\theta_H, \theta_L}{\operatorname{argmax}} Q(\theta_H, \theta_L | \theta_H^k, \theta_L^k) \quad (23) \end{aligned}$$

ここで k は反復回数を表す。また、 $E[\cdot]$ は条件付き期待値を表している。*E-step* で計算した $Q(\cdot)$ を *M-step* でこれを最大にするパラメータを定めることによって求めるパラメータを得ることができる。*EM* アルゴリズムの解は少なくとも局所的最適解に収束することが証明されている。

EM アルゴリズムの [*E-step*] は定義から次のようになる。

$$\begin{aligned} Q(\theta_H, \theta_L) \\ = \sum_S P(S | Y, \theta_H^k, \theta_L^k) \\ \times [\log P(S | \theta_H) + \log P(Y | S, \theta_L)] \quad (24) \end{aligned}$$

式(24)は全ての可能なラベルの組合せについて考慮しなければならないので、計算量は膨大である。よって次の近似式を用いる。

$$P(S) \doteq \prod_{\tau} p^{\operatorname{eg}}(s_{\tau} | s_v, v \in N_{\tau}) \quad (25)$$

また、*MFA* を行うことによって得られる各画素毎のラベルの生起確率 $P(s_{\tau} | Y)$ を用いることによって、事後確率 $P(S | Y)$ を次の近似式で与える。

$$P(S | Y) \doteq \prod_{\tau} p(s_{\tau} | Y) \quad (26)$$

式(5)で示されるように領域の連結性をあわす事前確率 $p^{\operatorname{eg}}(s_{\tau} | s_v)$ は着目する画素 τ とその周りの 8 近傍の画素が $0, 1, \dots, M-1$ の離散値のクリस्पなラベルで決定されていなければならない。ところが以前に述べたように *MFA* はラベルそのものを更新するのではなくラベルの生起確率を反復的に更新する手法であるため、確率的にしかラベルの値を知ることができない。つまり式(5)を計算できないという問題が起こってくる。ゆえに *E-Step* の期待値を厳密に得るためには (i, j) を中心とした 3×3 の格子の全てのとりうるラベルパターンについて式(4)の $N(\cdot)$ を以下に述べるように計算をしなければならない。

$$\begin{aligned} N^{MFA}(s_{\tau} = e_k | s_v, v \in N_{\tau}) \\ = \sum_{l_{\tau}} \prod_{v \in N_{\tau}} p(s_v | Y) N(s_{\tau} = e_k | s_v, v \in N_{\tau}) \quad (27) \end{aligned}$$

但し、ここで l_p は近傍 N_r 全てのとりうるラベルの組合せについて示している。式 (23) より $E - Step$ は次式で与えられる。

$$\sum_r \sum_{k=0}^{M-1} p(s_r = e_k | Y, \theta_h^k, \theta_l^k) \times \log \frac{\exp \beta N^m f^a(s_r = e_k | s_v, v \in N_r)}{\sum_{l=0}^{M-1} \exp \beta N^m f^a(e_l | s_v, v \in N_r)} \quad (28)$$

式 (28) を最大にする θ_H はそれについて偏微分したものを 0 とおくことによって求めることができる。具体的には

$$\sum_r \sum_{k=0}^{M-1} \left[p(s_r = e_k | Y) N^m f^a(s_r = e_k | s_v, v \in N_r) - p^{reg}(s_r = e_k | s_v, v \in N_r) \times N^m f^a(s_r = e_k | s_v, v \in N_r) \right] = 0 \quad (29)$$

式 (29) を最急降下法で解けばパラメータを求めることができる。式 (27) は近傍 N_r を二次のオーダーで考えると着目する画素の周りの 8 画素の全てのラベルパターンの組合せについて計算が必要である。つまり $(M-1)^8$ 通りもの膨大な計算をしなければならない。そこで本研究では次の近似式を与える。

$$N^m f^a'(s_r = e_k | s_v, v \in N_r) = \sum_{v \in N_r} 1 \times p(s_v = e_k | Y) \quad (30)$$

式 (30) は 8 画素のラベルパターンについて $(M-1)$ 種類の組合せだけについて計算すればよいので式 (27) に比べて大幅な計算量の節約が可能になる。式 (28) と同様に $E - Step$ は次式で与えられる。

$$\sum_r \sum_{k=0}^{M-1} p(s_r = e_k | Y, \theta_h^k, \theta_l^k) \times \log \frac{\exp \beta N^m f^a'(s_r = e_k | s_v, v \in N_r)}{\sum_{l=0}^{M-1} \exp \beta N^m f^a'(e_l | s_v, v \in N_r)} \quad (31)$$

式 (31) を最大にする θ_H はそれについて偏微分したものを 0 とおくことによって求めることができる。具体的には

$$\sum_r \sum_{k=0}^{M-1} \left[p(s_r = e_k | Y) N^m f^a'(s_r = e_k | s_v, v \in N_r) - p^{reg}(s_r = e_k | s_v, v \in N_r) \times N^m f^a'(s_r = e_k | s_v, v \in N_r) \right] = 0 \quad (32)$$

同様に式 (22) と式 (26) の擬似尤度を用いることによって式 (23) の第二項の $E[\log P(Y | S, \theta_L)]$

, θ_H^k, θ_L^k は次式で与えられる。

$$\sum_r \sum_{k=0}^{M-1} p(s_r = e_k | Y, \theta_H^k, \theta_L^k) \times \log P(y_r | y_v, v \in N_r, \theta_L) \quad (33)$$

式 (33) をパラメータ θ_L について偏微分したものをゼロとおくことによってそのパラメータを求めることができる。

以上により EM アルゴリズムによるパラメータとセグメンテーションの同時推定が可能になる。以下にその手順を示す。

- (1) テクスチャーについてその初期パラメータを与える。
- (2) (1) のパラメータを基に ML 推定によりセグメンテーションを行う。
- (3) (2) の結果から領域のパラメータ β を式 (29)、または式 (31) から推定し、あわせてテクスチャーのパラメータを更新する。
- (4) 再びセグメンテーションを行う。
- (5) 収束判定を行う。収束していなければ各パラメータを更新し、(4) に戻る。

5. シミュレーション実験

本論文の手法を用いてシミュレーション実験を行った。離散マルコフ確率場とガウス・マルコフ確率場のパラメータを表 1, 2 に示すように与え、ギブス・サンプラーを用いてセグメンテーション対象画像を作成した (図 1、図 2)。この対象画像を用いて本論文で述べたパラメータとセグメンテーションの同時推定を行った。以下にその結果を示す。

< 1 > EM アルゴリズム__1 (式 (28)) の実験結果

全てのラベル・パターンの組合せを考えた EM アルゴリズムの結果を表 1、グラフ 1 に示す。表 1 からテクスチャーのパラメータ (c, σ) はほぼ正確に推定できていることがわかる。領域の連結性を表すパラメータ (β) の推定値は若干、真の値よりも小さくなっている。これは EM アルゴリズムの局所解に解が収束した為だと考えられる。また、領域の連結性を表すパラメータは収束に多大な反復回数と膨大な時間を要することが明らかになった。収束を速めるためのなんらかの手法の開発が必要である。次の章でこの手法について検討してみる。

< 2 > EM アルゴリズム__2 (式 (31)) の実験結果

実験結果をグラフ 2 に示す。グラフ 2 からわかるように領域のパラメータ β は収束せずに発散してしまうことがわかる。これは式 (30) の近似があまり正確でないことが原因であるとおもわれる。

6. 改良 EM アルゴリズム

実験結果で述べたように式 (28) を用いた EM アルゴリズムは計算量が膨大な上に収束に多大な反復回数を必要とし実用的ではない。そこで次に述べる改良を加える。まず第一に式 (28) の計算量を削減する必要がある。式 (28) は着目する画素の周りの 3×3 の格子の全てのラベルパターンの組合せについて計算している。ところがグラフ 3、4 のように領域のパラメータ β が大きいときにはある特定のラベルパター

ンの生起確率が非常に大きくなり、他は小さくなる傾向にある。そこで領域のパラメータ β が大きいときはラベルパターンの生起確率を大きい順にソーティングして、確率の大きいラベルパターンについてだけ式(28)を計算して確率の小さいところは計算しなればよい。

しかし β が小さいときには各ラベルパターン毎の生起確率は一樣になる傾向があるのでソーティングを行っても無駄である。しかし β の初期値を大きく正解に近いものが与えられればソーティングは有効であると思われる。ところが β の初期値をどのように与えるかという問題が起ってくる。やみくもに大きい β を初期値として与えても計算量がいたずらに増えるだけである。なるべく正しい解に近い初期値を与えればその分収束も速まることが予想される。そこで式(6)、つまりテクスチャーの評価関数に改良を加える。着目する画素 $r = (i, j)^T$ の周りの $k \times k$ のウィンドウ W_r を考えて

$$P_r^{lex}(y_r | W_r, s_r) = \frac{1}{Z_r^{lex}} \exp[-U_r^{lex}(y_r | W_r, s_r)] \quad (34)$$

$$U_r^{lex}(y_r | W_r, s_r) = \frac{1}{2\sigma(s_r)^2} \sum_{r \in W_r} \{y_r^2 - \sum_{v \in N_r} c_v y_r y_v\} \quad (35)$$

$$Z_r^{lex} = (2\pi\sigma^2)^{\frac{k^2-1}{2}} |B|^{-\frac{1}{2}} \quad (36)$$

行列式 $|B|$ は求めるのは困難なので次の近似を与える。

$$|B| = \prod_{i=0}^{k-1} \prod_{j=0}^{k-1} \left[1 - 2 \sum_{(l,m) \in N^*} c_v \cos\left(\frac{2\pi}{M}li + \frac{2\pi}{N}mj\right) \right] \quad (37)$$

但し、

$$N^* = \{(1,0), (0,1), (1,1), (1,-1)\} \quad (38)$$

式(6)は着目する画素 r のラベルを決定するとき、 r の近傍の8画素だけを見て判断を下している。よって領域のパラメータ β が十分に大きくないときは誤認識も多くなり、セグメンテーション結果も穴が多数空く。ここから β を推定すれば当然その値は小さくなる。ところが式(34)は着目する画素の周りにウィンドウを設定してウィンドウ内の画素についても情報を得るので β が小さいときにもセグメンテーションは比較的うまくいく。ウィンドウを大きく設定してセグメンテーションをおこなうと穴が空かないので、それから β を推定すると大きな(比較的正解に近い)値をとることがわかる。しかしやみくもにウィンドウを大きくすると画像内の小さな領域は潰されて正確にセグメンテーションがおこなわれない危険がある。そこで最初はウィンドウを大きな値にセットして徐々にウィンドウを小さい値にしながらパラメータとセグメンテーションの同時推定を行えば反復回数を少なくできるものと思われる。その上 β の値は常に大き

な値にセットされるので、前に述べたようにある特定のラベルパターンだけが大きな生起確率をとるので一反復内の計算量も大幅に減らすことが可能になる。

7. シミュレーション実験2

改良したEMアルゴリズムを用いてシミュレーション実験を行った。結果を表2、グラフ5に示す。またセグメンテーション結果を図3に示す。グラフ5に示すように改良EMアルゴリズムは改良前に比べて大幅に収束が速くなっていることがわかる。反復回数は半分以下になっていることがわかる。

8. まとめと今後の課題

本研究では統計的推定の考えに基づくパラメータとセグメンテーションの同時推定法について検討した。そしてEMアルゴリズムに基づいた確率モデルのパラメータ推定とMFAに基づいたセグメンテーションの同時推定法について提案し、この手法が有効であることを示した。またテクスチャーの評価関数にウィンドウを導入することによってEMアルゴリズムの収束を速めることができることを示した。

今後の課題として次の3つを検討する必要がある。1つめはEMアルゴリズムによらないパラメータとセグメンテーションの同時推定法の開発である。EMアルゴリズムは一つのパラメータの推定値から次のパラメータを推定するためにセグメンテーションを $T=1$ まで行わなければならないので計算量がどうしても大きくなる。そこでアニーリングの過程でパラメータを推定する手法を用いることにより計算量を減らすことが可能になると考えられるが、これについては現在検討中である。2つめはテクスチャーのパラメータの初期値をどのように与えるかという問題である。現段階では適当に初期値を与えてあるのでこれについては今後検討を加えていきたい。そして3つめの課題として観測画像が幾つの領域から構成されるのかを判断するアルゴリズムの開発である。現段階では領域数は既知であるという前提のもとでセグメンテーション、及びパラメータ推定を行っているが、将来は完全な自動化を計りたい。

REFERENCES

- [1] H. Elliot and H. Derin, "Modelling and segmentation of noisy and textured image using Gibbs random fields," *IEEE Trans. Pattern Anal. Machine Intell.*, vol. PAMI-9, pp.39-55, Jan. 1987.
- [2] F.S.Cohen and D.B.Cooper, "Simple parallel hierarchical and relaxation algorithms for segmenting noncausal Markovian Random Fields," *IEEE Trans. Pattern Anal. Machine Intell.*, vol. PAMI-9, pp. 195-219, Mar. 1987.
- [3] B.S. Manjunath, T. Simchony, and R. Chelappa, "Stochastic and Deterministic Networks for Texture Segmentation," *IEEE Trans. Speech and Signal Processing*, vol. 38, No.6, pp.1039-1049, June. 1990.
- [4] J. Zhang, "The Mean Field Theory in EM procedures for Markov Random Fields," *IEEE Trans. Signal Processing*, vol.40, No.10, pp.2570-2583, Oct. 1992.




図1. 領域画像





図2. セグメンテーション対象画像

グラフ1. EMアルゴリズム_1 (beta=1.6)



グラフ2. EMアルゴリズム_2 (beta=1.6)





表1. EMアルゴリズム_1による各パラメータの推定値


texture_1	c(1,0)	c(0,1)	c(1,1)	c(-1,1)	σ
true	0.45	0.0	0.0	0.0	1.0
推定値	0.443	-1.20e-2	9.42e-3	-3.78e-3	1.01
texture_2	c(1,0)	c(0,1)	c(1,1)	c(-1,1)	σ
true	0.0	0.45	0.0	0.0	2.0
推定値	-2.93e-3	0.445	-1.90e-2	1.48e-2	2.02
texture_3	c(1,0)	c(0,1)	c(1,1)	c(-1,1)	σ
true	0.0	0.0	0.45	0.0	3.0
推定値	-1.03e-2	4.96e-3	0.447	-7.03e-3	3.1

領域のパラメータ β	β
true	1.6
推定値	1.43

グラフ3. 生起確率の分布(beta=0)



グラフ4. 生起確率の分布(beta=1.6)



グラフ5. 改良EMアルゴリズム(beta=1.6)





図3. セグメンテーション結果

表2. 改良EMアルゴリズムによる各パラメータの推定値

texture_1	c(1,0)	c(0,1)	c(1,1)	c(-1,1)	σ
true	0.45	0.0	0.0	0.0	1.0
推定値	0.453	2.86e-3	-1.46e-3	-3.97e-3	0.99
texture_2	c(1,0)	c(0,1)	c(1,1)	c(-1,1)	σ
true	0.0	0.45	0.0	0.0	2.0
推定値	1.03e-3	0.441	-8.81e-3	-6.86e-3	1.99
texture_3	c(1,0)	c(0,1)	c(1,1)	c(-1,1)	σ
true	0.0	0.0	0.45	0.0	3.0
推定値	-1.75e-2	1.30e-2	0.448	-7.70e-3	3.1

領域のパラメータ β	β
true	1.6
推定値	1.36