

逐次モンテカルロ法を用いた Bayes 的顔画像認識

松井 淳 Simon CLIPPINGDALE 藤井 真人 八木 伸行

NHK 放送技術研究所 〒157-8510 世田谷区砧 1-10-11

E-mail: {matsui.a-hk, simon.c-fe, fujii.m-ii, yagi.n-iy}@nhk.or.jp

あらまし 動画像を対象とした顔画像認識において、表情変化に対する頑健性を改善するため、個々の顔の確率分布を Bayes 推定により逐次的に学習する手法を提案する。本手法では、可変テンプレートマッチングにおける個々の顔モデルに付随した各種パラメータを確率変数とみなし、それらの同時確率分布に関する周辺化を逐次モンテカルロ法により実行する。10名の被験者の発話動作にともなう顔の変形の様子を撮影した評価データを用いて実験した結果、パラメータの同時確率分布をハミルトニアンモンテカルロ法によって一括学習する手法と比較して、顔認識誤り率が 11.0% から 2.3% に減少した。

キーワード 顔画像認識, 可変テンプレートマッチング, Bayes 推定, 逐次モンテカルロ

Bayesian Face Recognition using a Sequential Monte Carlo Method

Atsushi MATSUI, Simon CLIPPINGDALE, Mahito FUJII, and Nobuyuki YAGI

† NHK Science & Technical Research Laboratories, 1-10-11 Kinuta, Setagaya-ku, Tokyo, 157-8510 Japan

E-mail: {matsui.a-hk, simon.c-fe, fujii.m-ii, yagi.n-iy}@nhk.or.jp

Abstract We introduce a sequential learning algorithm for Bayesian probability distributions describing faces in video input images. In this algorithm, we consider certain parameters of a face model in a deformable template matching process as random variables so as to improve robustness against facial expressions. We evaluated the algorithm on a test set of video showing each of 10 persons talking. The results show that the new algorithm reduced the recognition ID error rate from 11.0% to 2.3% on the data, compared to a batch learning algorithm using a Hamiltonian Monte Carlo method.

Keywords face recognition, deformable template matching, Bayesian inference, sequential Monte Carlo

1. はじめに

顔画像認識とは、与えられた静止画または動画像から自動的に人間の顔を発見し人物を識別する技術をさすが、しばしば前者の処理は後者の処理とは独立の問題（顔画像検出）として扱われる。本稿では後者、すなわち、顔画像から個人を特定する処理に注目する。顔画像認識は、その目的と使用環境に応じて、多種多様な入力画像の変動に対応できなければならない。筆者らは放送素材映像の自動インデキシングを目的とした顔画像認識システム[1][2]を試作した。このシステムは可変テンプレートマッチングを用いることで、非剛体である顔の形状の変化にある程度対応可能であるが、照明や背景などの撮影条件が変化するたびに内部パラメータを調整する必要があった。また顔の大きな変形を伴う表情変化に対する頑健性に問題があった。

本稿では、時々刻々と変化する顔の状態に応じた各種パラメータの動的な補正を実現するため、逐次学習型の顔画像認識法を提案する。

本手法では、個々の顔のモデル（顔テンプレート）に付随するパラメータを確率変数とみなし、ベイジ的枠組みからオンライン学習則を導く。特に、筆者らが提案した顔画像認識法[12][13]において、事前に一括学習していたパラメータの事後確率分布を、現時刻までに与えられた過去の入力画像を用いて逐次的に推定することによって、表情変化等の顔の状態の変化により柔軟に対応しうる顔画像認識の実現を目指す。本稿で扱うような問題では、パラメータ更新の線形性や、観測モデルおよび運動モデルの不確定性についての正規分布の仮定は必ずしも満たされないため、Kalman フィルタを適用することは不相当であると考えられる。そこで、本稿ではこれらの仮定を必要としない逐次モンテカルロ法を用いた学習則によって、顔テンプレートの事後確率分布を逐次的に計算する。パラメータの確率分布を事前に一括学習するハミルトニアンモンテカルロ法[13]との比較実験を行い、提案手法の有効性を検証する。

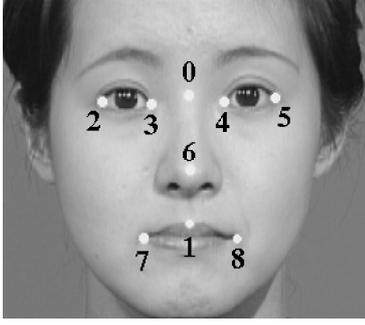


図 1: 特徴点の配置 ($N=9$)

Fig. 1: Example of node locations \mathbf{x}_A .

2. 顔テンプレート

筆者らが開発した顔画像認識システム[1][2]は, Elastic Graph Matching[3][4]をベースとした可変テンプレートマッチングを行う. 顔テンプレートは, 登録顔画像上に定義した N 個の特徴点の配置 $\mathbf{x}_A \in \mathbf{R}^{2 \times N}$ と, 各特徴点における K 個の方位と R 段階の解像度のガボール・ウェーブレット係数 $\mathbf{c}^A \in \mathbf{C}^{N \times K \times R}$, および人物 ID から構成される. 特徴点配置の具体例を図 1 に示す.

システムに登録した各テンプレートと入力画像上の顔画像との各解像度 r における類似度を式(1)で定義する.

$$S_{AB}^r = 1 - \alpha_f \left(1 - \frac{\langle \mathbf{c}_r^A, \mathbf{c}_r^B \rangle}{\|\mathbf{c}_r^A\| \|\mathbf{c}_r^B\|} \right) - \alpha_s \frac{\sqrt{E_{A,B}}}{\lambda_r} \quad (1)$$

式(1)の右辺第 2 項は特徴量の類似度をあらわす. $\langle \mathbf{c}_r^A, \mathbf{c}_r^B \rangle$ は二つの複素ベクトル $\mathbf{c}^A, \mathbf{c}^B$ の解像度 r に関する成分の内積をあらわし, 定数 λ_r は解像度 r におけるガボール・ウェーブレットの波長をあらわす. 各々のガボール・ウェーブレット係数は, 2 次元のガボール・ウェーブレットと, 各特徴点の周囲の輝度との畳み込み積分である. 解像度 r , 方位 n のガボール・ウェーブレットは, 式(2)で定義される.

$$g_n^r(\mathbf{x}) = \frac{k_r^2}{\sigma^2} \exp\left(-\frac{k_r^2 \|\mathbf{x}\|^2}{2\sigma^2}\right) \times \left[\exp(i(\mathbf{k}_n^r) \mathbf{x}) - \exp\left(-\frac{\sigma^2}{2}\right) \right] \quad (2)$$

ここで \mathbf{k}_n^r はガボール・ウェーブレットの中心周波数にあたる波数ベクトルであり, 式(3)で定義される. 図 2 にガボール・ウェーブレットの例を示す.

$$\mathbf{k}_n^r = k_r \begin{pmatrix} \cos(n\pi/K) \\ \sin(n\pi/R) \end{pmatrix}, \quad \begin{matrix} 0 \leq n < K = 8 \\ 0 \leq r < R = 5 \end{matrix} \quad (3)$$

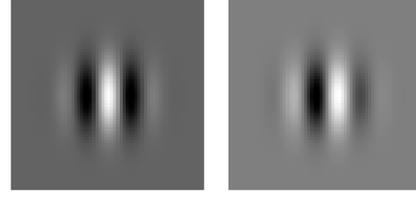


図 2: ガボール・ウェーブレット
(左:実数部, 右:虚数部)

Fig. 2: Gabor wavelet
(left: real part, right: imaginary part)

$E_{A,B}$ はテンプレートの特徴点配置 \mathbf{x}_A に対する入力画像上の特徴点配置 \mathbf{x}_B の変形の度合いを評価する歪みエネルギーである. 式(1)における α_f, α_s は, それぞれ特徴量の類似度, 歪みエネルギーの重みであり, 経験的に固定された定数である. 可変テンプレートマッチングでは, 与えられた画像に対してパラメーター α_f, α_s をある一組の値に固定した状態において式(1)を最大化することで, 各々の顔テンプレートごとに, 対応する入力画像上での特徴点配置を決定する.

3. 提案手法

3.1 オンライン Bayes 推定

式(1)のように, 拘束条件の項が付いた評価関数についてのパラメーターの最適化問題は, Bayes 推定[5][6]における事後確率最大化と関連づけて捉えることができる. 本稿では, 顔テンプレートに付随するいくつかのパラメーターを確率変数とみなし, それらの確率分布から, 顔データテンプレートの出現確率 (事後確率) を計算する. 事後分布最大を与えるパラメーター値は多くの場合うまく働くが, 事後分布形状が複雑な場合, 1 点のみの推定は破綻する事も少なくない. 本稿で提案する手法は事後分布を 1 点ではなく確率分布サンプルを採取する事によりより相応しい事後分布とそれに基づく諸統計量を計算する手法を提案する.

連続した入力画像 $y_{1:n} = \{y_1, y_2, \dots, y_n\}$ が逐次的に与えられる場合について考える. 表記の簡略化のため, 以下, 特にことわらない限り $\mathbf{x} = \mathbf{x}_B$ とおく. 式(1)において, 二つの複素ベクトル $\mathbf{c}_r^A, \mathbf{c}_r^B$ の類似度をそれらのノルムで正規化したもとの内積で評価しているが, これは各解像度 r についてのベクトル \mathbf{c}_r^B を指向性データとみなすことを意味する. そこで本稿では, 指向性データの自然な生成モデルとして知られている von Mises-Fisher 分布[7]を用いて n 枚目の入力画像 y_n の尤度を次式で定義する.

$$P(y_n | \mathbf{x}_n, \beta_{n \pm R}, \mathcal{H}_j) = \frac{1}{R} \sum_{r=1}^R \frac{1}{Z_b(\beta_{n,r})} \exp\left(\beta_r \frac{\langle \mathbf{c}_r^A, \mathbf{c}_{nr}^B \rangle}{\|\mathbf{c}_r^A\| \|\mathbf{c}_{nr}^B\|}\right) \quad (4)$$

ここで、 \mathcal{H}_j は仮定した j 番目の顔テンプレートであり、 $\beta_{n,1:R} = \{\beta_{n,1}, \beta_{n,2}, \dots, \beta_{n,R}\}$ は、時刻 n における尤度関数の鋭さを決定するハイパーパラメーターである。 Z_b は正規化定数であり、 p 次の第1種変形ベッセル関数 I_p を用いて次式で定義される。

$$Z_b(\beta) = \frac{(2\pi)^{k/2} I_{k/2-1}(\beta)}{\beta^{k/2-1}} \quad (5)$$

ただし、 k はベクトル \mathbf{c}_r^B の次元数 $k=2N \times K$ である。

入力画像 y が与えられる前の \mathbf{x}_n の予測確率分布は、筆者らが行った予備実験の結果[8]をふまえ、次式で定義する。

$$P(\mathbf{x}_n | \alpha_n, T_n, \mathcal{H}_j) = \frac{1}{Z_a(\alpha_n)} \exp\left(-\frac{\alpha_n}{2} (T_n^{-1}(\mathbf{x}_n) - \mathbf{x}_j^A)' \Lambda_j^{-1} (T_n^{-1}(\mathbf{x}_n) - \mathbf{x}_j^A)\right) \quad (6)$$

ここで、 Λ_j は正規特徴点配置空間上での特徴点配置の共分散行列をあらわす。 α は事前分布の鋭さを決定するハイパーパラメーターであり、規格化定数 Z_a は以下の式で求められる。

$$Z_a(\alpha) = (2\pi)^N \sqrt{\frac{\det \Lambda_j}{\alpha}} \quad (7)$$

T_n は、顔テンプレートの特徴点配置 \mathbf{x}_j^A が張る空間（以下、正規特徴点配置空間と呼ぶ）から、入力画像上の特徴点配置 \mathbf{x}_n が張る空間への写像をあらわす。

$$T_n: \mathbf{x}_A \mapsto \mathbf{x}_n,$$

$$T_n(\mathbf{x}_A) = \begin{bmatrix} r_n \cos \theta_n & -r_n \sin \theta_n & 0 & \dots & 0 \\ r_n \sin \theta_n & r_n \cos \theta_n & & & \vdots \\ 0 & & 0 & & 0 \\ \vdots & & & r_n \cos \theta_n & -r_n \sin \theta_n \\ 0 & \dots & 0 & r_n \sin \theta_n & r_n \cos \theta_n \end{bmatrix} \begin{bmatrix} x_A^1 \\ y_A^1 \\ \vdots \\ x_A^N \\ y_A^N \end{bmatrix} + \begin{bmatrix} u_n \\ v_n \\ \vdots \\ u_n \\ v_n \end{bmatrix} \quad (8)$$

以下、表記の簡略化のため、 T_n を決定する4つのパラメーターの組 $(r_n, \theta_n, u_n, v_n)$ のことを T_n によって代表してあらわすことにする。 T_n の各パラメーターは、入力画像上の顔の中心位置と大きさ、画像平面内の回転を決定する。入力画像が逐次的に与えられ、データが与えられる度にパラメーターの推定も逐次的に遂行するのがこの論文の目的である。そのためにはパラメーター空間を逐次的に探索する事は自然な方策であろう。この研究では顔全体の動きが極端に激しくない場合を想定し、 T_n の逐次更新則 $P(T_n | T_{n-1})$ として次のような確率的ダイナミカルシステムを考える。

$$\begin{aligned} r_n &= r_{n-1} + v_r, & v_r &\sim N(0, \delta_r) \\ \theta_n &= \theta_{n-1} + v_\theta, & v_\theta &\sim N(0, \delta_\theta) \\ u_n &= u_{n-1} + v_u, & v_u &\sim N(0, \delta_u) \\ v_n &= v_{n-1} + v_v, & v_v &\sim N(0, \delta_v) \end{aligned} \quad (9)$$

同様に、尤度関数および事前確率の分布の鋭さを決定するハイパーパラメーターについて、

次のような予測モデル $P(\alpha_n, \beta_{n,1:R} | \alpha_{n-1}, \beta_{n-1,1:R})$ を仮定する：

$$\begin{aligned} \log \alpha_n &= \log \alpha_{n-1} + v_\alpha, & v_\alpha &\sim N(0, \delta_\alpha) \\ \log \beta_{n,r} &= \log \beta_{n-1,r} + v_\beta, & v_\beta &\sim N(0, \delta_\beta) \end{aligned} \quad (10)$$

なお、対数正規分布を考える理由は、正值性を保証するためである。

データ $y_{1:n}$ が与えられたとき j 番目のモデル \mathcal{H}_j の事後確率は、Bayes の定理より次式によって再帰的に与えられる。

$$P(\mathcal{H}_j | y_{1:n}) = \frac{P(y_n | y_{1:n-1}, \mathcal{H}_j) P(\mathcal{H}_j | y_{1:n-1})}{P(y_n | y_{1:n-1})} \quad (11)$$

システムは、それまでに観測された入力画像集合 $y_{1:n}$ について事後確率最大を与えるモデル \mathcal{H}_{MP} を、時刻 n における認識結果として出力する。

$$\mathcal{H}_{MP}^{(n)} = \arg \max_{\mathcal{H}} P(\mathcal{H} | y_{1:n}) \quad (12)$$

式(11)にあらわれる \mathcal{H}_j の尤度は次式で与えられる。

$$\begin{aligned} P(y_n | y_{1:n-1}, \mathcal{H}_j) &= \int P(y_n | \mathbf{x}_n, \beta_{n,1:R}, \mathcal{H}_j) P(\mathbf{x}_n | \alpha_n, T_n, \mathcal{H}_j) \\ &\quad P(T_n | T_{n-1}) P(\alpha_n, \beta_{n,1:R} | \alpha_{n-1}, \beta_{n-1,1:R}) \\ &\quad d(\mathbf{x}_{n-1}, \alpha_{n-1}, \beta_{n-1,1:R}, T_{n-1}) \end{aligned} \quad (13)$$

3.2 逐次モンテカルロ

式(11)の計算は多次元連続空間に関する積分であり、ここで考えている問題を含め、解析的に計算を実行することは不可能である事が多い。本稿ではこの積分を逐次モンテカルロ法[9][10][11] (Sequential Monte Carlo, SMC法)による近似計算で実現する。

まず、時刻 n における各パラメーターの予測分布を独立同一なサンプルで表現するため、次のような提案分布 (proposal distribution) を考える。

$$\begin{aligned} \pi(\mathbf{x}_n, \alpha_n, \beta_n, T_n) &= P(\mathbf{x}_n | \alpha_n, T_n, \mathcal{H}_j) P(T_n | T_{n-1}, \Sigma_T) \\ &\quad P(\alpha_n | \alpha_{n-1}, \sigma_\alpha) P(\beta_n | \beta_{n-1}, \sigma_\beta) \end{aligned} \quad (14)$$

提案分布 $\pi(\mathbf{x}_n, \alpha_n, \beta_{n,1:R}, T_n)$ に従う N_j 個のサンプルが抽出されたとき、式(13)の積分は次式で近似的に計算可能である。

$$\begin{aligned} P(y_n | y_{1:n-1}, \mathcal{H}_j) &= \int P(y_n | \mathbf{x}_n, \beta_{n,1:R}, T_n, \mathcal{H}_j) P(\mathbf{x}_n, \alpha_n, \beta_{n,1:R}, T_n | y_{1:n-1}, \mathcal{H}_j) \\ &\quad d(\mathbf{x}_n, \alpha_n, \beta_{n,1:R}, T_n) \\ &\approx \sum_{i=1}^{N_j} \tilde{w}_n^{(i)} \Big|_{\mathcal{H}_j} \delta(\mathbf{x}_n, \alpha_n, \beta_{n,1:R}, T_n) = (\mathbf{x}_n^{(i)}, \alpha_n^{(i)}, \beta_{n,1:R}^{(i)}, T_n^{(i)}) \end{aligned} \quad (15)$$

ここで、 $\tilde{w}_n^{(i)} \Big|_{\mathcal{H}_j}$ は提案分布と事後確率分布との

誤差の補正項 (normalized importance weight) であり、式(14)の提案分布を用いる場合、次式で計算される。

$$w_n^{(i)} \Big|_{\mathcal{H}_j} = \frac{P(\mathbf{x}_n^{(i)}, \alpha_n^{(i)}, \beta_{1:R,n}^{(i)}, T_n^{(i)} | y_{1:n}, \mathcal{H}_j)}{\pi(\mathbf{x}_n^{(i)}, \alpha_n^{(i)}, \beta_{1:R,n}^{(i)}, T_n^{(i)})} \\ = P(y_n | \mathbf{x}_n^{(i)}, \alpha_n^{(i)}, \beta_{1:R,n}^{(i)}, T_n^{(i)}, y_{1:n-1}, \mathcal{H}_j) \quad (16)$$

$$\tilde{w}_n^{(i)} \Big|_{\mathcal{H}_j} = \frac{w_n^{(i)} \Big|_{\mathcal{H}_j}}{\sum_{q=1}^{N_j} w_n^{(q)} \Big|_{\mathcal{H}_j}} \quad (17)$$

また $\delta(x)$ はクロネッカーのデルタをあらわす。

このとき、時刻 n における j 番目の顔テンプレート \mathcal{H}_j の事後確率の逐次モンテカルロ近似は次式で与えられる。

$$P(\mathcal{H}_j | y_{1:n}) = \frac{P(y_n | y_{1:n-1}, \mathcal{H}_j) P(\mathcal{H}_j | y_{1:n-1})}{\sum_{k=1}^{N_{persons}} P(y_n | y_{1:n-1}, \mathcal{H}_k) P(\mathcal{H}_k | y_{1:n-1})} \\ \cong \frac{P(\mathcal{H}_j | y_{1:n-1}) \sum_{i=1}^{N_j} \tilde{w}_n^{(i)} \Big|_{\mathcal{H}_j}}{\sum_{k=1}^{N_{persons}} P(\mathcal{H}_k | y_{1:n-1}) \sum_{i=1}^{N_j} \tilde{w}_n^{(i)} \Big|_{\mathcal{H}_j}} \quad (18)$$

なお、第1番目の入力画像 y_1 が与えられる前の、各々のモデルの事前確率 $P(\mathcal{H}_j | y_0)$ は、特別な理由がない限り等確率とする。

$$P(\mathcal{H}_j | y_0) = \frac{1}{N_{persons}} \quad (19)$$

ここで、 $N_{persons}$ はシステムに登録された人数をあらわす。

4. 認識実験

4.1 実験条件

提案手法 (以下、Bayesian SMC と呼ぶ) の有効性を検証するため、ハミルトニアモンテカルロ法によりパラメータの確率分布を一括学習する手法 [13] (以下、Bayesian HMC と呼ぶ) を比較対象とした認識実験を行った。

実験に用いるデータは、評価データ、登録データ、学習データの3種類を用意した。

システムに逐次的に与える入力データ $y_{1:n}$ として用いる評価データは、10人 (男性7人、女性3人) の被験者それぞれについての発話時の顔の連続画像を用意した。各々の連続静止画像は、スタジオ照明・単色背景 (ブルーバック) の条件で撮影した正面を向いた顔画像の NTSC 動画像から、タテ 240 画素 × ヨコ 360 画素のサイズで 30 フレーム (1 秒間) を取得した。

各人物の顔テンプレート $\mathcal{H}_j = (\mathbf{x}_A, \mathbf{c}^A, j)$ の作成に用いる登録データは、評価データと同じ条件で撮影した無表情・正面の顔画像 1 枚 / 人を用意した。

提案手法における共分散行列 Λ_j の推定、および、従来手法においてパラメータの確率分布 $P(\mathbf{x}_n, \alpha_n, \beta_{n,1:R} | \mathcal{H}_j)$ の推定に用いる学習データは、6つの基本表情 (驚き、喜び、悲しみ、怒り、恐怖、嫌悪) [14] について撮影した各々3パターン、計 18 枚 / 人の顔画像を用意した。

なお、顔の位置情報の初期値 $T_0 = (r_0, \theta_0, u_0, v_0)$ は、個々の評価データについてあらかじめ手動で抽出した結果を用いた。また、提案手法において、各種パラメータの予測モデルの分散とハイパーパラメータの初期値は、 $\sigma_u = \sigma_v = 1.0$, $\sigma_r = 0.1$, $\sigma_\theta = 0.0001$, $\sigma_\alpha = \sigma_\beta = 0.01$, $\alpha_0 = 10.0$, $\beta_0 = 1.0$ とした。提案手法および従来手法において、モンテカルロ近似の精度を決定するサンプルの総数は、それぞれ一つの顔テンプレートあたり $N_j = 3600$ 個に統一した。

4.2 実験結果

一括学習型の従来手法 (Bayesian HMC) と、逐次学習型の提案手法 (Bayesian SMC) それぞれの評価データに対する顔認識誤り率を表1に示す。また、パラメータ分布の推定 (学習) と認識の一連の処理に要した処理時間もあわせて表1に示す。なお、各々の顔認識誤り率は、各時刻においてシステムが認識結果として出力した人物 ID が、評価データに登場している真の人物 ID と一致した回数、評価データ全体のフレーム数 (=300) に対する割合で評価した。また、処理時間は、CPU: Xeon 2.8 GHz の計算機を用いて、学習と認識の両方の処理にかかった時間の合計である。表1の実験結果より、従来の Bayesian HMC で 11.0% の顔認識誤りが発生したのに対して、本稿で提案した Bayesian HMC では顔認識誤りは 2.3% であり、直前の入力画像を用いた逐次学習を行うことで、顔の短時間的な形状変化に対する頑健性が改善していることがわかる。一方、処理時間については、Bayesian HMC で合計 1155 秒だったのに対して、Bayesian SMC では 2329 秒であり、約 2 倍の処理時間を必要とした。

図3に、計 3600×10 人 = 36000 個のサンプルのうち、normalized importance weight の上位 100 個のサンプルの特徴点配置の分布を対応する入力画像に重ねて示す。図3より、顔テンプレートの事後確率 $P(\mathcal{H}_j | y_{1:n})$ の計算への寄与が大きい、大きな importance weight の値を持つ特徴点配置のサンプルが、顔の各器官、とくに口の両端の位置変化に追従している様子がうかがえる。

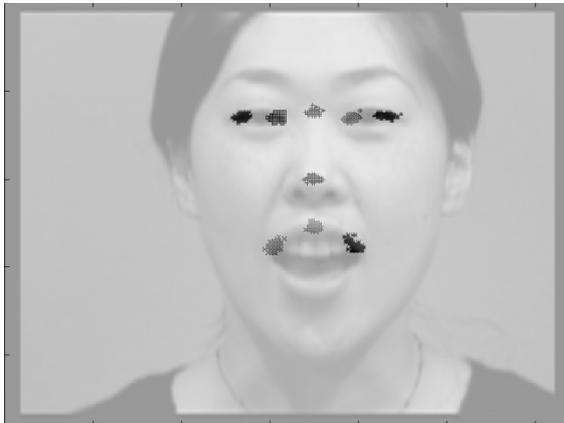
表1: 顔認識実験の結果 (顔認識誤り率)

Table 1: Face recognition results (ID error rate)

Model	Bayesian HMC	Bayesian SMC
ID Error Rate	11.0 %	2.3 %
Proc. time	1155 sec.	2329 sec.



n=0



n=4



n=8

図 3 : 各時刻 n におけるサンプルの特徴点配置
(normalized importance weight 上位 100 組)
Fig. 3: Examples of node locations of SMC
samples at 4-frame intervals.
(top 100 samples in order of importance weights)

5. まとめ

登録した人物ごとのモデルの事後確率を Bayes 推定にもとづく逐次モンテカルロ法を用いて計算する顔画像認識法を提案した. パラメータの一部を確率変数と捉え, その確率分布を学習データから推定する具体的なアルゴリズムを示した. 発話時の連続顔画像を用いた比較実験の結果, パラメータ分布の一括学習を行なう従来手法に比べ, 逐次学習を行う提案法は, 顔認識誤りが約 1/5 に削減され, 顔変形に対する頑健性が示された.

今後は, 様々な表情変化に対する本手法の有効性を検証していくとともに, 頭部や人物全体の動きを想定したパラメータの運動モデルの導入, ならびに, 本実験では手動で与えた顔の位置情報の自動検出法についても検討していきたい.

文 献

- [1] S. Clippingdale, and T. Ito, "A Unified Approach to Video Face Detection, Tracking and Recognition," Proc. ICIP'99 (1999).
- [2] S. Clippingdale, and T. Ito, "Partial automation of database acquisition in the FAVRET face tracking and recognition system using a bootstrap approach," Proc. MVA2000 (2000).
- [3] L. Wiskott, J. M. Fellous, N. Krüger and von der C. Malsburg, "Face Recognition by Elastic Bunch Graph Matching," TR96-08, Institut für Neuroinformatik, Ruhr-Universität Bochum (1996).
- [4] K. Okada, J. Steffens, T. Maurer, H. Hong, E. Elagin, H. Neven and von der C. Malsburg, "The Bochum/USC Face Recognition System And How it Fared in the FERET Phase III Test," Face Recognition: From Theory to Applications, Springer (1998).
- [5] D.J.C. Mackay, "Information Theory, Inference, and Learning Algorithms," Cambridge University Press (2003).
- [6] R.M. Neal, "Bayesian Learning for Neural Networks," Lecture Notes in Statistics, Springer, pp.55-98 (1996).
- [7] I.S. Dhillon and S. Sra, "Modeling Data using Directional Distributions," TR-03-06, University of Texas at Austin (2003).
- [8] 松井淳, S. Clippingdale 「表情変化の事前情報を利用した可変テンプレートマッチングによる顔画像認識」, 信学技報, PRMU2003-161, pp.61-65 (2003).
- [9] A. Doucet, N.D. Freitas, and N. Gordon, "Sequential Monte Carlo Methods in Practice," Springer, (2001).
- [10] J.S. Liu, "Monte Carlo Strategies in Scientific Computing," Springer, pp.53-77 (2001).
- [11] Y. Nakada, T. Matsumoto, T. Kurihara and K.

- Yosui, "Bayesian Reconstructions and Predictions of Nonlinear Dynamical Systems via the Hybrid Monte Carlo Scheme," *Signal Processing*, Elsevier, Vol.85, pp.129-145 (2005).
- [12] 鶴澤史貴, 松本隆, 松井淳, S. Clippingdale
「Bayes 的 Markov Chain Monte Carlo 顔画像認識」, *通学技報*, ITS2003-91, pp.19-24 (2003).
- [13] 松井淳, S. Clippingdale, 鶴澤史貴, 松本隆
「ハミルトニアンモンテカルロ法による Bayes 的顔画像認識」, *映情学誌*, Vol.59, No.8, pp.1183-1190 (2005).
- [14] P. Ekman, and W. V. Friesen, "Unmasking the Face," Prentice-Hall (1975).