

構造化 MCMC 法に基づいた顔部品検出

松 元 郁 佑[†] 加 藤 丈 和[†]
呉 海 元[†] 和 田 俊 和[†]

本論文では、マルコフ連鎖モンテカルロ法 (Markov Chain Monte Carlo, MCMC) の枠組にパラメータ間の相互依存関係を考慮した、構造化 MCMC 法を提案する。提案手法では、対象を構成する部品 (顔部品や多関節物体の体節など) 毎にパラメータを分割し、部品間の構造を他の部品の分布に対する条件付き確率として定義する。この条件付き確率をマルコフ推移核として MCMC 法を適用する。他の部品で推定された分布に基づいて各部品の推定を行うことで、部品毎に分布の推定を行いつつ、全体としては部品間の構造を考慮した推定が可能となる。提案手法を顔部品検出問題に適用し、実験によりその有効性を確認した。

Facial parts detection based on Structuralized MCMC

YUSUKE MATSUMOTO,[†] TAKEKAZU KATO,[†] HAIYUAN WU[†]
and TOSHIKAZU WADA[†]

In this paper, we propose a new method called structuralized MCMC, which is an extension of the framework of Markov Chain Monte Carlo (MCMC). Our method estimates parameters of the objects that consist of some parts which have structural relationship among themselves. Parameters of objects are divided for each part, and the structure among parts is represented as a conditional probability on distributions of other parts. The MCMC is applied by using the conditional probability as a kernel of Markov-chain. Each part is estimated by using the estimated distribution of other parts. Our method can estimate the distribution of each part while considering the structure among parts. This Structuralized MCMC is applied to a facial parts detection problem. The extensive experiments demonstrate the effectiveness of our method.

1. はじめに

マルコフ連鎖モンテカルロ法 (Markov Chain Monte Carlo, MCMC)¹⁾ は、ベイズ統計学で事後分布や事後確率を推定するためのシミュレーションの方法であり、図 1 の (a) に示すように、推定された分布からのランダムサンプリングと、サンプル点に従ったデータの評価による分布の推定を繰り返すことでノンパラメトリックな非ガウス分布を推定する強力な手法である。近年、コンピュータビジョンの分野でも、MCMC を時系列データに適用した ConDensation²⁾ など様々な応用が進んでいる。

MCMC 法はパラメータの数が少ない場合や、パラメータ間の相関が弱い場合には、効率良く分布を推定することができる。しかし、顔部品検出や多関節物体の姿勢推定など、多くのパラメータを持ち、かつ、パ

ラメータ間に複雑な相関関係を持つ対象を効率良く扱うことができない。これは、状態を全てのパラメータの直積空間内の点として扱うために状態空間が広くなり、またパラメータ間の相関関係によって、局所解に収束しやすくなるためである。

このような問題点を解決するために、MacCormick らは partitioned sampling³⁾ を提案している。この手法は全状態空間をいくつかのパラメータ毎に部分状態空間に分割し、各部分状態空間毎に分布を推定する手法である。この手法ではパラメータ空間を分割することで、効率良く分布を推定することができるが、分割されたパラメータ間の相互依存関係については考慮されていない。

また、Isard らは factored sampling⁴⁾ を提案している。この手法は、対象の色モデルと位置、姿勢を同時に推定する方法である。この手法では対象のパラメータを位置、姿勢と色モデルに分割し、位置、姿勢パラメータのサンプリングと色モデルのパラメータのサンプリングを交互に行うことで、これらのパラメー

[†] 和歌山大学
Wakayama University

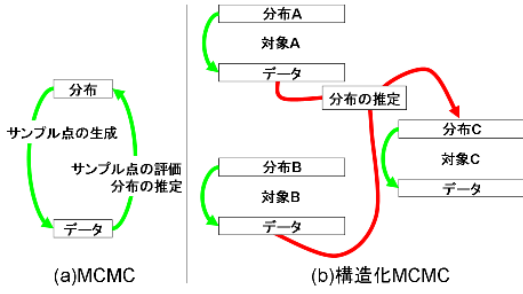


図 1 MCMC と構造化 MCMC

データを同時に更新している。この手法でも分割されたパラメータ間の依存関係については定義されていないため、構造を持つ対象に適用することはできない。

そこで、本論文ではパラメータ間の相互依存関係を考慮し、MCMC 法の枠組にそれを導入することにより、このような問題を効率良く扱う手法を提案する。我々はこの手法を構造化 MCMC 法と呼ぶ。提案手法は、複数の部品から構成され、部品間に構造を持つ対象を扱うための手法である。図 1(b) に示すように、状態パラメータは対象を構成する部品（顔部品や多関節物体の体節など）ごとに分割し、部品間の構造を、他の部品の分布に対する条件付き確率として定義する。この条件付き確率をマルコフ推移核として MCMC 法を適用する。他の部品で推定された分布に基づいて各部品の推定を行うことで、部品毎に分布の推定を行いつつ、全体としては部品間の構造を考慮した推定が可能となる。また、部品間の構造を確率分布として表現することにより、構造が厳密に決まっている対象だけでなく、顔部品のように個人差を持つ対象にも対応可能である。

本論文では、提案手法を顔部品検出問題に適用し、本手法の有効性を確認する。顔部品検出問題は、個々の顔部品の属性情報と、顔部品間の構造情報を考慮する必要がある。また、顔部品間の構造には個人差が含まれるため、これらの位置関係に厳密な制約を課すことはできない。このような問題に対して、本論文で提案する構造化 MCMC 法では、構造を確率分布として表現することで、個人差に対応することができる。

2. 構造化 MCMC 法の概要

本章では、本論文で提案する構造化 MCMC 法の概要を説明する。

2.1 問題の定式化

構造化 MCMC 法では、複数の部品からなる対象を扱う。ある部品 i のパラメータを \mathbf{X}_i 、画像特徴を \mathcal{Z}

としたとき、部品 i の事後確率を $p(\mathbf{X}_i|\mathcal{Z})$ と定義する。このとき、 F 個の部品全体に対する事後確率は次のように表される。

$$p(\mathcal{X}|\mathcal{Z}) = p(\mathcal{X}) \prod_i p(\mathbf{X}_i|\mathcal{Z}) \quad (1)$$

$$\mathcal{X} = \{\mathbf{X}_1, \dots, \mathbf{X}_F\}$$

$$\mathcal{Z} = \{\mathbf{Z}_1, \dots, \mathbf{Z}_F\}$$

ただし、 $p(\mathcal{X})$ は、 F 個の部品の同時生起確率であり、部品間の構造を表している。また、 \mathbf{Z}_i は、ある部品 i に関して観測された画像特徴を表す。

このとき、 F 個の部品からなる対象のパラメータの推定は、確率分布 $p(\mathcal{X}|\mathcal{Z})$ の推定問題と考えることができる。ただし、 \mathcal{X} は F 個の部品のパラメータの直積空間であり、これを直接求めるためには、広大な状態空間を扱う必要があり効率的ではない。そこで、本論文ではこれを部品毎のパラメータ推定問題として扱う。

2.2 構造化 MCMC 法の基本原理

ある部品 i の確率分布 $p(\mathbf{X}_i|\mathcal{Z})$ について考える。この \mathbf{X}_i は非常に広いパラメータ空間を持っているため、 $p(\mathbf{X}_i|\mathcal{Z})$ を直接求めることは非常に困難である。

$p(\mathbf{X}_i|\mathcal{Z})$ で \mathbf{X}_i に関してベイズの定理を適用すると、事後確率 $p(\mathbf{X}_i|\mathcal{Z})$ を次式のように変形できる。

$$p(\mathbf{X}_i|\mathcal{Z}) = \frac{p(\mathbf{Z}_i|\mathbf{X}_i)p(\mathbf{X}_i|\mathcal{Z}_i^*)}{p(\mathbf{Z}_i)} \quad (2)$$

$$\mathcal{Z}_i^* = \mathcal{Z} - \mathbf{Z}_i = \{\mathbf{Z}_1, \dots, \mathbf{Z}_{i-1}, \mathbf{Z}_{i+1}, \dots, \mathbf{Z}_F\}$$

ただし、 $p(\mathbf{X}_i|\mathcal{Z}_i^*)$ は、 \mathbf{X}_i の事前分布であり、これは他の部品のパラメータの分布によって決まる。また、 $p(\mathbf{Z}_i|\mathbf{X}_i)$ は尤度であり、あるパラメータ \mathbf{X}_i を仮定したときに観測データ \mathbf{Z}_i が得られる確率を表し、 $p(\mathbf{Z}_i)$ は \mathbf{X}_i に依存しない定数である。

ここで、 i 以外の部品 \mathcal{X}_i^* のパラメータの分布が推定されていると仮定すると、事前分布 $p(\mathbf{X}_i|\mathcal{Z}_i^*)$ は、次式のように求めることができる。

$$p(\mathbf{X}_i|\mathcal{Z}_i^*) = \int_{\mathcal{X}_i^*} p(\mathbf{X}_i|\mathcal{X}_i^*)p(\mathcal{X}_i^*|\mathcal{Z})d\mathcal{X}_i^*$$

$$= \int_{\mathcal{X}_i^*} \left\{ p(\mathbf{X}_i|\mathcal{X}_i^*) \right. \quad (3)$$

$$\left. p(\mathcal{X}_i^*) \prod_{j \neq i} p(\mathbf{X}_j|\mathcal{Z}) \right\} d\mathcal{X}_i^*$$

つまり、他の部品の分布が推定されていれば、それによって部品 i の事前分布を計算することができ、また、その事前分布に従って尤度を計算することで部品 i の事後分布を推定することができる。

しかし、式 (2)、(3) は、部品間で相互に依存関係を持っているため、全ての部品の分布を同時に推定す




図 2 ステップ $k-1$ からステップ k への部品位置推定

ることができない。そこで MCMC の枠組から、これをステップに分けて繰り返し処理によって漸近的に推定する。

あるステップ k において、部品 i について推定される分布 $p(\mathbf{X}_{i(k)}|\mathcal{Z})$ を、次式のように与える。

$$p(\mathbf{X}_{i(k)}|\mathcal{Z}) = \frac{p(\mathbf{Z}_i|\mathbf{X}_{i(k)})p(\mathbf{X}_{i(k)}|\mathcal{Z}_i^*)}{p(\mathbf{Z}_i)}$$

$$p(\mathbf{X}_{i(k)}|\mathcal{Z}_i^*) = \int_{\mathcal{X}_{i(k-1)}^*} \left\{ p(\mathbf{X}_{i(k)}|\mathcal{X}_{i(k-1)}^*)p(\mathcal{X}_{i(k-1)}^*) \prod_{j \neq i} p(\mathbf{X}_{j(k-1)}|\mathcal{Z}) \right\} d\mathcal{X}_{i(k-1)}^* \quad (4)$$

ここで、 $p(\mathbf{X}_{i(k)}|\mathcal{X}_{i(k-1)}^*)$ には、マルコフ過程が成立するので、 $p(\mathbf{X}_{i(k)}|\mathcal{Z})$ が収束するとき、任意の $\mathbf{X}_{i(0)}$ を初期分布として、この繰り返しを無限大まで繰り返すことによって $p(\mathbf{X}_{i(k)}|\mathcal{Z}) = \lim_{k \rightarrow \infty} p(\mathbf{X}_{i(k)}|\mathcal{Z})$ となる。

2.3 ランダムサンプリングによる分布の推定

式 (4) の積分計算は、 $\mathcal{X}_{i(k-1)}^*$ が取りうる全ての値に対して行う必要があるため、これを解くのは現実的ではない。そこで、ランダムサンプリングによって、分布を離散的に近似して推定する。

目的の $p(\mathbf{X}_{i(k)}|\mathcal{Z})$ を $\mathbf{X}_{i(k)}$ のサンプル点 $\{\mathbf{s}_{i(k)}^{(1)}, \dots, \mathbf{s}_{i(k)}^{(N)}\}$ とその重み $\{\pi_{i(k)}^{(1)}, \dots, \pi_{i(k)}^{(N)}\}$ によって近似する。今、サンプル点の集合 $S_{i(k)}$ が $\mathbf{X}_{i(k)}$ の事前分布 $p(\mathbf{X}_{i(k)}|\mathcal{Z}_i^*)$ に従って生成されたとして、 $\pi_{i(k)}^{(m)}$ を次式のように与える。

$$\pi_{i(k)}^{(m)} \propto p(\mathbf{Z}_i|\mathbf{X}_{i(k)} = \mathbf{s}_{i(k)}^{(m)}) \quad (5)$$

k ステップ目のサンプリングを生成する手順は、Condensation²⁾ で用いているのと同様に、重み π の比に従ってサンプル点を選択し、選択されたサンプル点を状態遷移確率に従って変化させることで新しいサンプル点を生成する。ただし、式 (4) に示すように、構造化 MCMC 法の場合、部品の組み合わせに対しての状態遷移確率 $p(\mathbf{X}_{i(k)}|\mathcal{X}_{i(k-1)}^*)$ によって定義されているので、図 2 に示すように、 i 以外の部品の全てのサン

プル点の組み合わせに対しての重みの積を計算し、その値の比に従ってサンプル点の組み合わせと選択する。そして選択されたサンプル点の組み合わせを状態遷移確率 $p(\mathbf{X}_{i(k)}|\mathcal{X}_{i(k-1)}^*)$ に従って変化させることで、新しいサンプル点を生成する。

具体的な推定方法を以下に示す。

現在よりも前の繰り返しの段階 (以下ステップ) $k-1$ におけるサンプルセット $(\mathbf{s}_{i(k-1)}^{(n)}, \pi_{i(k-1)}^{(n)})$, $n = 1, \dots, N$ を用いて現在のステップ k で新しいサンプルセット $(\mathbf{s}_{i(k)}^{(m)}, \pi_{i(k)}^{(m)})$, $m = 1, \dots, N$ を生成する。 n 番目のサンプル点 (サンプル数 N) を生成するルールは以下の通りである。

(1) ステップ $k-1$ におけるサンプルセットの重み $\pi_{i(k-1)}^{(n)}$ から得られる重みの積 $\pi'_{i(k)}$ を

$$\pi'_{i(k)} = \prod_{j \neq i} \pi_{j(k-1)}^{(n)} \quad (6)$$

によって得る。

(2) $\pi'_{i(k-1)}$ の値の比に従って N 個の仮のサンプル点 $\mathbf{s}'_{j(k)}$ を選択する。ここで、ステップ $k-1$ におけるサンプル点 $\mathbf{s}_{j(k-1)}^{(n)}$ の集合 $S_{j(k-1)}$ から $S_{(j \neq i)(k-1)}^*$ を部品 i 以外のサンプル点の集合だと考えると、選択されたサンプル点を

$$p(\mathbf{X}_{i(k)}|\mathcal{X}_{i(k-1)}^* = S_{(j \neq i)(k-1)}^*) \quad (7)$$

に従って再度ランダムサンプリングを行い、新たなサンプル点 $\mathbf{s}_{i(k)}^{(m)}$ を得る。

(3) $\mathbf{s}_{i(k)}^{(m)}$ を用いて、

$$\pi_{i(k)}^{(m)} \propto p(\mathbf{Z}_i|\mathbf{X}_{i(k)} = \mathbf{s}_{i(k)}^{(m)}) \quad (8)$$

となるように $\pi_{i(k)}^{(m)}$ を求める。これによって新しいサンプルセット $(\mathbf{s}_{i(k)}^{(m)}, \pi_{i(k)}^{(m)})$, $m = 1, \dots, N$ を得ることができる。

この (1)-(3) を繰り返すことによって、 $p(\mathbf{X}_{i(k)}|\mathcal{Z})$ を近似的に求める。

3. 構造化 MCMC 法による顔部品検出

本章では、前章で説明した構造化 MCMC 法を顔部品検出問題に適用する方法について述べる。全体の流れを図 3 に示す。

3.1 顔部品と構造のモデル

本論文では、顔部品それぞれのパラメータを顔部品モデルと呼び、顔部品の構造を表したモデルを顔構造モデルと呼ぶ。本節では、その二つについて述べる。

3.1.1 顔部品モデル

一般的に顔部品検出問題では、対象を構成する部品は、各顔部品であり、その間の構造は顔部品の位

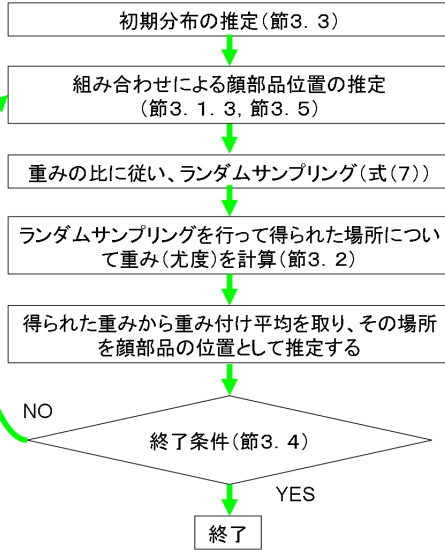


図3 実装フローチャート

置関係として定義できる。なお、本論文では、顔部品として、右目、左目、右鼻の穴、左鼻の穴の4つを用いる。また、各顔部品に対して位置 (x_i, y_i) とスケール s_i をパラメータとして用いる。つまり、顔部品モデルは、 $\mathbf{X}_i = (x_i, y_i, s_i)$ となり、顔全体を $\mathcal{X} = (\mathbf{X}_0, \mathbf{X}_1, \mathbf{X}_2, \mathbf{X}_3)$ と定義する。

3.1.2 顔構造モデル

本論文では、顔部品の構造モデルは、各顔部品位置の同時生起確率として定義する。ここでは、それぞれの顔部品位置で $N(\mu_i, \sigma_i)$ の正規分布を持ったモデルとする。以下、これを顔構造モデルと呼ぶ。

この顔構造モデルを作るために、トレーニング画像を用いて、両目と両鼻の位置を手動で抽出し、その位置によって平均値 μ_i と分散 σ_i を計算した。用いたトレーニングデータの数を n 、それぞれの顔部品の位置を \mathbf{q}_i^j とすると、

$$\mu_i = \frac{1}{n} \sum_{j=0}^n \mathbf{q}_i^j, \quad \sigma_i = \frac{1}{n} \sum_{j=0}^n (\mathbf{q}_i^j - \mu_i)^2 \quad (9)$$

によって顔構造モデルを生成した。その結果は図4のようになる。

3.1.3 顔構造モデルを用いた顔部品位置、スケールの推定

式(4)より、 $p(\mathbf{X}_{i(k)} | \mathcal{Z}_i^*)$ によって得られるものは顔部品の組合せによって得られる顔部品位置である。式(4)では $p(\mathbf{X}_{i(k)} | \mathcal{Z}_i^*)$ がほかの部品からの部品位置が得られる確率 $p(\mathbf{X}_{i(k)} | \mathcal{X}_{i(k-1)}^*)$ と、ほかの




図4 顔構造モデル: () 内は上が x, y 座標を示し、下が x, y の分散を示す

部品の事後確率の積 $\prod_{j \neq i} p(\mathbf{X}_{j(k-1)} | \mathcal{Z})$ によって推定されることを示している。また、ほかの部品の同時生起確率 $p(\mathcal{X}_{i(k-1)}^*)$ を顔構造モデルであると考え、式(4)全体は、パラメータ $\mathcal{X}_{i(k-1)}^*$ を持つ他の部品が現れているとき、顔部品モデル上でパラメータ $\mathbf{X}_{i(k)}$ を持つ部品が現れる確率を示している。本論文では、顔部品モデル上に正規分布を持たせている。 $f(x_i, N(\mu_i, \sigma_i))$ が正規分布 $N(\mu_i, \sigma_i)$ 上に x_i が入力されたときの値であると考え、顔部品位置推定は、 $p(\mathcal{X}_i^*) = \prod_{j \neq i} f(\mathbf{X}_j, N(\mu_j, \sigma_j))$ に従った計算を行うことになる。このように、顔部品候補が得られたときの顔部品の位置推定は顔構造モデルを用いて推定され、以下のように計算する。

ある二つの部品の顔構造モデル座標を (μ_{x_0}, μ_{y_0}) , (μ_{x_1}, μ_{y_1}) とし、それに対応する画像上の2点を $(x_0, y_0), (x_1, y_1)$ とすると、この顔構造モデル座標から画像上の点への変換は、座標系を同次座標系として考えると、

$$\begin{pmatrix} x_0 \\ y_0 \\ 1 \end{pmatrix} = T(\mathcal{X}_i^*) \begin{pmatrix} \mu_{x_0} \\ \mu_{y_0} \\ 1 \end{pmatrix} \quad (10)$$

$$T(\mathcal{X}_i^*) = \begin{pmatrix} \cos \theta & -\sin \theta & t_x \\ \sin \theta & \cos \theta & t_y \\ 0 & 0 & s \end{pmatrix} \quad (11)$$

で表される。 (x_1, y_1) に対しても同様の式が得られ、この二つによって変換パラメータを計算することができる。このとき、 s は拡大縮小成分、 θ は回転成分、 t_x, t_y はそれぞれ x, y 方向への平行移動成分を表す。この式によって、 s, θ, t_x, t_y が得られるので、この変換成分を用いて、顔部品モデル上の他の点での変換を行うこ

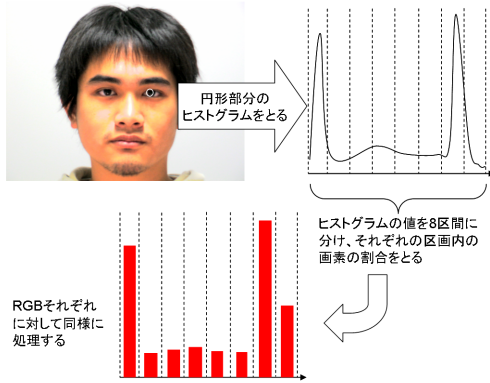


図 5 サンプル点周辺画素のヒストグラムの取り方

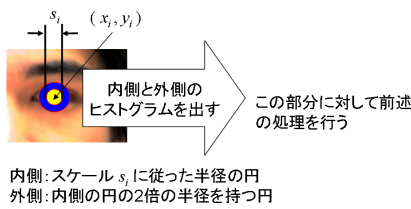


図 6 サンプル点周辺画素の定義

とで、2点から得られる他の点の位置を得ることができる。これによって得られた点が顔部品候補となり、 $p(\mathbf{X}_{i(k)} | \mathcal{X}_{i(k-1)}^*)$ で表される確率を計算することに相当する。

このように、他の部品から得られる部品の位置を推定するとき、2点以上の部品を選んで、そこから顔部品の位置を推定しないと確率密度が収束へと推移していかない。本論文では、最低限の点を用いることで問題を単純化し、2点から得られる部品の位置を求めることにする。

3.2 サンプル点の尤度の評価

本論文では、図 5 に示すように、得られたサンプル点の周辺の画素を用いて尤度の計算を行う。このとき、図 6 に示すように、スケール s_i の半径の内部とその 2 倍の半径を持つ円の内部のヒストグラムを用いる。実際にはヒストグラムの情報をそのまま用いるのではなく、RGB それぞれのヒストグラムの情報を圧縮するためにトレーニングデータを用いて主成分分析を行った結果を用いた。実験で用いた 60 人分 30719 点のトレーニングデータの場合、累積寄与率が 90% となる主成分までを画像特徴として用い、第 12 主成分までを利用した。

トレーニングデータを目、鼻、それ以外の三つのクラスに分けて固有空間内に投影し、サンプル点の尤

度はこの固有空間内での距離によって定義する。あるサンプル点 s_i の尤度 $p(\mathbf{Z}_i | \mathbf{X}_i = s_i)$ を次式のように定義する。ここで、 s_i から各クラス毎の最近傍のトレーニングデータ t_e, t_n, t_b とのユークリッド距離を $d_{i(e)}, d_{i(n)}, d_{i(b)}$ とする。

$$p(\mathbf{Z} | \mathbf{X}_i = s_i) = \frac{\exp(-d_{i(itarget)}^2 k_d)}{\exp(-d_{i(e)}^2 k_d) + \exp(-d_{i(n)}^2 k_d) + \exp(-d_{i(b)}^2 k_d)} \quad (12)$$

また、 $d_{i(itarget)}$ は s_i が i 番目の顔部品だとした場合の部品番号が $itarget$ となるときの距離を意味する。

3.3 SIFT を用いた初期分布の推定

本論文では、画像の局所特徴のみから得られた顔部品候補を初期分布として用いる。特徴点抽出には SIFT⁵⁾ を用いた。この SIFT によって得られる特徴点は画像のピークやエッジ周辺に現れ、多重解像度によって処理を行うため、様々なスケールの特徴点が抽出できる。SIFT では大量な特徴点が抽出され、その全ての点について組合せを考えるのでは計算量が膨大になる。計算量を抑えるために、前節で述べた固有空間内で最近傍識別を行い、目や鼻と識別されたもののみを初期分布として用いる。

このとき、最近傍識別の処理だけでは両目、両鼻の穴の区別がつけられないので、識別によって残った特徴点にはどの顔部品かというラベル付けは行わず、これらの特徴点をすべての顔部品の候補として扱う。

3.4 終了条件

本論文では、繰り返し計算の終了条件を顔部品の分布の広がりによって決定する。分布を広がり計算するために、重みづけ分散を計算した。処理の段階毎で分散の比率を求め、その比率が 1 に近づけば終了とする。このとき、このサンプルを $s_{i(k)}^{(m)}$ 、その平均を $\overline{s_{i(k)}}$ 、重みを $\pi_{i(k)}^{(m)}$ 、サンプル数を N とすると、 $\mathbf{X}_{i(k)}$ の分散 $D[\mathbf{X}_{i(k)}]$ は、

$$\overline{s_{i(k)}} = \frac{1}{N} \sum_m s_{i(k)}^{(m)} \quad (13)$$

$$D[\mathbf{X}_{i(k)}] = \sum_m \pi_{i(k)}^{(m)} \left(s_{i(k)}^{(m)} - \overline{s_{i(k)}} \right)^2 \quad (14)$$

となる。よって D_1 を閾値としたとき、 $|1 - D[\mathbf{X}_{i(k)}] / D[\mathbf{X}_{i(k-1)}]| < D_1$ を満たせば終了させる。

3.5 顔部品検出の安定化

本節では、顔部品検出を安定化させるために用いた方法を述べる。

3.5.1 顔部品位置推定の振動抑制

本手法では、顔部品位置を推定するときに、2点し

か正しい位置に現れていなければ、次のステップにおいて、その2点の他の2点の位置にサンプリングが行われ、ステップごとに顔部品位置が振動が起きてしまう。これを防ぐために、顔部品の推定結果から、同じ顔部品に対してもランダムサンプリングを行い、分布を推定する。

このとき、他の顔部品から得られるサンプル数と、その顔部品自身から得られるサンプル数は、定数 α と全サンプル数 N を用いて、それぞれ $(1 - \alpha)N$ 、 αN と設定する。

3.5.2 顔部品の組合せに対する制約

本手法では、各顔部品のサンプリング回数が多くなると、その組合せを計算するため、計算コストがかかる。また、初期の推定において、各顔部品のラベルが定まらないため、各部品の分布が混ざりあってしまう。そこで、次のようなサンプルの組合せに対するの絞りこみを行う。

3.5.2.1 傾きの制約

まず、顔の傾きについての制約を与える。3.1.3 節の変換パラメータの傾きパラメータ θ を用い、 $|\theta| \leq 20^\circ$ を制約として与える。これによって顔部品の裏返りなども除去できる。

3.5.2.2 スケールの制約

組合せから得られた顔部品にはスケールの情報も含まれる。このときのスケールは変換のときに用いたスケールを意味しており、これを用いて制約をかけることができる。

ある2点について組合せを考えたとき、それぞれの点を計算するとき用いたスケールを s_1, s_2 とする。この比率 s_2/s_1 は2点のスケールの大きさの違いを示し、その違いが30%未満の場合のみを可能性に加える。よって、 $|1.0 - (s_2/s_1)| < 0.7$ となる2点の組合せを正しい組合せとする。

4. 評価実験

4.1 実験環境

本論文に用いた実験環境を表1に示す。

表1 使用したPCとカメラ

CPU	Pentium 4 3.04G Hz
Memory	1G bytes
カメラ	SONY DFW-VL500

カメラで撮影された画像サイズは、640 × 480 ピクセルで、撮影するときの照明条件は全て同じようにした。また、用いた画像は総数95枚、そのうちトレーニングに用いた画像は64枚で、テスト用画像は残った

31枚とした。この画像は背景が白色で、目と鼻が人間の判断で区別可能なものであり、顔が正面を向いて、傾きはほぼ無いものを用いている。また、眼鏡をかけた場合も用いている。

トレーニングに関しては、ポジティブデータはSIFTの処理によって得られる特徴点の中の顔部品に現れたキーを用いてトレーニングを行う。また、ネガティブデータは誤った場所に現れるキーに関してトレーニングを行う。これによって顔部品の最近傍識別器を作成した。

4.2 実験結果

実験に用いた画像と初期にSIFTによって抽出された部品位置候補の例を図7に初期の部品候補を示している。ただし、目か鼻かということは考えずに点の構造関係を見ている。

図8に、図7(a)の画像の顔部品候補を元に得られた顔部品の位置推定の結果を示す。図8の左の図はランダムサンプリングによって得られる顔部品候補であり、右の図は各サンプル点の尤度を重みとした重みづけ平均によって期待値を出した結果である。左の画像から順番に初期状態、5回目のサンプリング、11回目のサンプリングの結果である。

初期の部品候補検出では、顔部品の候補が両鼻と、右目の部分と左目の一部に現れているが、他のところにも現れていることが分かる。また、繰り返しの処理を行うことによって正確な場所へ分布が集まっていく様子が見られる。

図7(b)に対する推定結果を図9に示す。この結果では、眼鏡をかけたときの顔部品位置の推定結果を表している。この結果を見ると、眼鏡のフレームには影響されず顔部品位置が推定できている。

全テストデータに顔部品の位置推定を行った結果、31枚中24枚が推定に成功した。残りの7枚は完全に失敗したものが5枚で、あとの2枚の例が図7(c)の画像であり、図10に示すように目と鼻が現れているものの、他のところでも尤度が高くなって、結果的に部品位置推定に失敗しているものである。その原因は尤度の計算に用いる画像特徴の選び方によるものだと思う。

これらの顔部品位置の重みづけ分散を図11に示す。これは顔部品それぞれの重みづけ分散の平均値を取ったものであり、右に示すものが x の分散で、左が y の分散を示す。これを見れば分かるように、成功した例の(a),(b)では分散が小さく、振動も見られないが、失敗した例では分散が大きく、振動している。

5. ま と め

本論文では MCMC 法を構造に対して拡張した構造化 MCMC 法を提案した. 本手法に基づいて, 顔部品の構造と顔部品を同次に考慮した, 顔部品の位置を推定した. 本手法では他の顔部品から顔部品位置を予測することによって, 未検出の顔部品を誤りを含んでいる場合でも顔部品の検出を行うことができ, 構造を含んだ対象に有効であることが確認できた.

今後の課題として, 顔部品検出の検出率がまだ不十分であるので, 提案手法のフレームワークを基に, 顔部品の検出失敗の原因と考えられる尤度の評価方法や, 初期分布の推定方法などの検討が挙げられる. また, 今回用いた顔画像はほぼ正面画像であったが, 本手法は本質的には, 角度やスケール変化に対して安定であるので, 今後, これらの顔画像にも適用し, 有効性を確認していく.


構造化 MCMC 法は他の構造関係が存在する対象にも適用することができると考えられる. 例えば, 多関節モデルをもったロボットが挙げられる. そのような対象への適用も考えていく予定である.

参 考 文 献


- 1) Gelfand, A. E. and Sahu, S. K.: Identifiability, improper priors, and Gibbs sampling for generalized linear models, *Journal Of the American Statistical Association*, Vol.94, pp. 247–253 (1999).
- 2) Isard, M. and Blake, A.: Condensation – conditional density propagation for visual tracking, *International Journal of Computer Vision*, Vol. 29, No. 1, pp. 5–28 (1998).
- 3) MacCormick, J. and Isard, M.: Partitioned Sampling, Articulated Objects, and Interface Quality Hand Tracking, *ECCV*, pp. 3–19 (2000).
- 4) Isard, M. and Blake, A.: ICondensation: Unifying low-level and high-level tracking in a stochastic framework, *5th European Conference Computer Vision (ECCV1998)*, pp. 893–908 (1998).
- 5) Lowe, D. G.: Towards a Computational Model for Object Recognition in IT Cortex, *First IEEE International Workshop on Biologically Motivated Computer Vision*, pp. 20–31 (2000).



(a)




(b)




(c)

図 7 はじめの顔部品候補の例



$k = 0$




$k = 5$




$k = 11$


図 8 顔部品位置の推定: 上下が k ステップでの位置推定で、上はランダムサンプリング、下はそのサンプルの重み付け平均を表す



$k = 0$




$k = 5$




$k = 14$


図 9 眼鏡をかけたときの顔部品の分布



$k = 0$




$k = 16$




$k = 36$


図 10 失敗例での顔部品の分布



(a)



(b)



(c)

図 11 顔部品位置の重みづけ分散の推移