

自己組織化型状態空間モデルを用いた運動軌跡のフィルタリング

市 村 直 幸†

時系列画像上での特徴点追跡により得られる運動軌跡には、観測ノイズとともに、誤対応ともなう外れ値が含まれる。この観測ノイズと外れ値の影響軽減のため、状態空間モデルを用いた時系列フィルタリングを用いる。適切な状態推定を行うためには、状態推定を司る時変な超パラメータを特徴点の運動に応じてオンライン推定する必要がある。本論文ではその推定のために、特徴点の座標とともに超パラメータを状態に含め同時推定する自己組織化型状態空間モデルを用いる。状態推定には逐次モンテカルロ法を適用するため、非線形なモデルの線形近似は必要としない。人工データおよび実データを用いた実験結果から、提案したフィルタの有効性を検討した。

Stochastic Filtering of Motion Trajectory Using a Self-organizing State Space Model

NAOYUKI ICHIMURA†

Observation noise and outliers are normally contained in motion trajectories obtained by tracking feature points in image sequences. A stochastic filtering based on state space model is used to reduce the effect of observation noise and outliers. To carry out proper state estimation, time-dependent hyper-parameters governing state estimation should be determined in accordance with motion of feature point. A self-organizing state space model is introduced to estimate hyper-parameters. In the self-organizing state space model, feature coordinates and hyper-parameters are included in state vector and they are estimated simultaneously online. Since Monte Carlo filter is used for state estimation, linear approximation for nonlinear model is not needed. Experiments are done to consider the usefulness of the proposed filter.

1. ま え が き

時系列画像上での特徴点の追跡は、時系列画像解析のための重要な処理である。追跡の結果である特徴点の運動軌跡には、観測ノイズとともに、特徴点抽出の誤り（追跡に不適当な性質を持つ特徴点の抽出）やフレーム間の輝度変動等に起因する誤対応ともなう外れ値が混入する。運動軌跡を利用する動きからの形状復元^{1),2)}や複数運動の分割^{3),4)}等の処理において、観測ノイズや外れ値の影響軽減は、精度向上等のために重要である。

観測ノイズや外れ値の影響を軽減する一方法として、状態空間モデルを用いた時系列フィルタリングがある^{5)~9)}。時系列フィルタリングでは、特徴点の運動やノイズに関する事前的知識と観測値を用いた状態推定を通じ、真の特徴点の位置を推定する。真の軌跡と

の誤差を小さくするためには、ノイズ分布の分散等の超パラメータ (hyper-parameter) を適切に設定する必要がある。観測系列 $Y_t = \{y_1, y_2, \dots, y_t\}$ のゆう度 $p(y_k | Y_{k-1})$, $k = 1, 2, \dots, t$ により超パラメータを推定できるが、数値探索に多くの計算量を必要とするため、オンライン処理である追跡への適用は難しい。一般に、運動の統計的性質は時間とともに変動するため、それに応じた超パラメータをオンラインで効率的に推定する必要がある。

時間的に変動する超パラメータを推定する1つの方法に、多重モデル適応フィルタ (multiple-model adaptive filter) がある¹⁰⁾。この方法では、異なる超パラメータを持つ複数のモデルを用意し、それらのモデルの状態推定結果を観測値に対する各モデルのゆう度に基づいて統合する。この方法は有効ではあるが、すべての超パラメータの組合せを前もって与えておく必要があるため、もし適切な超パラメータが前もって想定した範囲を逸脱した場合に適切な状態推定が行えない。さらに、超パラメータの数が多い (たとえば4以上) 場合や、状態推定の精度向上のため超パラメータの量

† 産業技術総合研究所情報処理研究部門
Information Technology Research Institute, National
Institute of Advanced Industrial Science and Technol-
ogy (AIST)

子化幅を小さくする場合に、超パラメータの組合せ数が膨大となり、きわめて多くのフィルタが必要となる問題がある。

本論文では、超パラメータを状態に含め、特徴点の座標と同時にオンライン推定するフィルタリング方法を検討する。この同時推定により、特徴点の運動に適応するように超パラメータを自動的に調整できる。このように自らの振舞いを自動的に調整する状態空間モデルは、自己組織化型状態空間モデルと呼ばれる¹¹⁾。この方法の1つの問題点は、超パラメータを状態に含めるためモデルが非線形となり、非線形モデルに適用可能な状態推定方法を必要とすることである。しかし、近年、非線形非ガウス型状態空間モデルに適用可能な逐次モンテカルロ法 (sequential Monte Carlo (SMC)) と総称される方法が提案されている^{12)~15)}。本論文では、SMCの一種であるモンテカルロフィルタ (Monte Carlo filter (MCF))³⁾ を状態推定に適用する。

超パラメータを状態に含めオンライン推定することは、1970年代から提案されていた。しかし、モデルの線形近似を必要とし、また状態とノイズの分布のガウス性を仮定する拡張カルマンフィルタを用いたため、適切な状態推定が行えなかった^{11),16)}。MCFではそのような近似や仮定を必要としないため、適切な状態推定が行える可能性がある。また、ノイズ分布のガウス性を仮定しないため、外れ値除去に有効な裾の重い (heavy tailed) 非ガウス分布を観測ノイズ分布として使用できる^{17)~19)}。

上記の超パラメータのオンライン推定と裾の重い非ガウス分布の使用により、その統計的性質が時間的に変動し、かつ、外れ値を含む運動軌跡に対する適応フィルタリングが実現できる。人工データおよび実データを用いた実験により、その有用性を検討する。

2. 運動軌跡のための状態空間モデル

2.1 状態空間モデルの表記と事前モデル

状態空間モデルを以下のように表す。

$$\mathbf{x}_t = \mathbf{F}\mathbf{x}_{t-1} + \mathbf{G}\mathbf{v}_t \quad (1)$$

$$\mathbf{y}_t = \mathbf{H}\mathbf{x}_t + \mathbf{w}_t \quad (2)$$

式(1)は状態遷移方程式であり、 \mathbf{x}_t は状態変数ベクトル、 \mathbf{v}_t はシステムノイズベクトルである。行列 \mathbf{F} と \mathbf{G} はシステム行列である。式(2)は観測方程式であり、 \mathbf{y}_t は観測ベクトル、 \mathbf{w}_t は観測ノイズベクトルである。行列 \mathbf{H} は観測行列である。

状態空間モデルに基づく時系列フィルタリングの目的は、現時刻 t までの観測系列 $Y_t = \{y_1, \dots, y_t\}$ に




図1 超パラメータの状態推定への影響の一例。(a) $\tau^2 = 1.0$, $\sigma^2 = 1.0$ 。(b) $\tau^2 = 0.01$, $\sigma^2 = 50.0$

Fig.1 An example of the effect of hyper-parameters for state estimation. (a) $\tau^2 = 1.0$ and $\sigma^2 = 1.0$, (b) $\tau^2 = 0.01$ and $\sigma^2 = 50.0$.

基づく、状態変数ベクトル \mathbf{x}_t の推定である。そして、この推定は、条件付き確率 $p(\mathbf{x}_t | Y_t)$ の計算により行われる。

観測ベクトル $\mathbf{y}_t = [x(t), y(t)]^T$ は、特徴点の画像上の位置座標の観測値である。この観測値に対し、次の滑らかさ表す事前モデルを使用する。

$$x(t+1) = 2x(t) - x(t-1) \quad (3)$$

$$y(t+1) = 2y(t) - y(t-1) \quad (4)$$

このモデルは、特徴点座標の2階差分が0、すなわち速度が滑らかに変化することを表している。

2.2 ノイズ分布と超パラメータ

システムノイズベクトル \mathbf{v}_t は、各次元が独立に密度関数 $q(\mathbf{v}; m_q, \tau^2)$ に従う白色ノイズであるとする。 m_q と τ は位置(location)と尺度(scale)を表すパラメータである。システムノイズ分布の多変数表現は $q_v(\mathbf{v}_t; m_{vq}, T)$ とする。観測ノイズベクトル \mathbf{w}_t は、各次元が独立に密度関数 $r(\mathbf{w}; m_r, \sigma^2)$ に従う白色ノイズであり、その多変数表現は $r_v(\mathbf{w}_t; m_{vr}, \Sigma)$ とする。本論文では、ノイズ分布の位置は0と仮定するので、 m_{vq} と m_{vr} の要素はすべて0となる。

ノイズ分布の尺度 τ と σ は状態推定を司るパラメータであり、これらは超パラメータと呼ばれる。図1は超パラメータの状態推定への影響を表す一例である。これは、式(3)と(4)の事前モデルとカルマンフィルタを用いた結果である。同じ観測値に対して、2つの超パラメータ $(\tau^2, \sigma^2) = (1.0, 1.0)$ (図1(a))と $(0.01, 50.0)$ (図1(b))を用いると、状態推定結果はまったく違ったものになる。特徴点の運動が事前モデルの仮定に近ければ、システムノイズ分布の分散が小

さく観測ノイズ分布の分散が大きな図 1 (b) の推定結果が望ましい。しかし、運動が事前モデルの仮定から逸脱していれば、より観測を優先する、つまり観測ノイズ分布の分散が小さな図 1 (a) の推定結果が望ましい。この例が示すように、超パラメータを特徴点の運動に応じて変化させないと、適切な推定結果を得ることはできない。

観測系列に対するゆう度 $p(y_k | Y_{k-1}; \theta)$, $k = 1, 2, \dots, t$, $Y_0 = \phi$, $\theta = \{\tau, \sigma\}$ の使用が、超パラメータの決定の一方法である。しかし、この方法は数値探索に多くの計算量を必要とし、オンライン処理である特徴点の追跡に用いることが難しい。時間とともに変動する運動の統計的性質に応じた超パラメータを、効率的にオンライン推定する方法が必要となる。

2.3 超パラメータ推定のための自己組織化型状態空間モデル

式 (3) と (4) の事前モデルより、状態変数ベクトルには $x(t)$, $y(t)$, $x(t-1)$ および $y(t-1)$ を含める。また、超パラメータ τ , σ も含める。

$$\mathbf{x}_t = [x_s(t), y_s(t), x_s(t-1), y_s(t-1), \log \tau^2(t), \log \sigma^2(t)]^T \quad (5)$$

超パラメータの対数は、ノイズ分布の尺度を正の値に保つためのものである。このように超パラメータを状態に含め、特徴点の座標と同時にオンライン推定する。この同時推定により、特徴点の運動に適応するように超パラメータを自動的に調整できる。このような自らの振舞いを自動的に調整する状態空間モデルは、自己組織化型状態空間モデルと呼ばれる¹¹⁾。

状態空間モデルの要素、行列 F , G , H およびノイズベクトル v_t , w_t を以下に示す。

$$\mathbf{F} = \begin{bmatrix} 2 & 0 & -1 & 0 & 0 & 0 \\ 0 & 2 & 0 & -1 & 0 & 0 \\ 1 & 0 & 0 & 0 & 0 & 0 \\ 0 & 1 & 0 & 0 & 0 & 0 \\ 0 & 0 & 0 & 0 & 1 & 0 \\ 0 & 0 & 0 & 0 & 0 & 1 \end{bmatrix}, \mathbf{G} = \begin{bmatrix} 1 & 0 & 0 & 0 \\ 0 & 1 & 0 & 0 \\ 0 & 0 & 0 & 0 \\ 0 & 0 & 0 & 0 \\ 0 & 0 & 1 & 0 \\ 0 & 0 & 0 & 1 \end{bmatrix}$$

$$\mathbf{H} = \begin{bmatrix} 1 & 0 & 0 & 0 & 0 & 0 \\ 0 & 1 & 0 & 0 & 0 & 0 \end{bmatrix} \quad (6)$$

$$\mathbf{v}_t = [v_x(t), v_y(t), v_{\tau^2}(t), v_{\sigma^2}(t)]^T \quad (7)$$

$$\mathbf{w}_t = [w_x(t), w_y(t)]^T \quad (8)$$

ここで、 v_{τ^2} と v_{σ^2} は超パラメータに対するシステムノイズ変数である。このノイズの付加が、超パラメータの時間変化を可能にする。システムノイズ分布 $q_v(\mathbf{v}_t; \mathbf{m}_{vq}, \mathbf{T})$ の位置と尺度は $\mathbf{m}_{vq} = [0, 0, 0, 0]^T$ と $\mathbf{T} = \text{diag}(\tau^2, \tau^2, \nu^2, \xi^2)$ である。観測ノイズ分布 $r_v(\mathbf{w}_t; \mathbf{m}_{vr}, \Sigma)$ の位置と尺度は $\mathbf{m}_{vr} = [0, 0]^T$ と

$\Sigma = \text{diag}(\sigma^2, \sigma^2)$ である。

超パラメータに対するシステムノイズの尺度 ν と ξ は超パラメータの変化を司るため、超々パラメータ (hyper-hyper-parameter) と呼ばれる。

3. モンテカルロフィルタによる状態推定

3.1 モンテカルロフィルタのアルゴリズム

ノイズベクトルが状態に含めた超パラメータに依存するため、2.3 節の状態空間モデルは非線形となる。よって、非線形モデルに適用可能な状態推定方法が必要となる。ここでは、モンテカルロフィルタ (MCF)¹³⁾ を状態推定に使用する。以下にそのアルゴリズムを示す。

MCF では、状態推定に用いる予測分布 $p(\mathbf{x}_t | Y_{t-1})$ およびフィルタ分布 $p(\mathbf{x}_t | Y_t)$ を、その分布から得られる m 個の実現値 (粒子 (particle) と呼ばれる) を用いて近似する。その粒子を $\{p_t^{(i)}\}_{i=1}^m$ および $\{f_t^{(i)}\}_{i=1}^m$ と表す。また、システムノイズ分布も同様に、粒子 $\{v_t^{(i)}\}_{i=1}^m$ で近似する。これらの粒子を用いた 1 期先予測とフィルタの繰返しで、状態推定は行われる。

[MCF アルゴリズム]

[Step 1: 初期分布の粒子の生成]

状態の初期分布 $p_0(\mathbf{x})$ に従う乱数ベクトルを m 個発生し、初期のフィルタの粒子 $\{f_0^{(i)}\}_{i=1}^m$ を得る。

[Step 2: フィルタリング] 次の処理を繰り返す。

[Step2-1: システムノイズ分布に従う粒子の発生] システムノイズ分布に従う乱数ベクトルを m 個発生し、粒子 $\{v_t^{(i)}\}_{i=1}^m$ を得る。

[Step 2-2: 1 期先予測] 次式より、予測分布 $p(\mathbf{x}_t | Y_{t-1})$ に従う粒子 $\{p_t^{(i)}\}_{i=1}^m$ を得る。

$$p_t^{(i)} = \mathbf{F} f_{t-1}^{(i)} + \mathbf{G} v_t^{(i)} \quad (9)$$

[Step 2-3: 予測分布に従う粒子のゆう度の計算] 粒子 $\{p_t^{(i)}\}_{i=1}^m$ のゆう度 $\{\alpha_t^{(i)}\}_{i=1}^m$ を観測値 y_t と観測ノイズ分布より得る。

$$\alpha_t^{(i)} = r_v(y_t - \mathbf{H} p_t^{(i)}; \mathbf{m}_{vr}, \Sigma) \quad (10)$$

[Step 2-4: フィルタ] 1 期先予測により得た粒子 $\{p_t^{(i)}\}_{i=1}^m$ を次の確率に従いサンプリングし、フィルタ分布 $p(\mathbf{x}_t | Y_t)$ に従う粒子 $\{f_t^{(i)}\}_{i=1}^m$ を得る。




図 2 異なる超パラメータを持つ観測ノイズ分布の例

Fig. 2 An example of observation noise distributions with different hyper-parameters.

$$Pr\left(\mathbf{f}_t^{(i)} = \mathbf{p}_t^{(i)}\right) = \frac{\alpha_t^{(i)}}{\alpha_t^{(1)} + \dots + \alpha_t^{(m)}} \quad (11)$$

Step 2-1, 2-2 により, 状態遷移方程式による 1 期先予測を行う. そして, Step 2-3, 2-4 により, 観測値 y_t と 1 期先予測位置 $H\mathbf{p}_t^{(i)}$ の差を観測ノイズ分布により評価した式 (10) のゆう度を使い, 1 期先予測分布の粒子 $\left\{\mathbf{p}_t^{(i)}\right\}_{i=1}^m$ の中から粒子を選択している. この処理によって, 状態推定結果を表すフィルタ分布が, 状態遷移方程式が表す対象の運動モデル, そして, 観測値および観測ノイズのすべてを考慮した状況で更新される.

3.2 MCF による超パラメータ推定の説明

Step 2-4 のリサンプリングに用いる粒子のゆう度は, 観測位置と予測位置の差および観測ノイズ分布により計算される(式 (10)). 高いゆう度を持つ粒子はリサンプリングで生き残るため, その粒子(状態ベクトル)に含まれる超パラメータが, 特徴点の運動にフィルタを適応させるための良い超パラメータとして選択される.

図 2 に, 異なる超パラメータを持つ 2 つの観測ノイズ分布の例を示す. もし, 観測位置と予測位置の差が -1 ならば, 分布 A は分布 B に比べ高いゆう度を与える. よって, 分布 A の超パラメータが高い確率で選択される. 一方, もし, 観測位置と予測位置の差が 5 ならば, 分布 B の超パラメータが高い確率で生き残る. このように, MCF におけるリサンプリングによって, 特徴点の運動に適応する超パラメータが選択される.

4. 非ガウス観測ノイズ分布

MCF は非線形非ガウス型状態空間モデルの状態推定に適用可能なため, 観測ノイズ分布に外れ値の影響軽減に有効な裾の重い非ガウス分布を用いる^{17)~19)}.




図 3 外れ値除去と運動変化への追跡のトレードオフ

Fig. 3 Tradeoff between outlier rejection and tracking abrupt changes in motion.

ここでは, 次式のコーシー分布 $C(0, \sigma^2)$ を用いる.

$$r(w; 0, \sigma^2) = \frac{\sigma}{\pi \{w^2 + \sigma^2\}} \quad (12)$$

この分布はガウス分布より裾が重く, 高い頻度で発生する観測ノイズと低い頻度で発生する外れ値を同時に表現できる. このような表現ができる裾の重い分布が外れ値の影響軽減に有効な理由は, モンテカルロフィルタアルゴリズムの Step 2-3 の式 (10) により説明できる. 式 (10) において観測値 y_t が外れ値であったとする. この際, 予測分布の粒子 $\mathbf{p}_t^{(i)}$ から得られる 1 期先予測位置 $H\mathbf{p}_t^{(i)}$ と, 観測値 y_t の差が大きくなり, 予測分布の中心付近にある粒子に対するゆう度は小さくなる傾向にある. しかし, 観測ノイズ分布 $r_v(w_t; m_{vr}, \Sigma)$ として上記のような裾の重い分布を使うと, ガウス分布に比べ予測分布の中心付近にある粒子に対するゆう度は大きくなる. その結果, 予測分布の中心付近にある粒子がリサンプリングされる確率が高くなる. よって, 状態推定結果であるフィルタ分布が外れ値に引きずられる確率が低くなり, 外れ値の影響を受けにくくなるのである. これらのことから, 裾の重い観測ノイズ分布を用いることにより, 外れ値の混入した運動軌跡に対する状態推定を実現できる.

5. 実験

提案方法の有効性を検討するため, 人工データおよび実データを用いた実験結果を示す.

5.1 人工データ: トレードオフの調整問題

4 章で述べたように, 裾の重い観測ノイズ分布の使用により, 外れ値の影響を軽減する状態推定が行える. しかし, 外れ値の影響軽減により, 運動変化への追跡に遅れが生じる可能性がある(図 3). 本実験では, フィルタの適応能力を検討するため, この外れ値除去と運動変化への追跡のトレードオフの調整問題を取り扱う. このトレードオフの調整は, 超パラメータの調整と等価である. たとえば, システムノイズの尺度を大きくすれば予測範囲が広くなり, 変化に対し俊




図 4 実験に用いた人工データ。実線は真の運動軌跡であり、破線は観測ノイズと外れ値を含む観測値である

Fig.4 Synthetic data used in the experiment. The solid line represents the true trajectory and the dotted line represents observation with noise and outliers.

敏な追跡が行えるが、外れ値の影響を受けやすくなる。現在の特徴点の動きに応じて、必要な超パラメータがオンライン推定できれば、このトレードオフは適切に調整されるはずである。

図 4 の人工データを使用した。このデータには、3 つの外れ値 ($t = 15, 30, 75$) と急激な運動変化 ($t = 50$) がある。状態推定の際、特徴点の座標および超パラメータに対するシステムノイズ分布にもコーシー分布 $C(0, \tau^2)$ を用いた。これにより、高い頻度で発生する滑らかな動きと、低い頻度で発生する急激な運動変化の両方を表現する。

提案したフィルタの最も良い性能を評価するため、ここでは超々パラメータ ν と ξ を観測系列に対するゆう度を用いて求めた²⁰⁾。ゆう度 $l(\nu, \xi)$ は、次式より近似的に計算できる¹³⁾。

$$l(\nu, \xi) \cong \sum_{t=1}^N \log \left(\sum_{i=1}^m \alpha_t^{(i)} \right) - N \log m \quad (13)$$

ここで、 $\alpha_t^{(i)}$ は MCF アルゴリズムの Step 2-3 で求めるゆう度であり、 N は観測系列 Y_t の長さである。数値探索には粗探索を用いた。つまり、まず (ν, ξ) に対し $\{1, 2, \dots, 20\} \times \{1, 2, \dots, 20\}$ の粗いグリッドを用意し、そのすべての組合せについて式 (13) を計算して超々パラメータの最ゆう推定値を求める。その値を用いより細かいグリッドを設定し、さらに探索を行う。表 1 に得られた推定値を示す。

MCF で用いる粒子数 m は 10,000 とした。特徴点の位置の初期分布には、平均 $[x(1), y(1), x(1), y(1)]^T$ 、共分散行列 $\text{diag}(10, 10, 10, 10)$ のガウス分布を用いた。また、超パラメータの初期分布は、

表 1 ゆう度により推定した、提案したフィルタの超々パラメータとカルマンフィルタと MCF の超パラメータ、および、真の運動軌跡と推定結果の間の平均 2 乗誤差 (MSE)

Table 1 Hyper-hyper-parameters determined for the proposed filter, hyper-parameters determined for Kalman filter and MCF, and mean squared error (MSE) between estimated and true trajectories of both filters.

Proposed filter			Kalman filter		
ν^2	ξ^2	MSE	τ^2	σ^2	MSE
0.006	0.034	0.118	0.20	8.5	0.269
MCF					
τ^2	σ^2	MSE			
0.006	0.14	0.128			

$[-8, 8]$ の範囲の一樣分布とした。特徴点の推定位置は、状態推定結果の粒子 $f_t^{(i)}$ の $x_s(t)$ と $y_s(t)$ から Parzen 推定²¹⁾ により 2 次元確率分布を求め、そのモードより得た。超パラメータの推定値も同様に、1 次元確率分布を求め、そのモードより得た。

提案したフィルタの性能を評価するため、カルマンフィルタとの比較を行った。カルマンフィルタは線形ガウスモデルを仮定するため、式 (5) の状態変数ベクトルから超パラメータを取り除き、ノイズ分布にガウス分布を仮定した。最も良い性能を比較するため、超パラメータ τ と σ はゆう度を用いて求めた。線形ガウスモデルに対するゆう度は、ガウス分布となる予測分布に対する観測値のゆう度として計算できる。表 1 に得られた推定値を示す。

また、超パラメータのオンライン推定を用いた状態推定結果が、ゆう度を用いて超パラメータをオフラインで推定した場合と同等の性能を持つかどうかを確認する必要もある。よって、提案したフィルタと同じノイズ分布を持つモデルの超パラメータをオフライン推定した場合との比較も行った。超パラメータの推定に用いたゆう度は式 (13) と同じであるが、変数は超パラメータ τ, σ となる。表 1 に得られた推定値を示す (このフィルタは単に MCF と記述している)。

状態推定の結果、カルマンフィルタでは外れ値の影響により推定誤差が大きくなるが、提案したフィルタでは明らかに外れ値の影響が軽減されていた (図 5 (a), (b) および図 6 (a) ~ (d))。提案したフィルタでの超パラメータの時間変化を見ると (図 7)、急激な運動方向の変化が生じた $t = 50$ 付近で、システムノイズの尺度 τ が急激に増加している。これは、運動方向の変化へ追従するために、フィルタが追跡速度を司るシステムノイズの尺度を増加させたためである。この自動的な超パラメータの調整により、 $t = 50$ 付近での

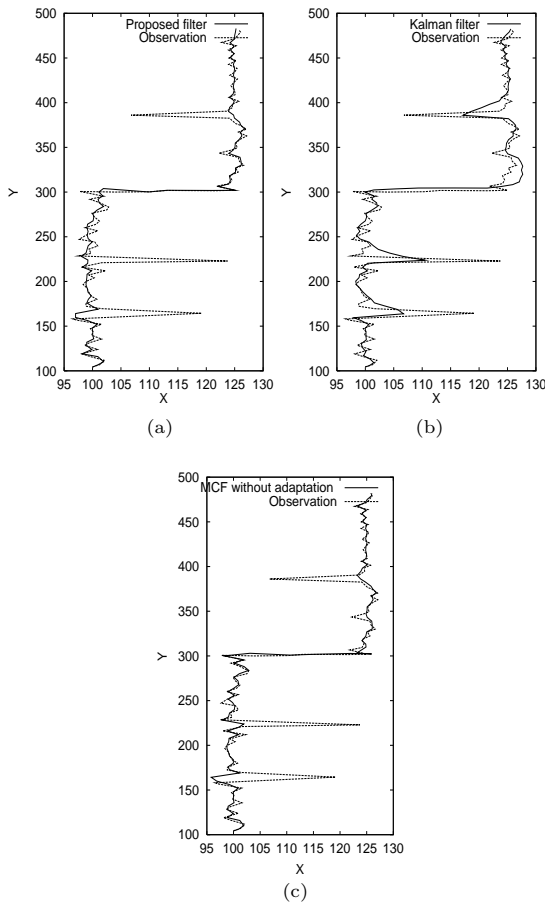


図 5 人工データに対する状態推定結果 . (a) 提案したフィルタ . (b) カルマンフィルタ . (c) 超パラメータをオフライン推定した MCF . 破線が観測値, 実線が推定結果を表す

Fig. 5 Filtering results for synthetic data. (a) proposed filter, (b) Kalman filter, (c) MCF with hyper-parameters estimated offline. The dotted line represents observation and the solid line represents estimation result.

推定誤差がカルマンフィルタに比べ小さくなっている (図 6 (a) ~ (d)). 真の運動軌跡と推定結果の間の平均 2 乗誤差でも, 提案したフィルタがより正確な状態推定を行っていることが分かる (表 1).

また, 超パラメータをオフライン推定した場合と比較すると, 状態推定結果はほぼ同様のものが得られている (図 5 (a), (c) および 図 6 (a), (b), (e), (f)). 真の運動軌跡と推定結果の間の平均 2 乗誤差はわずかであるが小さくなっている (表 1). これによって, 超パラメータのオンライン推定によっても, 超パラメータをオフライン推定した場合と同等の状態推定が行えることが確認できた .

この実験ではすべてのフィルタの最も良い性能を比較するため, データが事前に得られているものとして

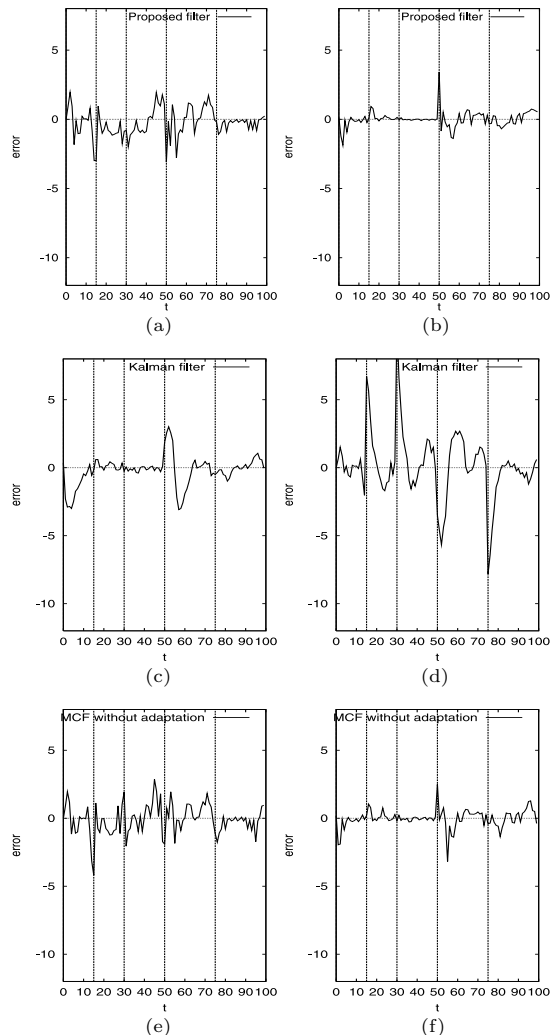


図 6 人工データの各時刻における推定誤差 . (a), (b) : 提案したフィルタにおける x 座標と y 座標の誤差 . (c), (d) : カルマンフィルタにおける x 座標と y 座標の誤差 . (e), (f) : 超パラメータをオフライン推定した MCF における x 座標と y 座標の誤差 . 垂直な線は, 外れ値 ($t=15,30,75$) と急激な運動変化 ($t=50$) が生じた時間を表す

Fig. 6 Error in coordinates for synthetic data. Abscissa represents time. (a),(b): error in x and y coordinates for the proposed filter, (c),(d): error in x and y coordinates for the Kalman filter, (e),(f): error in x and y coordinates for the MCF with hyper-parameters estimated offline. Vertical lines show when outliers ($t=15,30,75$) and abrupt change in motion ($t=50$) occur.

超々パラメータや超パラメータをゆる度を用いて求めた . この過程で超々パラメータを求めることは, 超パラメータを求めることとは違い, 超パラメータをどのくらいの速さで変化させれば状態推定誤差を小さくできるかということの状態空間モデルに獲得させていることになる . 実際のオンライン処理では, 事前にすべ




図 7 超パラメータ, $\log_{10}(\tau^2)$ (実線) と $\log_{10}(\sigma^2)$ (破線), の時間変化

Fig. 7 Changes in hyper-parameters, $\log_{10}(\tau^2)$ and $\log_{10}(\sigma^2)$, in the filtering.

てのデータが得られるということではなく,このような処理はできない.しかし,あるデータを使って超々パラメータを求めることによってモデルが獲得する超パラメータの変化のさせ方は,他のデータに対しても適用可能と思われる.つまり,あるデータを使って“学習した”超々パラメータは,学習に用いたデータ以外にも効果を発揮すると思われる.一方,超パラメータを学習した場合には,学習に用いたデータには有効ではあるが,それ以外のデータに適用できるとはいい難い.なぜなら,モデルが獲得しているのはあくまで与えられたデータに対するノイズの性質であり,超々パラメータを求めた場合のようにノイズの時間的な変化に対する追従の方法を獲得しているわけではないからである.この点を確認するために,次節では本節で得られた超パラメータと超々パラメータを用いて,他のデータに対して処理を行った結果を示す.

5.2 人工データ：オンライン処理

オンライン処理では事前にすべてのデータが与えられることはないため,5.1節のようにゆう度を用いて超パラメータや超々パラメータを推定することはできない.よって,前もって何らかの方法でこれらのパラメータを設定しておく必要がある.ここでは,5.1節で得られたパラメータを用いてデータのオンライン処理を行い,提案したフィルタの超パラメータのオンライン推定が,超々パラメータの推定に用いたデータ以外にも効果を発揮することを示す.

図 8 の人工データを使用した.このデータには,外れ値 ($t = 75$) と急激な運動変化 ($t = 30, t = 36, t = 50$) がある.5.1節同様に 3 つのフィルタで処理を行った.

状態推定の結果,提案したフィルタでは最初の急激な運動変化において大きな誤差が生じるものの,シス




図 8 実験に用いた人工データ.実線は真の運動軌跡であり,破線は観測ノイズと外れ値を含む観測値である.このデータの処理のために,5.1節で求めた超パラメータと超々パラメータを用いる

Fig. 8 Synthetic data used in the experiment. The solid line represents the true trajectory and the dotted line represents observation with noise and outliers. The hyper-parameters and hyper-hyper-parameters computed in the Section 5.1 were used to process this data.

テムノイズの超パラメータを急激に増加させることによりその誤差をすぐに押さえ込んでいる.それ以後の運動変化にも同様に対処できており,また,外れ値の影響も軽減されている(図 9 (a), 図 10 (a), (b), 図 11).カルマンフィルタでは各運動変化および外れ値の影響を受け推定誤差が大きくなっている(図 9 (b), 図 10 (c), (d)).超パラメータのオンライン推定を行わないMCFでは外れ値の影響は軽減されているものの,急激な運動変化の追従に遅れが生じている(図 9 (c), 図 10 (e), (f)).真の運動軌跡と推定結果の間の平均 2 乗誤差でも,提案したフィルタが最も正確な状態推定を行っていることが分かる(表 2).

上記の結果から,オンライン処理において提案したフィルタが有用であることが確認された.この結果は,事前に与えられたデータから超パラメータでなく,超パラメータの変化のさせ方(超々パラメータ)を学習することのオンライン処理での有効性を表している.

5.3 外れ値と急激な運動変化の識別に関する考察

ここで 5.1 節および 5.2 節に関連し,外れ値と急激な運動変化の識別に関して考察しておく.本論文の状態空間モデルには,外れ値や急激な運動変化に対する情報はノイズ分布を裾の重い分布にすることでしか与えていない.つまり,外れ値や急激な運動変化は低い確率ではあるが生じる」ということだけが与えられている情報である.よって,外れ値か運動変化なのかを識別する情報は,運動方向の変化の頻度しか

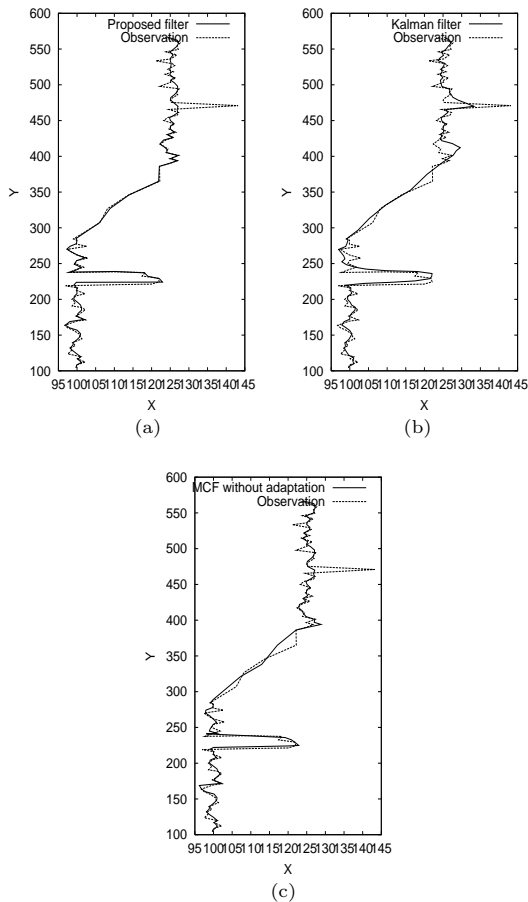


図9 人工データに対する状態推定結果。(a) 提案したフィルタ。(b) カルマンフィルタ。(c) 超パラメータをオフライン推定したMCF。破線が観測値、実線が推定結果を表す

Fig.9 Filtering results for synthetic data. (a) proposed filter, (b) Kalman filter, (c) MCF with hyper-parameters estimated offline. The dotted line represents observation and the solid line represents estimation result.

ない。つまり、一時的に急激に移動するが元の運動の状況に戻ってくるなら外れ値、連続して移動が生じるなら運動変化、ということでは両者の識別はできない。よって、たとえば図8のデータの最初の運動変化が仮に外れ値であったとしても、その影響を軽減することは困難である。その意味で、図9と図10の結果は、連続して生じる外れ値には対処できないという意味でのネガティブな実験例を表している。

しかし、この識別方法そのものについては一般的と考えられる。スポーツの、特にサッカーやバスケット、ラグビー等の球技の、“フェイント”という動作を例として考えても、相手の“クセ”等の特別な情報がない限り、有効ではないとはいえ上記の識別方法以外でフェイントを見破ることはできないといえる。それだ

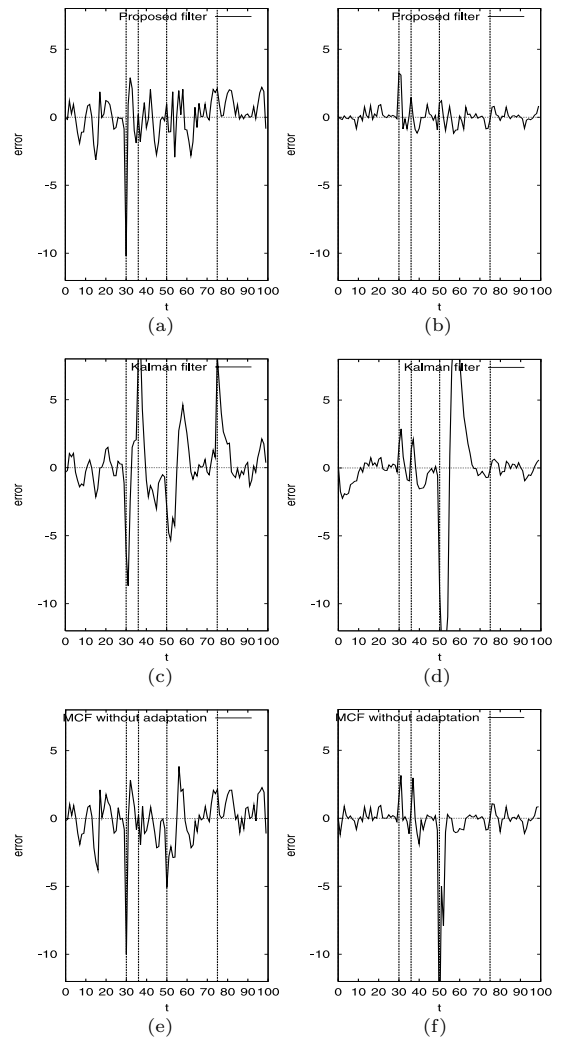


図10 人工データの各時刻における推定誤差。(a),(b): 提案したフィルタにおける x 座標と y 座標の誤差。(c),(d): カルマンフィルタにおける x 座標と y 座標の誤差。(e),(f): 超パラメータをオフライン推定したMCFにおける x 座標と y 座標の誤差。垂直な線は、外れ値 ($t=75$) と急激な運動変化 ($t=30, 36, 50$) が生じた時間を表す

Fig.10 Error in coordinates for synthetic data. Abscissa represents time. (a),(b): error in x and y coordinates for the proposed filter, (c),(d): error in x and y coordinates for the Kalman filter, (e),(f): error in x and y coordinates for the MCF with hyper-parameters estimated offline. Vertical lines show when outliers ($t=75$) and abrupt change in motion ($t=30, 36, 50$) occur.

からこそ、フェイントは敵方の追跡を回避する有効な手段として広く用いられているといえよう。本論文の場合、データにとって敵方とは追跡アルゴリズムということになるが、対象を限定しないオンライン処理では追跡アルゴリズムはデータのクセを知ることはできないので、上記の識別方法以外には対処しようがない

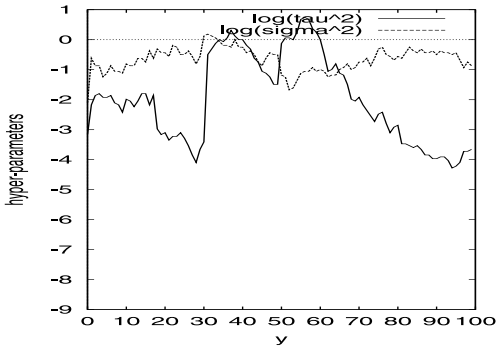


図 11 超パラメータ, $\log_{10}(\tau^2)$ (実線) と $\log_{10}(\sigma^2)$ (破線), の時間変化

Fig. 11 Changes in hyper-parameters, $\log_{10}(\tau^2)$ and $\log_{10}(\sigma^2)$, in the filtering.

表 2 提案したフィルタの超々パラメータとカルマンフィルタと MCF の超パラメータ, および, 真の運動軌跡と推定結果の間の平均 2 乗誤差 (MSE)

Table 2 Hyper-hyper-parameters determined for the proposed filter, hyper-parameters used for Kalman filter and MCF, and mean squared error (MSE) between estimated and true trajectories of both filters.

Proposed filter			Kalman filter		
ν^2	ξ^2	MSE	τ^2	σ^2	MSE
0.006	0.034	0.177	0.20	8.5	0.439
MCF					
τ^2	σ^2	MSE			
0.006	0.14	0.274			

と考えられる。もちろん, たとえば通常 3 フレームくらいは外れ値は連続する, というようなクセがデータにある場合には, その情報を積極的にモデルに埋め込むことは有効である。しかし, そのような知識は状況依存性があり一般性が薄れるため, 本論文ではそのようなデータに関する知識については考慮していない。つまり, 外れ値とは何かということに関して「まれに生じる大きな逸脱」という以外に特別な知識を埋め込むのを避けている。

いずれにせよ, データに関する何らかの知識が得られる場合, それをどのようにモデルに組み込むかや, どうやってデータから獲得するかは, 個々の状況に依存して決めるべきであり, それが応用においては重要な場合もある。もし, 多量のデータが事前に得られるならば, 超々パラメータの学習によってこのような問題も解決できる可能性もあり, 今後の課題の 1 つである。

5.4 人工データ：3次元運動と形状復元の精度向上
この実験では, 運動軌跡 (特徴対応データ) からの

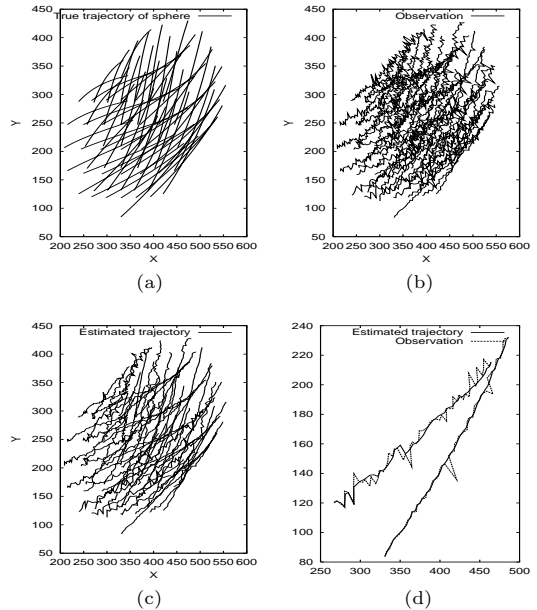


図 12 球上の 62 個の特徴点より得た運動軌跡. (a) 真の運動軌跡. (b) 観測ノイズと外れ値を含む観測値. (c) 提案したフィルタにより推定された運動軌跡. (d) (c) より選択した典型的な推定結果

Fig. 12 Motion trajectories obtained from 62 feature points on sphere. (a) True motion trajectories, (b) Observation with noise and outliers, (c) Estimated trajectories obtained from the proposed filter, (d) Typical results of the proposed filter selected from (c).

物体の 3 次元運動と形状復元の精度向上への, フィルタリングの効果を検討する。カメラの内部パラメータは既知とし, 因子分解法によるユークリッド復元²⁾と射影的奥行き推定の反復により, アフィン投影を用いても透視投影画像から誤差なく運動と形状復元ができる方法を用いる¹⁾。これにより, 投影モデルの近似による誤差の影響を排除し, フィルタリングの効果を評価できる。

球上の 62 点の 3 次元特徴点を透視投影し, 60 フレーム分の運動軌跡を生成した (図 12 (a))。60 フレームの間に, ロール, ピッチ, ヨーそれぞれを 30, 30, 15 度均一に変化させつつ, 各座標で 60 [mm] 均一に平行移動させた。生成した運動軌跡にガウスノイズと外れ値を加え観測値とした (図 12 (b))。各運動軌跡のガウスノイズの分散は, [1:16] の範囲の一樣分布によりランダムに設定した。また, 外れ値は 6% の確率で [-20:20] の範囲の一樣乱数をガウスノイズに加え生成した。各特徴点の奥行きとノイズの分散の違いのため, 各運動軌跡は異なる統計的性質を持ち, さらに外れ値の出現時間も異なる。よって, 各運動軌跡, 各




図 13 復元された回転角，ロール，ピッチ，ヨー，の誤差．(a) 観測値から復元された回転角の誤差．(b) 推定された運動軌跡から復元された回転角の誤差

Fig. 13 Errors in recovered rotation angles: roll, pitch and yaw. (a) Errors in rotation angles obtained from observation, (b) Errors in rotation angles obtained from estimated trajectories.

時間ごとに異なる超パラメータが必要となるため，超パラメータのオンライン推定が重要となる．

超々パラメータの値や粒子数等の条件を人工データと同一とし，状態推定した結果，観測ノイズと外れ値の影響が軽減された（図 12 (c), (d)）．観測値から復元された球の回転角の誤差は，最大で 2 度から 4 度程度で突発的な変化も含むが（図 13 (a)），推定結果から復元された回転角の誤差は 1 度以内に減少した（図 13 (b)）．因子分解法のような複数フレームを用いるアルゴリズムでは，誤差の影響は平均化により軽減される．しかし，もしノイズ成分の平均が 0 でなければ，平均化の結果にはオフセットが生じ，それが運動や形状推定に悪影響を与える．オフセットは主として外れ値によって生じ，提案したフィルタはその影響を軽減できるため，図 13 のように誤差を減少させることができる．復元形状の誤差は，形状行列 S を用い， $\|S_{true} - S_{estimated}\| / \|S_{true}\|$ より評価した．観測値より復元された形状では誤差が 5.8%であったが，推定結果から復元した場合には 2.5%に減少した．この結果より，提案したフィルタは 3 次元運動と形状復




図 14 目の追跡結果のスナップショット．画像中の楕円は，推定された目の位置を表す

Fig. 14 Snapshots of the eye tracking image sequence. The arc in pictures shows the estimated eye position obtained from the proposed filter.

元の精度向上に有効であると考えられる．なお，提案したフィルタと同様に人工データから得られた超パラメータを用いてカルマンフィルタと超パラメータのオンライン推定をしない MCF を適用すると，形状復元誤差はそれぞれ 4.6%，3.1%となり，ここでも 5.2 節と同様に超々パラメータを学習することのオンライン処理での有効性が表れている．

5.5 実データ：目のオンライン追跡における超パラメータの推定

実システムでの超パラメータの適応能力を確認するため，提案したフィルタを目の追跡システムに組み込んだ．右目のテンプレートをを用いて目の追跡を行った（図 14）．マッチングには，正規化相関を計算するハードウェアをもった画像ボードを使用した．超々パラメータの値や粒子数等の条件は人工データと同一とした．

状態推定の結果，システムノイズの尺度は，動きの速い時刻 ($t=0-35, 60-100$) には大きく，動きの遅い時刻 ($t=35-60$) には小さくなっており，運動に追従するように変化していた（図 15 (a), (b)）．また，観測ノイズの尺度は，速度変化が大きい時刻 ($t=0-35, 60-75$) では大きく，速度変化の小さい時刻 ($t=35-60, 75-100$) では小さくなっており，観測誤差を反映しているといえる（図 15 (a), (b)）．この結果は，提案したフィルタの実システムでの適応能力の妥当性を表している．図 15 (c) は運動軌跡の観測値と推定結果を示している．本実験では適応能力を示すことを主眼としたため，1 点の外れ値を除いて推定により雑音の影響がどのように軽減されたかは明示されていない．しかし，適応能力については，図 15 (d) のカルマンフィルタによる結果と比較することにより，その効果が分かる．つまり，カルマンフィルタでは運動変化への追従が完全に遅れているのに対し，提案したフィルタでは遅れな

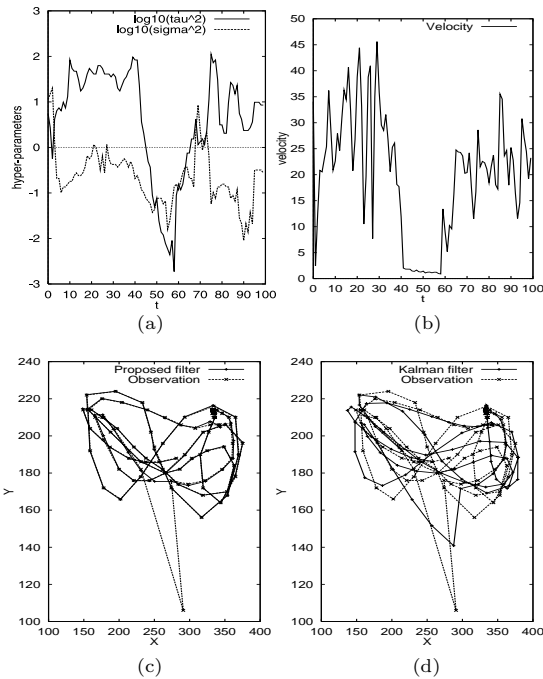


図 15 実システムの実験結果。(a) 超パラメータの変化。(b) 目の各時刻における移動速度 [pixels/frame] (c) 追跡結果。実線は推定された軌跡を、破線は観測された軌跡を表す。(d) カルマンフィルタによる追跡結果。実線は推定された軌跡を、破線は観測された軌跡を表す

Fig. 15 Changes in hyper-parameters, velocity and filtered trajectory. (a) Changes in hyper-parameters. (b) Changes in feature velocity [pixels/frame]. (c) Filtered trajectory and observation. The solid line shows the estimated trajectory and the dotted line shows the observation. (d) Filtered trajectory of the Kalman filter and observation. The solid line shows the estimated trajectory and the dotted line shows the observation.

く運動変化へ追従している。処理速度は PentiumIII 500 MHz の PC 上で約 6 [frame/s] であった。

5.6 フィルタの実装上の問題

以上の実験結果より、提案したフィルタの有効性が確認された。このような結果を得るためには、実装上の問題点を解決する必要がある、ここでは粒子からの状態推定値の計算と、粒子数の決定について述べる。

逐次モンテカルロ法では、本来連続な確率分布を粒子により離散化することによって、任意の形状の確率分布の表現とそれに基づく状態推定を実現している。しかし、その離散化のために、離散的な確率分布からどのようにして 1 つの状態推定値を求めるかという点が問題となる。

最も容易な方法として粒子の平均値を求める方法があるが、非対称分布や多峰分布等では平均とモードが一致しないため、任意の形状の確率分布を表現できる

という利点を無駄にする結果となる。もし、平均値を用いても妥当な処理結果が得られるとすると、状態の分布がガウス分布に近い場合か、処理に用いられているデータに関する他の知識（たとえば、データ間の空間的な配置に対する制約等）が本質的な役割を果たしており、状態の分布を粗く近似しても許容される場合と思われる。このような場合には、計算量の少ないカルマンフィルタが有効である可能性が高いので、逐次モンテカルロ法そのものの適用を再検討する必要がある。

粒子からモードを求める計算は、離散的なサンプルからの連続確率分布の推定の問題であるので、本論文では 5.1 節で述べたようにカーネル推定の一環である Parzen 推定²¹⁾を用いている。粒子から座標と各超パラメータについてのヒストグラムを作成し、そのヒストグラムの各ビンにカーネルを配置することにより、離散分布から連続分布を推定している。カーネルとしては等方ガウス関数を用い、各ビンに対するカーネルの分散は同一とした。分散の決定は試行錯誤により行った。具体的な値としては座標に対する 2 次元のカーネルについては 5.0、超パラメータに対する 1 次元のカーネルについては 3.0 とした。

その他の実装上の問題点としては、粒子数の決定がある。粒子数の決定は現状では試行錯誤で行われており、処理時間に制約がある場合にはその制約から粒子数が決定される場合もある。ただ、状態推定の観点から粒子数を見積もる 1 つの方法として、3.1 節で示したモンテカルロフィルタアルゴリズムの Step 2-3 で計算されるゆう度 $\left\{ \alpha_t^{(i)} \right\}_{i=1}^m$ を使う方法が考えられる。粒子数が少ない場合、特に分布の裾の部分の近似が粗くなり、観測値が予測分布の裾の部分に表れた場合、ほとんどの粒子に対するゆう度が 0 に近くなる場合がある。このような場合には、次のリサンプリングの過程で一部の粒子しか生き残らず、フィルタ分布が縮退する状況を引き起こす。よって、粒子数が不足していると判断する 1 つの方法として、処理の過程でゆう度をチェックしておくことが考えられる。

6. む す び

特徴点の運動軌跡に対し、自己組織化型状態空間モデルを用いた時系列フィルタリングを提案した。状態推定を司る超パラメータを状態に含め、特徴点の座標と同時にオンライン推定するため、各時刻で特徴点運動に応じた超パラメータを用いることができる。実験を通じ、その有効性を確認した。

提案した方法の問題点として、状態推定のために用いた粒子による分布の近似の影響がある。各時間ごとにリサンプリングを行うことにより、リサンプリングの頻度の高いある特定の値だけに粒子が偏り、分布が縮退する場合がある。このような縮退は、初期分布や分布を近似する粒子の試行ごとの変化に依存するため、予期しない処理結果の変動を引き起こす。このような現象は“sample impoverishment”と呼ばれ²²⁾、逐次モンテカルロ法と総称される方法で問題となっている。提案した方法を長期の時系列画像に適用するためには、時間の経過（リサンプリングの回数が増える）とともに進行するこの現象を避け、超パラメータの適応能力を保持するような機構を考案する必要がある。たとえば、縮退を避けるようなリサンプリングの方法を考案することは1つの解決案である。このような数値計算の安定化や、動きの分割や3次元運動と形状復元への応用等が今後の課題である。

参 考 文 献

- 1) Christy, S. and Horaud, R.: Euclidean reconstruction: from paraperspective to perspective, *Proc. 4th European Conf. Computer Vision*, Vol.2, pp.129–140 (1996).
- 2) Poelman, C.J. and Kanade, T.: A paraperspective factorization method for shape and motion recovery, *IEEE Trans. Pattern Anal. & Mach. Intell.*, Vol.19, No.3, pp.206–218 (1997).
- 3) Ichimura, N.: A robust and efficient motion segmentation based on orthogonal projection matrix of shape space, *Proc. Int. Conf. Computer Vision and Pattern Recognition*, Vol.II, pp.446–452 (2000).
- 4) Ichimura, N.: Motion segmentation using feature selection and subspace method based on shape space, *Proc. Int. Conf. Pattern Recognition*, Vol.III, pp.858–864 (2000).
- 5) Meditch, J.S.: *Stochastic optimal linear estimation and control*, McGraw-Hill (1969).
- 6) Dickmanns, E.D. and Graefe, V.: Applications of dynamic monocular machine vision, *Machine Vision and Applications*, Vol.1, No.4, pp.241–261 (1988).
- 7) Deriche, R. and Faugeras, O.: Tracking line segments, *Proc. 1st European Conf. Computer Vision*, pp.259–268 (1990).
- 8) Dickmanns, E.D. and Mysliwetz, B.D.: Recursive 3-D road and relative ego-state recognition, *IEEE Trans. Pattern Anal. & Mach. Intell.*, Vol.14, No.2, pp.199–213 (1992).
- 9) Goncalves, L., Bernardo, E.D., Ursella, E. and Perona, P.: Monocular tracking of the human arm in 3D, *Proc. 5th Int. Conf. Computer Vision*, pp.764–770 (1995).
- 10) Bar-Shalom, Y. and Fortmann, T.E.: *Tracking and data association*, Academic Press (1988).
- 11) Kitagawa, G.: A self-organizing state-space model, *J. Amer. Statist. Assoc.*, Vol.93, pp.1203–1215 (1998).
- 12) Gordon, N.J., Salmond, D.J. and Smith, A.F.M.: Novel approach to nonlinear/non-Gaussian Bayesian state estimation, *IEEE Proc. F*, Vol.140, No.2, pp.107–113 (1993).
- 13) Kitagawa, G.: Monte Carlo filter and smoother for non-Gaussian nonlinear state space models, *J. Comp. and Graph. Stat.*, Vol.5, No.1, pp.1–25 (1996).
- 14) Isard, M. and Blake, A.: Condensation – Conditional density propagation for visual tracking, *Internat. J. Computer Vision*, Vol.29, No.1, pp.5–28 (1998).
- 15) Liu, J.S. and Chen, R.: Sequential Monte Carlo methods for dynamic systems, *J. Amer. Statist. Assoc.*, Vol.93, pp.1032–1044 (1998).
- 16) Anderson, B.D.O. and Moore, J.B.: *Optimal Filtering*, Prentice-Hall (1979).
- 17) Masreliez, C.J. and Martin, R.D.: Robust Bayesian estimation for the linear model and robustifying the Kalman filter, *IEEE Trans. Auto. Control*, Vol.AC-22, No.3, pp.361–371 (1977).
- 18) Lange, K.L., Little, R.J.A. and Taylor, J.M.G.: Robust statistical modeling using the t distribution, *J. Amer. Statist. Assoc.*, Vol.84, No.408, pp.881–896 (1989).
- 19) Ichimura, N. and Ikoma, N.: Filtering and smoothing for motion trajectory of feature point using non-Gaussian state space model, *IEICE Trans. Inf. & Syst.*, Vol.E84-D, No.6, pp.755–759 (2001).
- 20) Akaike, H.: Likelihood and the Bayes procedures, *Bayesian Stat.*, pp.143–166 (1980).
- 21) Fukunaga, K.: *Introduction to Statistical Pattern Recognition*, Academic Press (1972).
- 22) King, O. and Forsyth, D.A.: How does CONDENSATION behave with a finite number of samples?, *Proc. 6th European Conf. Comp. Vis.*, pp.695–709 (2000).

(平成 14 年 2 月 26 日受付)

(平成 14 年 9 月 12 日採録)

(担当編集委員 長尾 健司)



市村 直幸（正会員）

1989年電気通信大学電気通信学部通信工学科卒業。1994年同大学大学院電気通信学研究科博士後期課程単位取得退学。同年電子技術総合研究所入所。2001年産業技術総合研究所，情報処理研究部門主任研究員。2002年3月より米国コロンビア大学計算機科学科に客員研究員として滞在中。コンピュータビジョン，時系列解析，情報圧縮等の研究に従事。工学博士。電子情報通信学会，計測自動制御学会，IEEE各会員。
