

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

産業技術総合研究所 情報処理研究部門

〒305-8568 つくば市梅園 1-1-1 中央第二

nic@ni.aist.go.jp, <http://staff.aist.go.jp/naoyuki.ichimura/>

あらまし 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、観測ノイズと共に、誤対応に伴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、特徴点の座標と共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

Information Technology Research Institute

National Institute of Advanced Industrial Science and Technology

Tsukuba Central 2, 1-1-1, Umezono, Tsukuba, Ibaraki, 305-8568 Japan

nic@ni.aist.go.jp, <http://staff.aist.go.jp/naoyuki.ichimura/>

Abstract 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、観測ノイズと共に、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に伴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 (hyperparameter) 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共に変動するため、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一つの方法に、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も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、全ての超パラメータの組合わ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 (例えば 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子化幅を小さくする場合に、超パラメータの組合わせ数が膨大となり、極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る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]。この方法の一つの問題点は、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)) [13] 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。

$$x_t = Fx_{t-1} + Gv_t \quad (1)$$

$$y_t = Hx_t + w_t \quad (2)$$

式 (1) は状態遷移方程式であり、 x_t は状態変数ベクトル、 v_t はシステムノイズベクトルである。行列 F と G はシステム行列である。式 (2) は観測方程式であり、 y_t は観測ベクトル、 w_t は観測ノイズベクトルである。行列 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 $Y_t = \{y_1, \dots, y_t\}$ に基づく、状態変数ベクトル x_t の推定である。そして、この推定は、条件付き確率 $p(x_t | Y_t)$ の計算により行われる。

観測ベクトル $y_t = [x(t), y(t)]^T$ 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 v_t は、各次元が独立に密度関数 $q(v; m_q, \tau^2)$ 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 $q_v(v_t; m_{vq}, T)$ とする．観測ノイズベクトル w_t は、各次元が独立に密度関数 $r(w; m_r, \sigma^2)$ に従う白色ノイズであり、その多変数表現は $r_v(w_t; m_{vr}, \Sigma)$ 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} の要素は全て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、状態推定結果は全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．時間と共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




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) $\tau^2 = 0.01$, $\sigma^2 = 50.0$

める．また、超パラメータ τ, σ も含める．

$$x_t = [x_s(t), y_s(t), x_s(t-1), y_s(t-1), \log \tau^2(t), \log \sigma^2(t)]^T \quad (5)$$

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る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．

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

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

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

$$w_t = [w_x(t), w_y(t)]^T \quad (8)$$

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 $q_v(v_t; m_{vq}, T)$ の位置と尺度は $m_{vq} = [0, 0, 0, 0]^T$ と $T = \text{diag}(\tau^2, \tau^2, \nu^2, \xi^2)$ である．観測ノイズ分

布 $r_v(w_t; m_{vr}, \Sigma)$ の位置と尺度は $m_{vr} = [0, 0]^T$ 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 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 $p(x_t | Y_{t-1})$ およびフィルタ分布 $p(x_t | Y_t)$ 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一期先予測とフィルタの繰り返しで、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 $p_0(x)$ 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: 一期先予測] 次式より、予測分布 $p(x_t | Y_{t-1})$ に従う粒子 $\{p_t^{(i)}\}_{i=1}^m$ を得る。

$$p_t^{(i)} = Ff_{t-1}^{(i)} + Gv_t^{(i)} \quad (9)$$

[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。

$$\alpha_t^{(i)} = r_v(y_t - Hp_t^{(i)}; m_{vr}, \Sigma) \quad (10)$$

[Step 2-4: フィルタ] 一期先予測により得た粒子 $\{p_t^{(i)}\}_{i=1}^m$ を次の確率に従いリサンプリングし、フィルタ分布 $p(x_t | Y_t)$ に従う粒子 $\{f_t^{(i)}\}_{i=1}^m$ を得る。

$$Pr(f_t^{(i)} = p_t^{(i)}) = \frac{\alpha_t^{(i)}}{\alpha_t^{(1)} + \dots + \alpha_t^{(m)}} \quad (11)$$




図 2: 異なる超パラメータをもつ観測ノイズ分布の例

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))。高いゆう度をも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もつ二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]。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。そのため、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。




図 3: 外れ値除去と運動変化への追跡のトレードオフ




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

5.1 人工データ: トレードオフの調整問題

4節で述べたように，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。例えば，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，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。

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)

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

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。数値探索には粗密探索を用いた。つまり，まず $\{1, 2, \dots, 20\} \times \{1, 2, \dots, 20\}$ の粗いグリッドを用い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， $[-8, 8]$ の範囲の一様分布とした。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。

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

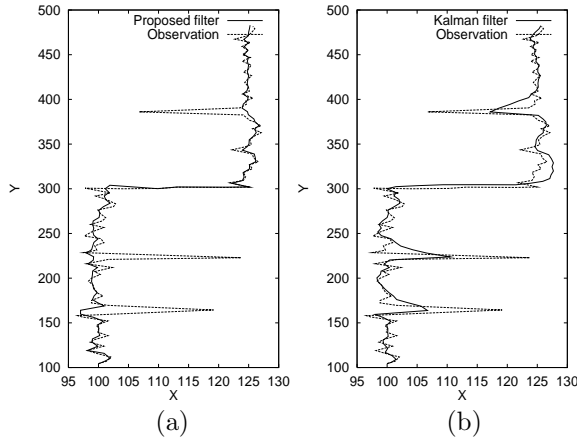


図 5: 人工データに対する状態推定結果. (a) 提案したフィルタ. (b) カルマンフィルタ. 破線が観測値, 実線が推定結果を表す

た (図 5 および図 6). 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). 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わかる (表 1).

5.2 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 8(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] 均一に並行移動させた. 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 8(b)). 各運動軌跡のガウスノイズの分散は, [1:16] の範囲の一様分布

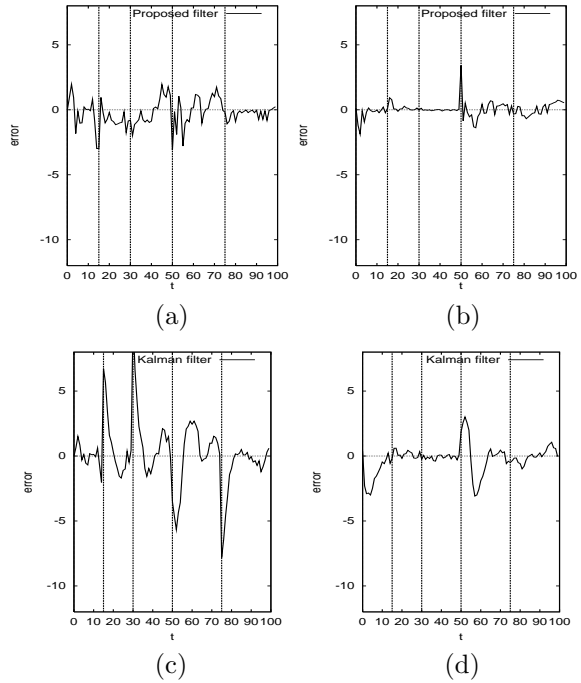


図 6: 人工データの各時刻における推定誤差. (a),(b): 提案したフィルタにおける x 座標と y 座標の誤差. (c),(d): カルマンフィルタにおける x 座標と y 座標の誤差. 垂直な線は, 外れ値 ($t=15, 30, 75$) と急激な運動変化 ($t=50$) が生じた時間を表す

によりランダムに設定した. また, 外れ値は 6% の確率で $[-20:20]$ の範囲の一様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もち, さらに外れ値の出現時間も異なる. よって, 各運動軌跡, 各時間毎に異なる超パラメータが必要となる.

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 8(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 9(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 9(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 9 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,




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

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次元運動と形状復元の精度向上に有効であると考えられる.

5.3 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

実システムでの動作を確認するため, 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 10). 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 11). 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言える (図 11). 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. 処理速度は PentiumIII 500MHz の PC 上で約 6[frame/s] であった.

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





図 8: 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

きる. 実験を通じ, その有効性を確認した.


今後の課題として, 提案したフィルタの, 動きの分割や 3次元運動と形状復元への応用や, 数値計算の速度向上等が挙げられる.

参考文献

- [1] S. Christy and R. Horaud: "Euclidean reconstruction: from paraperspective to perspective," Proc. 4th European Conf. Computer Vision, Vol.2, pp.129-140, 1996.
- [2] C. J. Poelman and T. Kanade: "A paraperspective factorization method for shape and motion recovery," IEEE Trans. Pattern Anal. & Mach. Intell., Vol.19, No.3, pp.206-218, 1997
- [3] N. Ichimura: "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] N. Ichimura: "Motion segmentation using feature selection and subspace method based on shape space" Proc. Int. Conf. Pattern Recognition, Vol.III, pp.858-864, 2000
- [5] J.S. Meditch: "Stochastic optimal linear estimation and control," McGraw-Hill, 1969
- [6] E. D. Dickmanns and V. Graefe: "Applications of dynamic monocular machine vision," Machine



(a)



(b)

図 9: 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





図 10: 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

Vision and Applications, Vol.1, No.4, pp.241-261, 1988

- [7] R. Deriche and O. Faugeras: "Tracking line segments," Proc. 1st European Conf. Computer Vision, pp.259-268, 1990.
- [8] E. D. Dickmanns and B. D. Mysliwetz: "Recursive 3-D road and relative ego-state recognition," IEEE Trans. Pattern Anal. & Mach. Intell., Vol.14, No.2, pp.199-213, 1992
- [9] L. Goncalves, E. D. Bernardo, E. Ursella and P. Perona: "Monocular tracking of the human arm in 3D," Proc. 5th Int. Conf. Computer Vision, pp.764-770, 1995
- [10] Y. Bar-Shalom and T. E. Fortmann: "Tracking and data association," Academic Press, 1988



(a)

(b)

図 11: 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]

- [11] G. Kitagawa: "A self-organizing state-space model," J. Amer. Statist. Assoc., Vol. 93, pp. 1203-1215, 1998
- [12] N. J. Gordon, D. J. Salmond, and A. F. M. Smith: "Novel approach to nonlinear/non-Gaussian Bayesian state estimation," IEE Proc. F, Vol. 140, No. 2, pp. 107-113, 1993
- [13] G.Kitagawa: "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] M. Isard and A. Blake: "Condensation – conditional density propagation for visual tracking," Internat. J. Computer Vision, Vol. 29, No. 1, pp. 5-28, 1998
- [15] J. S. Liu and R. Chen: "Sequential Monte Carlo methods for dynamic systems," J. Amer. Statist. Assoc., Vol. 93, pp. 1032-1044, 1998
- [16] B. D. O. Anderson and J. B. Moore: "Optimal Filtering," Prentice-Hall, 1979
- [17] C. J. Masreliez and R. D. Martin: "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] K. L. Lange, R. J. A. Little and J. M. G. Taylor: "Robust statistical modeling using the t distribution," J. Amer. Statist. Assoc., Vol.84, No.408, pp.881-896, 1989
- [19] N. Ichimura and N. Ikoma: "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] H. Akaike: "Likelihood and the Bayes procedures," Bayesian Stat., pp. 143-166, 1980
- [21] K. Fukunaga: "Introduction to Statistical Pattern Recognition," Academic Press, 1972