

## 回転変動を考慮した分離型2次元格子HMMによる顔画像認識

玉森 聡<sup>†</sup> 南角 吉彦<sup>†</sup> 徳田 恵一<sup>†</sup>

<sup>†</sup>名古屋工業大学 大学院工学研究科 〒466-8555 名古屋市昭和区御器所町

**あらまし** 画像認識においては認識対象の拡大縮小や回転といった幾何学的な変動に対応する必要がある。これまでに画像の横、縦方向の変動に対して頑健な確率モデルとして分離型2次元格子HMMが提案されている。分離型2次元格子HMMは横、縦方向で独立したマルコフ状態遷移を持ち、画像の位置や大きさの変動に対する正規化をモデル構造に含む。しかしながら、このモデル構造においては回転変動に対応することができず、認識精度が低下する問題を抱えていた。そこで本稿では分離型2次元格子HMMのモデル構造を拡張し、回転変動にも対応可能なモデル構造を提案する。また、変分EMアルゴリズムを用いた提案法の学習アルゴリズムを導出し、顔画像認識実験により提案法の有効性を示す。さらに、確定的アニーリングEMアルゴリズムを適用することにより、学習アルゴリズムの改善を図る。

**キーワード** 隠れマルコフモデル, 顔画像認識, 分離型2次元格子HMM, 確定的EMアルゴリズム

### Face recognition based on separable lattice 2-D HMM considering rotational variations

Akira TAMAMORI<sup>†</sup>, Yoshihiko NANKAKU<sup>†</sup>, and Keiichi TOKUDA<sup>†</sup>

<sup>†</sup> Dept. of Computer Science and Engineering, Nagoya Institute of Technology, Gokiso-cho, Syowa-ku,  
Nagoya, 466-8555, Japan

**Abstract** In image recognition systems, it needs to deal with geometrical variations of images such as size, location and rotation. Separable lattice 2-D hidden Markov Models (SL2D-HMMs) have been proposed as probabilistic models which are robust to variations in both horizontal and vertical directions. SL2D-HMMs have multiple Markov state transitions along with those directions and they perform an elastic matching between images and model parameters. However, SL2D-HMMs cannot deal with rotational variations which degrade the recognition performance. In this paper, we propose a model structure which can deal with rotational variations by extending SL2D-HMMs. We derive a training algorithm for the proposed model based on the variational EM algorithm and evaluate the effectiveness of the model in face recognition experiments. Moreover, we apply the Deterministic Annealing EM (DAEM) algorithm to improve the training algorithm.

**Key words** Hidden Markov Model, Face Recognition, Separable lattice 2-D HMMs, Deterministic Annealing EM algorithm

#### 1. ま え が き

画像認識はパターン認識における主要テーマの一つとして長年に渡り研究が重ねられ、さまざまな手法が提案されてきた。特に主成分分析など統計的な手法に基づくものは大きな成果を挙げている。しかしこれらの手法では学習やテストに用いる画像が位置や大きさの変動を含む場合、認識性能は大きく劣化するため、事前に画像を正規化する必要がある。これまで、多くの画像認識の研究ではこれら各種の正規化は前処理としてデータやタスクに依存したヒューリスティックな手法が用いられることが多かった。これに対し、画像の正規化をモデル構造に含む確率モデルとして分離型2次元格子HMM(Separable Lattice 2-D HMM) [1] が提案されている。分離型2次元格子HMMは

縦・横方向でそれぞれ状態系列を持ち、それぞれは独立に遷移可能であると仮定することにより、入力画像の縦・横方向の移動・伸縮に対して矩形を維持したまま対応可能となる。しかし分離型2次元格子HMMのモデル構造では、回転変動には対応できないという問題点を抱えていた。

本稿では回転変動を考慮した分離型2次元格子HMMのモデル構造について検討する。回転変動の場合、画像内における認識対象の傾きは一律と考えられるため、縦・横方向の状態の並びを一定方向にシフトさせればよい。そこで、画像内における状態位置の変動量を表現するHMMを縦・横方向それぞれ新たに導入する。これにより、従来の分離型2次元格子HMMに比較して回転変動も吸収可能となり、回転変動による認識精度の低下を軽減することが期待される。また、本稿で提案する

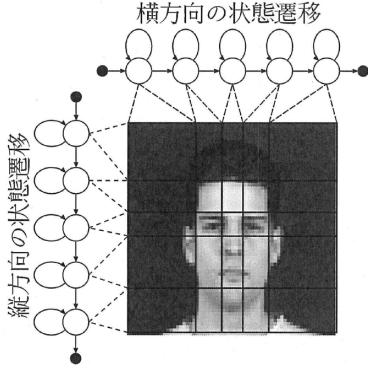


図1 分離型2次元格子HMM




図2 分離型2次元格子HMMのベイジアンネットワーク表現

モデルの学習には従来の分離型格子2次元HMM同様、変分近似に基づくEMアルゴリズム(変分EMアルゴリズム)を用いて計算量の削減を図る。さらに、確定的アニーリングEMアルゴリズム[2]を適用することにより、学習アルゴリズムの改善を図る。

## 2. 分離型2次元格子HMM

分離型格子HMMは2次元に拡張されたHMMの一種であり、状態系列の直積構造を用いることによって、多次元データのモデル化に有用な特性を保持しつつ、計算量を削減している。2次元における分離型格子HMMでは、矩形を維持しながら縦・横方向の伸縮が表現可能であることから、画像の位置や大きさの変動に対応することができる。分離型2次元格子HMMの構造とそのベイジアンネットワーク表現を、それぞれ図1, 2に示す。また、尤度関数を次式に示す。

$$\begin{aligned}
 P(\mathbf{O}, \mathbf{S} | \Lambda) &= P(\mathbf{O} | \mathbf{S}, \Lambda) \prod_{m=1}^2 P(\mathbf{S}^{(m)} | \Lambda) \\
 &= \prod_t P(\mathbf{O}_t | \mathbf{S}_t, \Lambda)
 \end{aligned} \quad (1)$$

$$\times \prod_{m=1}^2 \left[ P(\mathbf{S}_1^{(m)} | \Lambda) \prod_{t^{(m)}=2}^{T^{(m)}} P(\mathbf{S}_{t^{(m)}}^{(m)} | \mathbf{S}_{t^{(m)}-1}^{(m)}, \Lambda) \right] \quad (2)$$

ここで、 $\Lambda$ はモデルパラメータ、 $\mathbf{O} = \{\mathbf{O}_t | t = (t^{(1)}, t^{(2)})\}$ は2次元観測データ、 $\mathbf{S} = \{\mathbf{S}^{(1)}, \mathbf{S}^{(2)}\}$ は状態遷移を表す隠れ変数をそれぞれ表す。また、 $\mathbf{S}_{t^{(m)}}^{(m)} \in \{1, \dots, K^{(m)}\}$ は、 $m$ 次元方向のマルコフ連鎖 $\mathbf{S}^{(m)}$ における $t^{(m)}$ の状態を表す変数であり、 $K^{(m)}$ は状態数を表す。

## 3. 回転変動を考慮した分離型2次元HMM

2次元HMMを用いた画像のモデル化においては、状態遷移確率に制約がない場合、どの画素にどの状態を割り当てるかは本質的に自由である。しかし、画像の連続性などを考慮すると、この割り当てにある程度の制約を加える必要がある。分離型2次元格子HMMはleft-to-right(top-to-bottom)型の状態遷移を仮定するとき、状態の割り当てを矩形状にすることが可能である。これにより、対象の位置や大きさの変動を吸収することができる。しかし、このモデル化は認識対象が回転変動をしないことを仮定している。したがって、回転変動を加えた画像を与えられた場合画素と状態の対応関係が崩れ、認識精度の低下を招く。

本稿では、回転変動にも対応可能となるように、分離型2次元格子HMMのモデル構造を拡張する。図2に示した分離型格子2次元HMMのベイジアンネットワーク表現において、同一横(縦)座標に注目するとき、全て縦(横)方向に同一の状態が並んでいた。これに対し、本研究では矩形状の割り当てを緩める意味で、画像中における状態の位置をシフトさせる。このときのシフト量はHMMを用いてモデル化を行う。以降、本手法を提案法と呼ぶ。

提案法における尤度関数を次式で定義する。

$$P(\mathbf{O} | \Lambda) = \sum_{\mathbf{S}} \sum_{\mathbf{d}} P(\mathbf{O}, \mathbf{S}, \mathbf{d} | \Lambda) \quad (3)$$

$$\begin{aligned}
 P(\mathbf{O}, \mathbf{S}, \mathbf{d} | \Lambda) &= P(\mathbf{O} | \mathbf{S}, \mathbf{d}, \Lambda) P(\mathbf{S} | \Lambda) P(\mathbf{d} | \Lambda) \\
 &= \prod_{t^{(1)}, t^{(2)}} P(\mathbf{O}_{t^{(1)}, t^{(2)}} | \mathbf{S}_{t^{(1)}}, \mathbf{d}_{t^{(2)}}^{(1)}, \mathbf{d}_{t^{(1)}}^{(2)}, \Lambda) \\
 &\quad \times \prod_m P(\mathbf{S}^{(m)} | \Lambda) \cdot \prod_m P(\mathbf{d}^{(m)} | \Lambda) \quad (4)
 \end{aligned}$$

$$P(\mathbf{S}^{(m)} | \Lambda) = P(\mathbf{S}_1^{(m)} | \Lambda) \prod_{t^{(m)}=2}^{T^{(m)}} P(\mathbf{S}_{t^{(m)}}^{(m)} | \mathbf{S}_{t^{(m)}-1}^{(m)}, \Lambda) \quad (5)$$

$$P(\mathbf{d}^{(m)} | \Lambda) = P(\mathbf{d}_1^{(m)} | \Lambda) \prod_{t^{(n)}=2}^{T^{(n)}} P(\mathbf{d}_{t^{(n)}}^{(n)} | \mathbf{d}_{t^{(n)}-1}^{(n)}, \Lambda) \quad (6)$$

ここで新たに導入した変数 $\mathbf{d}$ について説明する。本稿では状態位置変動量を $\mathbf{d}$ と表し、 $\mathbf{S}$ 同様に次元間で独立なマルコフ連鎖とする：

$$\mathbf{d} = \{\mathbf{d}^{(1)}, \mathbf{d}^{(2)}\} \quad (7)$$

$$\mathbf{d}^{(m)} = \{\mathbf{d}_1^{(m)}, \mathbf{d}_2^{(m)}, \dots, \mathbf{d}_{T^{(m)}}^{(m)}\} \quad (8)$$




図3 提案法のベイジアンネットワーク表現

$$d_{t(n)}^{(m)} \in \{D_{min}^{(m)}, D_{min}^{(m)} + 1, \dots, D_{max}^{(m)}\}, n \neq m \quad (9)$$

ただし  $D_{min}^{(m)}$  は第  $m$  次元における最小シフト量を表し、 $D_{max}^{(m)}$  は第  $m$  次元における最大シフト量を表す。提案法ではこの  $d$  を用いて  $S_t$  を次のように表す。

$$S_t = \left( S_{t^{(1)}+d_{t(1)}^{(1)}}^{(1)}, S_{t^{(2)}+d_{t(1)}^{(2)}}^{(2)} \right) \quad (10)$$

このとき  $d_{t(1)}^{(2)}$ ,  $d_{t(2)}^{(1)}$  の値によって  $t^{(1)} + d_{t(1)}^{(1)}$ ,  $t^{(2)} + d_{t(1)}^{(2)}$  が  $T$  の領域を超えてしまう事態が発生するため、以下の境界条件を設ける。

$$\begin{cases} S_{t^{(m)}}^{(m)} = 1 & (t^{(m)} \leq 0) \\ S_{t^{(m)}}^{(m)} = K^{(m)} & (t^{(m)} > T^{(m)}) \end{cases} \quad (11)$$

提案法のモデル構造とベイジアンネットワーク表現を、それぞれ図3, 4に示す。ただし図4(a)は従来法のモデル構造を表している。また同図(b)は提案法のモデル構造を表しており、提案法は従来法のモデル構造にシフト状態遷移を追加したモデル構造となっていることが分かる。

提案法のモデルパラメータは次式で表される。

$$\Lambda = \{\Lambda_S^{(1)}, \Lambda_S^{(2)}, \Lambda_d^{(1)}, \Lambda_d^{(2)}, \mathbf{B}\} \quad (12)$$

$$\Lambda_S^{(m)} = \{\Pi_S^{(m)}, A_S^{(m)}\} \quad (13)$$

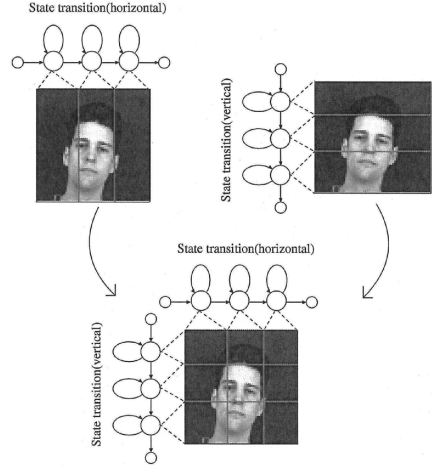
$$\Lambda_d^{(m)} = \{\Pi_d^{(m)}, A_d^{(m)}\} \quad (14)$$

また、モデルパラメータの各要素は以下のように定義される。

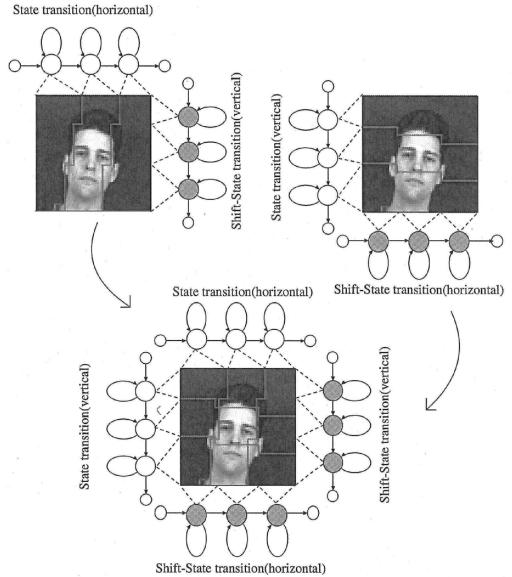
• 分離型2次元格子HMMの状態遷移に関するパラメータ:  $\Lambda_S^{(m)}$

1) 初期状態確率  $\Pi_S^{(m)} = \{\pi_{S,i}^{(m)} | 1 \leq i \leq K^{(m)}\}$ :  
 $\pi_{S,i}^{(m)} = P(S_1^{(m)} = i | \Lambda)$  は、観測  $O$  に関する第  $m$  次元の状態系列において、時刻(座標)  $t^{(m)} = 1$  における状態が  $i$  である確率を表す。

2) 状態遷移確率  $A_S^{(m)} = \{a_{S,ij}^{(m)} | 1 \leq i, j \leq K^{(m)}\}$ :  
 $a_{S,ij}^{(m)} = P(S_{t^{(m)}}^{(m)} = j | S_{t^{(m)}-1}^{(m)} = i, \Lambda)$  は、観測  $O$  に関する第



(a) 分離型2次元格子HMM



(b) 回転変動を考慮した分離型2次元格子HMM

図4 従来法と提案法のモデル構造の比較

$m$  次元の状態系列において、状態  $i$  から状態  $j$  に遷移する確率を表す。

• シフト状態遷移に関するパラメータ:  $\Lambda_d^{(m)}$

1) 初期状態確率  $\Pi_d^{(m)} = \{\pi_{d,i}^{(m)} | 1 \leq i \leq K_d^{(m)}\}$ :  
 $\pi_{d,i}^{(m)} = P(d_1^{(m)} = i | \Lambda)$  は、状態位置変動  $d$  に関する第  $m$  次元の状態系列において、時刻(座標)  $t^{(m)} = 1$  における状態が  $i$  である確率を表す。

2) 状態遷移確率  $A_d^{(m)} = \{a_{d,ij}^{(m)} | D_{min} \leq i, j \leq D_{max}\}$ :  
 $a_{d,ij}^{(m)} = P(d_{t^{(m)}}^{(m)} = j | d_{t^{(m)}-1}^{(m)} = i, \Lambda)$  は、状態位置変動  $d$  に関

係する第  $m$  次元の状態系列において、状態  $i$  から状態  $j$  に遷移する確率を表す。

- 出力確率分布:  $B$

分離型格子 HMM の各状態における出力確率分布を  $B = \{b_k(O_t) | k \in K\}$  と定義する。本稿では各状態の出力確率分布  $b_k(O_t)$  は平均ベクトル  $\mu_k$ 、共分散行列  $\Sigma_k$  を持つ単一ガウス分布  $\mathcal{N}(O_t; \mu_k, \Sigma_k)$  であると仮定している。

## 4. 学習アルゴリズム

### 4.1 変分 EM アルゴリズム

従来の分離型 2 次元格子 HMM における EM アルゴリズムと同様に、提案法における EM アルゴリズムを実行するためには以下に示す  $Q$  関数を計算する必要がある。

$$\begin{aligned} Q(\Lambda, \Lambda') &= E \{ \ln P(O, S, d | \Lambda') | O, \Lambda \} \\ &= \sum_S \sum_d P(S, d | O, \Lambda) \ln P(O, S, d | \Lambda') \quad (15) \end{aligned}$$

このとき新たに導入した隠れ変数  $d$  により、提案法の EM アルゴリズムにおける計算量は、従来法の  $Q$  関数を計算するための計算量に比べてさらに増大するため、実時間では計算が困難である。そこで、EM アルゴリズムに変分近似を導入して計算量の削減を図る。

まず、対数尤度の下限  $\mathcal{F}$  を Jensen の不等式及び事後確率分布  $P(S, d | O, \Lambda)$  の近似確率分布  $Q(S, d)$  を用いて定義する。

$$\begin{aligned} \ln P(O | \Lambda) &= \ln \sum_S \sum_d P(O, S, d | \Lambda) \\ &= \ln \sum_S \sum_d Q(S, d) \frac{P(O, S, d | \Lambda)}{Q(S, d)} \\ &\geq \sum_S \sum_d Q(S, d) \ln \frac{P(O, S, d | \Lambda)}{Q(S, d)} \\ &= \sum_S \sum_d Q(S, d) \ln P(O, S, d | \Lambda) \\ &\quad - \sum_S \sum_d Q(S, d) \ln Q(S, d) \quad (16) \end{aligned}$$

$$= \mathcal{F}(Q, \Lambda) \quad (17)$$

ここで、 $\mathcal{F}$  は EM アルゴリズムにおける  $Q$  関数の事後確率分布  $P(S, d | O, \Lambda)$  を新たな分布  $Q(S, d)$  で近似した形となっている。変分 EM アルゴリズムでは、以下の手順で  $\mathcal{F}$  の最大化を繰り返すことにより尤度の下限を極大に導く。

$$(E \text{ step}) : Q_{k+1} = \arg \max_Q \mathcal{F}(Q, \Lambda_k)$$

$$(M \text{ step}) : \Lambda_{k+1} = \arg \max_{\Lambda} \mathcal{F}(Q_{k+1}, \Lambda)$$

通常の EM アルゴリズムにおける E ステップが事後確率の計算であるのに対し、変分 EM アルゴリズムでは、分布  $Q(S, d)$  に関しての最適化を行う。また、M ステップに関しては期待値計算を  $Q(S, d)$  を用いて行うこと以外は一般的な EM アルゴリズムと同じ手順となる。これにより、 $Q$  関数と同様に、 $\mathcal{F}$  は学習の繰り返しによって必ず増加することが保証される。

次に、 $Q(S, d)$  の推定について説明する。本稿では、近似分

布  $Q(S, d)$  を用いた期待値計算に伴う計算量を削減するために、 $S, d$  の間の独立性、およびそれぞれの変数における各次元間の独立性を仮定した以下の制約条件を設ける。

$$Q(S, d) = Q(S)Q(d) \quad (18)$$

$$= Q(S^{(1)})Q(S^{(2)})Q(d^{(1)})Q(d^{(2)}) \quad (19)$$

ただし  $\sum_{S^{(m)}} Q(S^{(m)}) = 1$ ,  $\sum_{d^{(m)}} Q(d^{(m)}) = 1$  を満たすとする。このような制約条件下における最適な  $Q(S, d)$  は、 $\mathcal{F}$  を  $Q(S, d)$  について最大化することにより得られる。また、 $\mathcal{F}$  は次のように変形できる。

$$\begin{aligned} \mathcal{F}(Q, \Lambda) &= \sum_S \sum_d Q(S, d) \ln \frac{P(O, S, d | \Lambda)}{Q(S, d)} \\ &= \sum_S \sum_d Q(S, d | \Lambda) \ln P(O | \Lambda) \\ &\quad + \sum_S \sum_d Q(S, d) \ln \frac{P(S, d | O, \Lambda)}{Q(S, d)} \\ &= \ln P(O | \Lambda) - KL(Q || P) \quad (20) \end{aligned}$$

ここで、 $\ln P(O | \Lambda)$  は  $Q(S, d)$  に依存しないため、 $Q(S, d)$  に関して  $\mathcal{F}$  を最大化することは、 $P(S, d | O, \Lambda)$  と  $Q(S, d)$  の Kullback-Leibler (KL) divergence を最小化することと等価である。よって  $Q(S, d) = P(S, d | O, \Lambda)$  としたとき、KL divergence は 0 となり、尤度の下限  $\mathcal{F}$  は尤度と等しくなる。

$\mathcal{F}$  の最大化にあたり、制約  $\sum_{S^{(m)}} Q(S^{(m)}) = 1$ ,  $\sum_{d^{(m)}} Q(d^{(m)}) = 1$  の下での最適な近似分布は変分法に基づき次式で与えられる。

$$\begin{aligned} Q(S^{(m)}) &\propto P(S^{(m)}) \\ &\times \exp \left[ \sum_{S/S^{(m)}} \left\langle \prod_{n \neq m} Q(S^{(n)}) \ln P(O | S, d, \Lambda) \right\rangle_{Q(d)} \right] \quad (21) \end{aligned}$$

$$\begin{aligned} Q(d^{(m)}) &\propto P(d^{(m)}) \\ &\times \exp \left[ \sum_S \left\langle \prod_{n \neq m} Q(d^{(n)}) \ln P(O | S, d, \Lambda) \right\rangle_{Q(S)} \right] \quad (22) \end{aligned}$$

式 (21), (22) を繰り返し適用することにより最適な近似分布  $Q(S, d)$  が得られる。提案法における変分 EM アルゴリズムの E-step では以下に示す期待値を計算する。

$$\langle S_{t^{(m)}}^{(m)}, i \rangle = \sum_S Q(S) \delta(S_{t^{(m)}}^{(m)}, i) \quad (23)$$

$$\langle (S_{t^{(m)}-1}^{(m)}, i)(S_{t^{(m)}}^{(m)}, j) \rangle = \sum_S Q(S) \delta(S_{t^{(m)}-1}^{(m)}, i)(S_{t^{(m)}}^{(m)}, j) \quad (24)$$

$$\langle d_{t^{(m)}}^{(m)}, i \rangle = \sum_d Q(d) \delta(d_{t^{(m)}}^{(m)}, i) \quad (25)$$

$$\langle (d_{t^{(m)}-1}^{(m)}, i)(d_{t^{(m)}}^{(m)}, j) \rangle = \sum_d Q(d) \delta(d_{t^{(m)}-1}^{(m)}, i)(d_{t^{(m)}}^{(m)}, j) \quad (26)$$

$$\begin{aligned} \langle S_t, k, l \rangle &= \left\langle S_{t^{(1)}+d_{t^{(2)}}^{(1)}}, i \right\rangle \left\langle S_{t^{(2)}+d_{t^{(1)}}^{(2)}}, j \right\rangle \\ &\quad \times \left\langle d_{t^{(2)}}^{(1)}, p \right\rangle \left\langle d_{t^{(1)}}^{(2)}, q \right\rangle \end{aligned} \quad (27)$$

ただし,  $k = (i, j)$ ,  $l = (p, q)$  とする.

M-step では E-step で計算した各種期待値を用いて次式に従いパラメータを更新する.

$$\pi_{S,i}^{(m)} = \left\langle S_1^{(m)}, i \right\rangle \quad (28)$$

$$\pi_{d,i}^{(m)} = \left\langle d_1^{(m)}, i \right\rangle \quad (29)$$

$$a_{S,ij}^{(m)} = \frac{\sum_{t^{(m)}=2}^{T^{(m)}} \left\langle (S_{t^{(m)}-1}^{(m)}, i) (S_{t^{(m)}}^{(m)}, j) \right\rangle}{\sum_{t^{(m)}=2}^{T^{(m)}} \left\langle S_{t^{(m)}}^{(m)}, i \right\rangle} \quad (30)$$

$$a_{d,ij}^{(m)} = \frac{\sum_{t^{(n)}=2}^{T^{(n)}} \left\langle (d_{t^{(n)}-1}^{(m)}, i) (d_{t^{(n)}}^{(m)}, j) \right\rangle}{\sum_{t^{(n)}=2}^{T^{(n)}} \left\langle d_{t^{(n)}}^{(m)}, i \right\rangle} \quad (31)$$

$$\mu_k = \frac{\sum_t \sum_l \langle S_t, k, l \rangle O_t}{\sum_t \sum_l \langle S_t, k, l \rangle} \quad (32)$$

$$\Sigma_k = \frac{\sum_t \sum_l \langle S_t, k, l \rangle (O_t - \mu_k) (O_t - \mu_k)^T}{\sum_t \sum_l \langle S_t, k, l \rangle} \quad (33)$$

#### 4.2 確定的アンニーリング EM アルゴリズム

本稿では変分 EM アルゴリズムにおける局所最適性の問題を解決するために, 変分 EM アルゴリズムに対し確定的アンニーリングアルゴリズム [2] を導入した変分 DAEM アルゴリズムを適用する. 変分 DAEM アルゴリズムでは, 尤度関数を最大化する代わりに, 以下の自由エネルギー関数  $\mathcal{L}_\beta$  を最小化することでアルゴリズムが導出される.

$$\mathcal{L}_\beta = -\frac{1}{\beta} \ln \sum_S \sum_d P(O, S, d | \Lambda)^\beta \quad (34)$$

$\mathcal{L}_\beta$  の最小化は  $-\mathcal{L}_\beta$  の最大化と等価であることに注意し, 変分 EM アルゴリズムのときと同様に Jensen の不等式を用いて以下のように下限  $\mathcal{F}_\beta$  を定義する.

$$\begin{aligned} -\mathcal{L}_\beta &= \frac{1}{\beta} \ln \sum_S \sum_d Q_\beta(S, d) \frac{P(O, S, d | \Lambda)^\beta}{Q_\beta(S, d)} \\ &\geq \frac{1}{\beta} \sum_S \sum_d Q_\beta(S, d) \ln \frac{P(O, S, d | \Lambda)^\beta}{Q_\beta(S, d)} \\ &= \sum_S \sum_d Q_\beta(S, d) \ln P(O, S, d | \Lambda) \\ &\quad - \frac{1}{\beta} \sum_S \sum_d Q_\beta(S, d) \ln Q_\beta(S, d) \end{aligned} \quad (35)$$

$$= \mathcal{F}_\beta(Q_\beta, \Lambda) \quad (36)$$

$\mathcal{F}_\beta$  を最大化する最適な  $Q_\beta$  は, 変分法に基づき次式で与えられる.

$$Q_\beta(S^{(m)}) \propto P(S^{(m)})^\beta \times \exp \left( \left[ \sum_{S/S^{(m)}} \left\langle \prod_{n \neq m} Q_\beta(S^{(n)}) \ln P(O | S, d, \Lambda) \right\rangle_{Q_\beta(d)} \right] \right)^\beta \quad (37)$$

$$Q_\beta(d^{(m)}) \propto P(d^{(m)})^\beta \times \exp \left( \left[ \sum_S \left\langle \prod_{n \neq m} Q_\beta(d^{(n)}) \ln P(O | S, d, \Lambda) \right\rangle_{Q_\beta(S)} \right] \right)^\beta \quad (38)$$

ここで,  $\beta$  が小さな値のとき,  $Q_\beta(S, d)$  は一様分布に近い分布となり, 尤度関数が局所解の少ない単純な形状となる. また,  $\beta = 1$  のとき  $Q_\beta(S, d)$  は変分 EM アルゴリズムにおける近似事後分布に一致する. よって,  $\beta$  を 0 から 1 にゆっくりと増加させながら EM ステップを繰り返すことにより, 局所最適性の問題を改善することができる.

#### 5. 認識実験

本稿では XM2VTS データベース [3] を用いて顔画像モデルを作成し, 認識実験を行った. 実験条件を表 1 に示す. SL2D は分離型 2 次元格子 HMM を表す. 本稿では位置, 大きさを事前に正規化した画像と, ガウス乱数により回転角を変動させた画像を用いて実験を行なった. ただし提案法のモデルパラメータは, 従来法である SL2D より平均, 分散等のモデルパラメータを上記正規化済みの画像データを用いてあらかじめ学習しておいたものに, シフト状態遷移確率を追加することにより作成した.

学習アルゴリズムに変分 EM アルゴリズムを適用したときの実験結果を図 5 に示す. ただし図中の SL2D は従来法による認識率を表している. また横点線は, 予備実験として SL2D により学習・認識とも正規化済みのデータを用いて認識実験を行ったときの認識率を表しており, 今回の実験においては認識率の上限值とみなされる. 実験結果より, SL2D と比較して全てのシフト状態数において認識率の改善が見られた. シフト状態数  $12 \times 12$  のとき最大認識率 80% を得たが, この値は上述した認識率の上限值である 79% を越えており, 提案法による回転変動の正規化がなされたと言える. またシフト状態数  $14 \times 14$  以降で認識率の低下が見られるが, これはシフト状態数を増やしたことで許容する変動の範囲が広がり, 最適な状態遷移系列の推定が困難になったためと考えられる.

次に変分 DAEM アルゴリズムを適用したときの実験結果を図 6 に示す. 温度パラメータ  $\beta$  の更新は  $(i/I)^\alpha$ ,  $I = 40, \alpha = 8$  とした. ここで,  $i$  は現在の更新回数を表す. 図 5 と図 6 を比較すると, 変分 DAEM アルゴリズムを適用することにより認識率の改善が見られた. このことから, 変分 EM アルゴリズムにおける局所最適性の問題を改善できたといえる.

最後に図 7 に示す回転角の異なるテストデータに対し, Viterbi



表 1 実験条件

画像データ	XM2VTS データベース
原画像サイズ	720 × 576
使用画像サイズ (pixels)	64 × 64
階調数	256, グレースケール
学習用データ (変動なし)	1名あたり7枚 × 100名分
テスト用データ	1名あたり1枚 × 100名分
テストデータの回転角	-10° ~ 10°
SL2D 状態数	24 × 24
シフト状態数	2k × 2k (3 ≤ k ≤ 8)




図 5 認識率 (変分 EM)




図 6 認識率 (変分 DAEM)

パスに基づく最適状態系列を SL2D と提案法でそれぞれ求めた。それらを図 8 に示す平均ベクトルを用いて図示化した状態アライメントを図 9 に示す。ただし ExSL2D は提案法を表す。いずれのテストデータにおいても、SL2D ではモデル構造の制約から矩形状の状態アライメントしか得られず、回転変動には対応できていないことが分かる。一方、提案法である ExSL2D では回転角に対応した状態アライメントが得られており、これは ExSL2D によって回転変動を考慮した最適状態系列の推定がなされたことを意味する。

## 6. む す び

本稿では、回転変動を考慮した分離型 2 次元格子 HMM のモデル構造を提案し、顔画像認識実験においてその有効性を確認した。認識実験の結果から、提案モデルは回転変動を含んだ画像に対しても従来法に比べて高い認識性能を有することを示した。また、変分 DAEM アルゴリズムを適用することにより、認識率が改善されることを確認した。さらに状態アライメント



図 7 テストデータ




図 8 平均ベクトル

手法	10°	0°	-10°
SL2D 変分 EM			
SL2D 変分 DAEM			
ExSL2D 変分 EM シフト状態数 16 × 16			
ExSL2D 変分 DAEM シフト状態数 16 × 16			

図 9 状態アライメント

により回転変動を考慮した状態遷移系列が得られたことを確認し、提案モデルは回転変動を正規化可能なモデル構造を有することを示した。

今後の課題としては、より大規模な実験の検討、最適な HMM 状態数の決定などが挙げられる。

## 文 献

- [1] 大野也澄志, 南角吉彦, 徳田恵一, 北村正, Zoubin Ghahramani, “変分近似に基づいた分離型 2 次元 HMM 学習アルゴリズム,” 信学技報, Vol.102, No.652, PRMU2002-211, pp.1-6, Feb. 2003.
- [2] 上田修功, 中野良平, “確定的アニーリング EM アルゴリズム,” 電子情報通信学会論文誌, J80-D-II, no.1, pp.267-276, Jan. 1997.
- [3] K. Messer, J. Mates, J. Kitter, J. Luetttin, and G. Maitre, “XM2VTSDB: The Extended M2VTS Database,” Audio and Video-Based Biometric Person Authentication, pp.72-77, 1999.