

## ベイズ基準による可変固有画像モデルに基づく画像認識

学籍番号 23413534

氏名

沢田 慶

指導教員名

南角 吉彦

## 1 はじめに

画像認識において、認識対象の位置や大きさなどの幾何学的変動に対応可能な分離型格子 HMM に固有画像のような主成分分析の構造を組み込んだ可変固有画像モデル (HMEM) が提案されている。従来、HMEM の学習には尤度最大化 (ML) 基準が用いられてきた。しかし、画像認識では十分な量の学習データを用いることが困難である場合も多く、このような場合に、ML 基準により HMEM のような複雑なモデル構造を学習すると過学習を起こす恐れがある。これに対して、ベイズ基準は、事前情報を事前分布として用いて事後分布を推定することにより過学習の緩和が期待できる。そこで、本研究ではベイズ基準の近似手法である変分ベイズ法を用いた HMEM に基づく画像認識を提案し、顔画像認識実験により提案法の有効性を示す。

## 2 可変固有画像モデル

## 2.1 確率的固有画像モデル

確率的固有画像モデルは固有画像 (固有顔) 法や部分空間法を確率統計モデルとして定式化したモデルであり、観測データ間に潜む複数個の因子の存在を仮定する確率的潜在変数モデルである。固有画像は確率的な主成分分析 (Probabilistic Principal Component Analysis; PPCA) や因子分析 (Factor Analysis; FA) を用いて表現され、潜在変数である因子によりデータ間の共分散や相関構造をモデル化できる。

## 2.2 分離型格子 HMM

分離型格子 HMM (Separable Lattice HMM; SL-HMM) は、HMM を多次元に拡張したモデルである [1]。2 次元画像における SL-HMM は、横・縦方向の状態系列を持ち状態遷移はそれぞれ独立であると仮定する。モデルの出力は横・縦方向の状態の組み合わせによって決定される。SL-HMM は、矩形を維持しながら横・縦方向の伸縮を表現することができるため、認識対象の位置や大きさの変動に対応することができる。

## 2.3 可変固有画像モデル

可変固有画像モデル (Hidden Markov Eigen-image Model; HMEM) は、PPCA/FA と SL-HMM を統合したモデルであり、固有画像とノイズベクトルが SL-HMM から生成されると仮定する [2]。HMEM の尤度関数は次式で定義される。

$$P(O|\Lambda) = \sum_z \int P(O|x, z, \Lambda) P(x) P(z|\Lambda) dx \quad (1)$$

ここで、 $\Lambda$  はモデルパラメータ、 $O$  は 2 次元観測データ、 $x$  は因子ベクトルを表す。また、 $z$  は HMM における状態遷移を表し  $z = \{z^{(1)}, z^{(2)}\}$  とする。

HMEM は、固有画像を認識対象の位置や大きさの正規化を含むように変換することができる。つまり、状態系列が与えられると、正規化された観測データによる PPCA/FA とみなすことができる。HMEM はすべての観測データ間の相関は因子によりモデル化されるため、SL-HMM の問題点である観測データは対応する状態から独立して生成されるという制限を克服できる。このように、HMEM は PPCA/FA と SL-HMM の利点を持ち合わせており、統計的分析に基づく

線形特徴抽出と認識対象の位置や大きさの変動に対応することができる。

## 3 ベイズ基準による可変固有画像モデルの学習

## 3.1 ベイズ基準

従来、HMEM の学習には尤度最大化 (Maximum Likelihood; ML) 基準が用いられてきた。ML 基準では、観測データに対する尤度を最大にするモデルパラメータを最尤推定値  $\Lambda_{ML}$  として推定する。ML 基準による未知観測データ  $X$  の識別には、予測分布  $P(X|\Lambda_{ML})$  を用いる。しかし、ML 基準はモデルパラメータを点推定するため学習データが少量の場合には過学習を起こす恐れがある。

これに対して、ベイズ基準による未知観測データ  $X$  の識別には、次式で定義される予測分布  $P(X|O)$  を用いる。

$$P(X|O) = \int P(X|\Lambda) P(\Lambda|O) d\Lambda \quad (2)$$

ここで、 $P(\Lambda|O)$  は観測データ  $O$  が与えられたもとでのモデルパラメータ  $\Lambda$  の事後分布である。予測分布では事後分布を用いてモデルパラメータに関する期待値計算が行われる。事後分布  $P(\Lambda|O)$  は事前分布  $P(\Lambda)$ 、尤度関数  $P(O|\Lambda)$ 、エビデンス  $P(O)$  を用いてベイズの定理より表される。ベイズ基準ではモデルパラメータの周辺化を行っているため、ML 基準に比べ過学習が緩和される。すなわち、学習データが少量であるとき、ベイズ基準は潜在的に ML 基準より汎化能力の高いモデルを学習することが可能となる。しかし、HMEM のように潜在変数を持つモデルの場合、全ての潜在変数を考慮する必要があり、特殊な場合を除いて事後分布を解析的に得ることは困難である。そのため、事後分布を推定するためには何らかの近似を用いる必要がある。そこで本研究では、変分ベイズ (Variational Bayesian; VB) 法 [3] を用いて HMEM にベイズ基準を適用する。VB 法は比較的少ない計算量で精度良く近似事後分布を推定することができる。

## 3.2 変分ベイズ法を用いた可変固有画像モデルの学習

VB 法は、全ての未知量を周辺化した対数周辺尤度を考える。対数周辺尤度に任意の分布  $Q(x, z, \Lambda)$  を導入し、Jensen の不等式を用いることにより対数周辺尤度の下限  $\mathcal{F}$  を定義する。

$$\begin{aligned} \ln P(O) &= \ln \sum_z \iint P(O, x, z, \Lambda) dx d\Lambda \\ &\geq \sum_z \iint Q(x, z, \Lambda) \ln \frac{P(O, x, z, \Lambda)}{Q(x, z, \Lambda)} dx d\Lambda \\ &= \mathcal{F}(Q) \end{aligned} \quad (3)$$

ここで、 $Q(x, z, \Lambda)$  は事後分布の近似分布となり、下限  $\mathcal{F}$  を最大化することにより、適切な近似事後分布  $Q(x, z, \Lambda)$  を求めることができる。本研究では、計算量削減のために近似事後分布に  $Q(x, z, \Lambda) = Q(x)Q(z^{(1)})Q(z^{(2)})Q(\Lambda)$  という制約条件を与える。変分事後分布と呼ばれる  $Q(x)$ 、 $Q(z^{(m)})$ 、 $Q(\Lambda)$  は、それぞれ  $\int Q(x) dx = 1$ 、 $\sum_{z^{(m)}} Q(z^{(m)}) = 1$ 、 $\int Q(\Lambda) d\Lambda = 1$  とする。ここで、 $m \in \{1, 2\}$  である。この条件の下で、変分

事後分布を導出すると次式になる .

$$Q(\mathbf{x}) \propto P(\mathbf{x}) \exp \left\{ \sum_{z^{(1)}} \sum_{z^{(2)}} \int Q(\mathbf{x}) Q(z^{(1)}) Q(z^{(2)}) \times \ln P(\mathbf{O} | \mathbf{x}, z^{(1)}, z^{(2)}, \Lambda) d\Lambda \right\} \quad (4)$$

$$Q(z^{(m)}) \propto \exp \left\{ \sum_{z^{(\tilde{m})}} \iint Q(\mathbf{x}) Q(z^{(\tilde{m})}) Q(\Lambda) \times \ln P(\mathbf{O} | \mathbf{x}, z^{(1)}, z^{(2)}, \Lambda) P(z^{(m)} | \Lambda) d\mathbf{x} d\Lambda \right\} \quad (5)$$

$$Q(\Lambda) \propto P(\Lambda) \exp \left\{ \sum_{z^{(1)}} \sum_{z^{(2)}} \int Q(\mathbf{x}) Q(z^{(1)}) Q(z^{(2)}) \times \ln P(\mathbf{O} | \mathbf{x}, z^{(1)}, z^{(2)}, \Lambda) P(z^{(1)} | \Lambda) P(z^{(2)} | \Lambda) d\mathbf{x} \right\} \quad (6)$$

ここで,  $\tilde{m}$  は  $m = 1$  のとき  $\tilde{m} = 2$ ,  $m = 2$  のとき  $\tilde{m} = 1$  である . 変分事後分布  $Q(\mathbf{x})$ ,  $Q(z^{(m)})$ ,  $Q(\Lambda)$  は相互に依存しているため, 変分事後分布を個別に繰り返し更新することで下限  $\mathcal{F}$  を最大化することができる .

#### 4 顔画像認識実験

本研究では提案法の有効性を示すために XM2VTS データベース [4] を用いて顔画像認識実験を行った . 画像は  $64 \times 64$  画素, 256 階調のグレースケールである . 学習データは 1 名あたり 6 枚の 100 名分, テストデータは 1 名あたり 2 枚の 100 名分を用意した . また, HMM の状態数は  $32 \times 32$  状態とした . そして, ML 法を用いた SL-HMM と HMEM, VB 法を用いた SL-HMM と HMEM の認識率の比較を行った . VB 法の事前分布には, 一様分布と全学習データから学習されたモデル (Universal Background Model; UBM) を用いた . SL-HMM の事前分布には一様分布, SL-HMM の構造で学習した UBM を, HMEM の事前分布には一様分布, SL-HMM の構造で学習した UBM を HMEM の構造に変更した分布, HMEM の構造で学習した UBM を用い認識率の比較を行った . また, 事前分布にはデータ量に対応する調整パラメータが存在するが, 本実験では因子数 1 において最適化した調整パラメータを他の因子数でも用いた . 図 1 に顔画像認識実験の認識率を示す . 図 1(a) は HMEM のノイズベクトルの分散は対角等分散 (PPCA), 図 1(b) は HMEM のノイズベクトルの分散は対角共分散 (FA) の認識率である .

図 1 より, HMEM において, VB 法は ML 法より高い認識率が得られた . また, VB 法において HMEM と SL-HMM を比較すると HMEM の方が高い認識率となった . この結果より, 提案法の有効性を示した . PPCA (図 1(a)) と FA (図 1(b)) を比較すると, ML 法を用いた場合には PPCA は FA より高い認識率を示したが, VB 法を用いた場合には FA が PPCA より高い認識率を示した . FA はノイズ成分をパラメータとして持つため PPCA よりモデルの自由度が高いが, ML 法では学習データの不足による過学習により認識率が低下した . これに対し, VB 法では事前分布の利用とモデルパラメータの周辺化により過学習を緩和することができ, 高い認識率を得ることができたと考えられる . この結果より, ノイズベクトルの分散の推定精度が認識率に大きく影響することがわかった . また, FA は PPCA の構造を含むため, 高い推定精度の学習を行うことができれば, FA は PPCA より有用なモデル構造であるといえる .




図 1: 顔画像認識実験の認識率 (a) ノイズベクトルの分散は対角等分散 (PPCA), (b) ノイズベクトルの分散は対角共分散 (FA)

次に, 事前分布を比較する . PPCA (図 1(a)) においては, HMEM-VB-flat が高い認識率が得られた . これに対して, FA (図 1(b)) においては, HMEM-VB-SLUBM が高い認識率が得られた . この結果より, 対角共分散を仮定する SL-HMM の UBM を事前分布として用いることは, ノイズベクトルの分散に対角共分散を仮定する FA の構造においては有効であった . また, PPCA と FA の因子数 1 以外において, HMEM-VB-UBM は HMEM-VB-flat より高い認識率が得られない場合がある . これは, 事前分布の調整パラメータを因子数 1 において最適化したことと, 基底の事前分布を設定することは難しいためと考えられる .

#### 5 むすび

本研究では, 可変固有画像モデル (HMEM) の学習に変分ベイズ法を用いてベイズ基準を適用した . 顔画像認識実験の結果, HMEM の学習に変分ベイズ法を用いることで尤度最大化法より高い認識率を示した . HMEM の因子分析のモデル構造は確率的な主成分分析よりも自由度が高いが, 尤度最大化法では学習データが少量の場合には高い汎化能力を得ることができなかったのに対し, 変分ベイズ法では学習データが少量の場合において高い汎化能力を示した . また, 適切な事前分布を設定することで高い認識率を得ることができるとわかった . 今後の課題としては, より最適な事前分布の検討や HMEM より複雑なモデル構造へのベイズ基準の適用が挙げられる .

#### 参考文献

- [1] D. Kurata, *et al.*, "FACE RECOGNITION BASED ON SEPARABLE LATTICE HMMS", ICASSP, 2006.
- [2] Y. Nankaku, *et al.*, "FACE RECOGNITION USING HIDDEN MARKOV EIGENFACE MODELS", ICASSP, 2007.
- [3] H. Attias, "Inferring Parameters and Structure of Latent Variable Models by Variational Bayes", UAI, 1999.
- [4] K. Messer, *et al.*, "XM2VTSDB: The Extended M2VTS Database", AVBPA, 1999.