

非ガウス型状態空間モデルを用いた 特徴点位置系列のフィルタリング

市村 直幸[†]

生駒 哲一[‡]

[†]電子技術総合研究所
〒 305-8568 つくば市梅園 1-1-4
ichimura@etl.go.jp

[‡]九州工業大学 工学部
〒 804-8550 北九州市戸畑区仙水町 1-1
ikoma@comp.kyutech.ac.jp

あらまし 時系列画像上での特徴点の追跡では、特徴点抽出段階での誤りやフレーム間での照明条件の変化等に起因して、誤対応が生じる。特徴点の運動軌跡には、この誤対応に伴う外れ値が含まれる。この外れ値の影響軽減のために、非ガウス型状態空間モデルの使用を検討する。観測ノイズ分布を裾の重い非ガウス分布にした、二つのモデルを用いる。それらは、特徴点の座標を状態とする線形非ガウス型モデルと、特徴点の座標と共にモデルパラメータを状態に含め、そのオンライン推定を行う非線形非ガウス型モデルである。これらのモデルによる状態推定には、逐次モンテカルロ法を適用する。人工データおよび実データを用いた実験結果から、非ガウス型モデルの外れ値の影響軽減への有効性を確認した。

Filtering of Time Series of Feature Point Coordinates Using Non-Gaussian State Space Model

Naoyuki ICHIMURA[†]

Norikazu IKOMA[‡]

[†]Electrotechnical Laboratory
1-1-4, Umezono, Tsukuba, Ibaraki,
305-8568 Japan
ichimura@etl.go.jp

[‡]Kyushu Institute of Technology
1-1, Sensuicho, Tobata-Ku,
Kitakyushu, Fukuoka, 804-8550 Japan
ikoma@comp.kyutech.ac.jp

Abstract False matching due to error in feature extraction and change in illumination between frames may occur in feature point tracking on image sequence. The false matching leads to outliers in motion trajectories of feature points. We introduce a non-Gaussian state space model to reduce the effect of the outliers. Two models with heavy-tailed non-Gaussian observation noise distribution are used: linear non-Gaussian model with state vector which consists of coordinate of feature point and nonlinear non-Gaussian model with one which consists of both the coordinate and model parameters. In the latter model, online estimation of model parameters is carried out simultaneously in state estimation. A sequential Monte Carlo method is used to estimate the optimal state of these models. The experimental results using synthetic and real data show that the non-Gaussian models can reduce the effect of the outliers.

1 はじめに

カメラから連続して撮像された時系列画像上での特徴追跡は、動きからの形状復元、複数運動の分割等の基本となる重要な処理である。

特徴追跡の一つの方法として、相関に基づくブロックマッチング法 [1] がある。この方法は処理手順が単純で、ハードウェアでの実装も行いやすいため、広く用いられている。しかし、特徴抽出での誤り（追跡に不適当な性質を持つ特徴の抽出）や、フレーム間での照明条件の変化等に起因して誤対応が生じる。

誤対応の影響を軽減する一方法として、特徴点の運動軌跡に対する時系列フィルタリングがある。カルマンフィルタ [2][3] が代表的な方法であるが、線形ガウス型状態空間モデルが前提のため、観測ノイズ分布に非正規性が見られる場合、例えばデータに外れ値 (outlier) が含まれる場合に対し、ロバストでないことが指摘されている [4]。また、非線形性をもつモデルに対しても適用が困難である [5]。

このような制約を取り除くため、非線形非ガウス型状態空間モデルに対する状態推定方法の研究が進められてきた。特に、予測、フィルタおよびスムージングの条件付き確率分布に含まれる、状態に対する積分の近似計算方法が問題とされてきた。そして、近年、逐次モンテカルロ法 (Sequential Monte Carlo method: SMC) と総称される状態推定方法が提案されている [6]-[9]。これらの方法では、確率分布をその実現値 (粒子と呼ぶ) を多数用い近似する。粒子を用いて 1 期先予測とフィルタの分布を順次推定し、逐次的な状態推定を実現する。

確率分布の近似方法としては、他にもガウス分布の和 (混合分布) を用いる方法 [5] や、状態空間を離散化する方法 [10] がある。しかし、状態の次元が高くなった場合、前者の方法では混合分布のパラメータ推定の数値計算の安定性 (初期値への依存、局所解) や混合数の決定の問題があり、後者の方法では高次元空間の離散化による組み合わせ数の増大の問題がある。粒子を用いる方法にはそのような問題はなく、高次元の状態空間にも適用可能という実用上重要な利点がある。そのため、時系列画像に対するモデル照合に基づくトップダウンな物体追跡 [8] 等の現実的な問題に利用されている。

本論文では、特徴点を対象としたボトムアップな追跡を取り扱う。特に、時系列画像から得られる特徴点の運動軌跡の処理における、観測ノイズ分布の

非ガウス化による外れ値の影響軽減と、それに用いる非ガウス型モデルのモデルパラメータのオンライン推定を目的とする。特徴点の運動軌跡には誤対応に伴う外れ値が含まれるため、観測ノイズ分布としてガウス分布より裾の重い (heavy-tailed) 非ガウス分布の使用が有効である。また、時系列画像内で多数の特徴点が抽出されるが、一般に個々の特徴点の運動軌跡の統計的な性質は異なり、それぞれに応じたモデルパラメータの設定が必要である。尤度に基づいて複数の候補の中から適切なモデルパラメータを求める方法 [11] があるが、オフライン処理であるため、特徴追跡というオンライン処理に対しては整合性が悪い。よって、モデルパラメータを状態変数に含め、オンライン推定する方法 [12] を検討した。この方法では、モデルが非ガウスに加え非線形にもなるが、SMC により状態推定が可能である。

本論文では、まず 2 節において、状態推定の基礎事項を示す。3 節で、特徴点の運動軌跡の処理に用いる非ガウス型モデルを示す。4 節で、状態推定に用いるモンテカルロフィルタについて述べる。5 節で実験結果を示す。そして、6 節で本論文をまとめる。

2 状態空間モデルと状態推定

状態空間モデルとして、次式を用いる。

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

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

式 (1) は状態遷移方程式で、 \mathbf{x}_t は状態ベクトル、 \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、状態遷移行列および駆動行列である。式 (2) は観測方程式で、 \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処理の目的は、現時刻 t までの観測系列 $Y_t = \{\mathbf{y}_1, \dots, \mathbf{y}_t\}$ に基づく、状態ベクトル \mathbf{x}_{t+m} の推定である。そして、この推定は、条件付き確率分布 $p(\mathbf{x}_{t+m} | Y_t)$ の計算により行われる。 $m > 0$ 、 $m = 0$ および $m < 0 (t+m \geq 0)$ に対応し、予測、フィルタおよびスムージングとなる。

3 特徴点の運動軌跡に対する非ガウス型状態空間モデル

時系列画像上での追跡の結果得られる特徴点の運動軌跡に対して、フィルタリングおよびスムージングを行う非ガウス型状態空間モデルを示す。特徴点

の座標を状態とする線形モデルと、特徴点の座標と共にモデルパラメータを状態に含む非線形モデルの2種類を用いる。

3.1 状態空間モデルの構造

各特徴点毎に独立に、式(1),(2)の状態空間モデルを仮定する。観測系列 $\mathbf{y}_i = [x(t), y(t)]^T$ は、特徴点の画像上の位置座標の観測値である。観測ノイズベクトル $\mathbf{w}_i = [w_x(t), w_y(t)]^T$ は、各次元が独立に密度関数 $r(w; m_r, \sigma^2)$ に従う白色雑音であるとする。 m_r と σ は密度関数の位置 (location) と尺度 (scale) を表すパラメータである。また、システムノイズベクトル $\mathbf{v}_i = [v_x(t), v_y(t)]^T$ は、各次元が独立に密度関数 $q(v; m_q, \tau^2)$ に従う白色雑音であるとする。 m_q と τ は位置と尺度を表すパラメータである。 m_r, σ, m_q および τ は状態推定を司るパラメータであり、これらをモデルパラメータと呼ぶ。

3.1.1 特徴点の座標を状態とする線形モデル

状態ベクトル \mathbf{x}_i は、特徴点の真の座標に対応する。これを逐次推定し、特徴点の運動軌跡を推定する。特徴点の運動の2階差分がほぼ0、すなわち速度の変化が滑らかであると仮定し、次の状態ベクトル \mathbf{x}_i と、行列 \mathbf{F} 、 \mathbf{G} および \mathbf{H} を用いる。

$$\mathbf{x}_i = [x_s(t), y_s(t), x_s(t-1), y_s(t-1)]^T \quad (3)$$

$$\mathbf{F} = \begin{bmatrix} 2 & 0 & -1 & 0 \\ 0 & 2 & 0 & -1 \\ 1 & 0 & 0 & 0 \\ 0 & 1 & 0 & 0 \end{bmatrix}, \mathbf{G} = \begin{bmatrix} 1 & 0 \\ 0 & 1 \\ 0 & 0 \\ 0 & 0 \end{bmatrix}, \quad \mathbf{H} = \begin{bmatrix} 1 & 0 & 0 & 0 \\ 0 & 1 & 0 & 0 \end{bmatrix} \quad (4)$$

3.1.2 モデルパラメータを状態に含む非線形モデル

モデルパラメータのうち σ と τ を、特徴点の座標と同時に推定する。この場合には、以下の状態ベクトル \mathbf{x}_i と、行列 \mathbf{F} 、 \mathbf{G} および \mathbf{H} を用いる。

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

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




図1: ガウス分布とコーシー分布. 位置:0、スケール:3.

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

このモデルは、モデルパラメータは一定という仮定に基づいている。また、システムノイズベクトルおよび観測ノイズベクトルがモデルパラメータに依存しているため、このモデルは非線形となる。

3.2 外れ値の影響軽減のための観測ノイズ分布の非ガウス化

システムノイズ分布は、 $q(v; m_q, \tau^2) \sim N(0, \tau^2)$ のガウス分布とする。観測ノイズ分布として、 $r(w; m_r, \sigma^2) \sim C(0, \sigma^2)$ の位置0、尺度 σ のコーシー分布を選択した。この分布は次式で与えられる。

$$r(w; 0, \sigma^2) = \frac{\sigma}{\pi \{w^2 + \sigma^2\}} \quad (7)$$

コーシー分布は同一のパラメータを持つガウス分布に比べ裾の重い分布である(図1)。この性質から、高い頻度で発生する観測誤差と低い頻度で発生する外れ値とを、一つの分布で同時に表現できると考えられる。よって、この分布を外れ値の影響軽減のため採用した。

この観測ノイズ分布の非ガウス化により、式(3),(4)および式(5),(6)の要素をもつ状態空間モデルは、それぞれ、線形非ガウス型モデルおよび非線形非ガウス型モデルとなる。

4 モンテカルロフィルタによる状態推定

前節で示した非ガウス型モデルでのフィルタリングおよびスムージングには、Kitagawaによって提案された逐次モンテカルロ法であるモンテカルロフィルタ (MCF) [7][12] を用いる。以下では、前節で示

したモデルを含む非線形非ガウス型状態空間モデルについて、MCFの計算手順を示す。

次の非線形非ガウス型状態空間モデルを考える。

$$\mathbf{x}_t = f(\mathbf{x}_{t-1}, \mathbf{v}_t) \quad (8)$$

$$\mathbf{y}_t = h(\mathbf{x}_t, \mathbf{w}_t) \quad (9)$$

ここで、 $f(\cdot)$ 、 $h(\cdot)$ は一般には非線形の関数とする。このモデルに対し、一期先予測、フィルタおよびスムージングの分布、 $p(\mathbf{x}_t | Y_{t-1})$ 、 $p(\mathbf{x}_t | Y_t)$ および $p(\mathbf{x}_t | Y_N)$ が次式のように求められる[10]。ただし、観測系列の長さを N とする。

$$p(\mathbf{x}_t | Y_{t-1}) = \int_{-\infty}^{\infty} p(\mathbf{x}_t | \mathbf{x}_{t-1}) p(\mathbf{x}_{t-1} | Y_{t-1}) d\mathbf{x}_{t-1} \quad (10)$$

$$p(\mathbf{x}_t | Y_t) = \frac{p(\mathbf{y}_t | \mathbf{x}_t) p(\mathbf{x}_t | Y_{t-1})}{p(\mathbf{y}_t | Y_{t-1})} \quad (11)$$

$$p(\mathbf{y}_t | Y_{t-1}) = \int_{-\infty}^{\infty} p(\mathbf{y}_t | \mathbf{x}_t) p(\mathbf{x}_t | Y_{t-1}) d\mathbf{x}_t \quad (12)$$

$$p(\mathbf{x}_t | Y_N) = p(\mathbf{x}_t | Y_t) \cdot \int_{-\infty}^{\infty} \frac{p(\mathbf{x}_{t+1} | Y_N) p(\mathbf{x}_{t+1} | \mathbf{x}_t)}{p(\mathbf{x}_{t+1} | Y_t)} d\mathbf{x}_{t+1} \quad (13)$$

各分布には状態ベクトルに関する積分が含まれる。非線形非ガウス型モデルに対し、これらの積分を解析的に表現することは出来ない。よって、各分布に対する何らかの近似表現が必要となる。

上記の各分布の近似表現とそれを用いた状態推定の一方法が、MCFである[7][12]。この方法では、各分布を複数の実現値(粒子)を用いて近似する。各分布に対する m 個の粒子を次のように表す。

$$\begin{array}{l} \text{一期先予測: } p(\mathbf{x}_t | Y_{t-1}), \quad \left\{ p_t^{(1)}, \dots, p_t^{(m)} \right\} \\ \text{フィルタ: } p(\mathbf{x}_t | Y_t), \quad \left\{ f_t^{(1)}, \dots, f_t^{(m)} \right\} \\ \text{スムージング: } p(\mathbf{x}_t | Y_N), \quad \left\{ s_{t|N}^{(1)}, \dots, s_{t|N}^{(m)} \right\} \\ \text{システムノイズ: } q(\mathbf{v}_t), \quad \left\{ v_t^{(1)}, \dots, v_t^{(m)} \right\} \end{array}$$

こ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。以下に、そのアルゴリズムを示す。

[モンテカルロフィルタアルゴリズム]

[Step1:初期分布の生成] 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 $f_0^{(i)}$ ($i = 1, \dots, m$) を得る。

[Step2: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] 各次元がシステムノイズ分布 $q(\mathbf{v}; m_q, \tau^2)$ に従う乱数ベクトルを m 個発生し、粒子 $v_t^{(i)}$ を得る。

[Step2-2:一期先予測の計算] 次式より、予測分布 $p(\mathbf{x}_t | Y_{t-1})$ に従う粒子 $p_t^{(i)}$ を得る。

$$p_t^{(i)} = f\left(f_{t-1}^{(i)}, v_t^{(i)}\right), \quad i = 1, \dots, m \quad (14)$$

[Step2-3:予測分布に従う粒子の尤度の計算] 次式より、粒子 $p_t^{(i)}$ の観測値 \mathbf{y}_t に関する尤度を得る。

$$\alpha_t^{(i)} = r\left(g\left(\mathbf{y}_t, p_t^{(i)}\right); m_r, \sigma^2\right) \left| \frac{\partial g}{\partial \mathbf{y}_t} \right|, \quad i = 1, \dots, m \quad (15)$$

ここで、 $g(\cdot)$ は観測方程式に含まれる関数 $h(\cdot)$ の逆関数(式(9)を \mathbf{w}_t について解いたもの)である。

[Step2-4:フィルタの計算] 一期先予測により得た粒子 $p_t^{(i)}$ を次の確率に従いリサンプリングし、フィルタの分布 $p(\mathbf{x}_t | Y_t)$ に従う粒子 $f_t^{(i)}$ を得る。

$$Pr\left(f_t^{(i)} = p_t^{(i)} | Y_t\right) = \frac{\alpha_t^{(i)}}{\alpha_t^{(1)} + \dots + \alpha_t^{(m)}}, \quad i = 1, \dots, m \quad (16)$$

スムージングの分布に対する粒子は、現在の一期先予測の粒子と共に、過去の粒子にもフィルタリングを行うことによって得られる[7]。つまり、上記のアルゴリズムの Step2-4 を次のように変更する。

[Step2-4:スムージングの計算] 一期先予測により得た粒子 $p_t^{(i)}$ および遅れ L までのスムージングの粒子からなる粒子の集合 $(s_{t-L|t-1}^{(i)}, \dots, s_{t-1|t-1}^{(i)}, p_t^{(i)})^T$ を式(16)の確率に従いリサンプリングし、固定ラグスムージングの分布 $p(\mathbf{x}_{t-L} | Y_t)$ に従う粒子 $s_{t-L|t}^{(i)}$ を得る。

ここでは、遅れが L の固定ラグスムージングのアルゴリズムを示した[†]。この場合、現時点より L 時点前までの粒子を保持しておく必要がある。

5 実験結果

観測ノイズ分布の非ガウス化とモデルパラメータのオンライン推定の、外れ値の影響軽減への有効性を確認するために、人工データおよび時系列画像から得た実データに対し実験を行った。また、これらのモデルの有効性検証のために、式(3),(4)の要素

[†]これは固定区間スムージングの分布 $p(\mathbf{x}_t | Y_N)$ の計算の際に、粒子のバリエーションが減少し、分布の縮退が生じることの対策として導入された[7]。

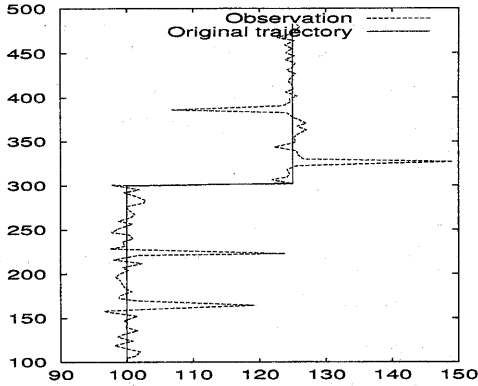


図 2: 実験に用いた人工データ。

をもちノイズにガウス分布を仮定した線形ガウス型モデルと比較した。線形ガウス型モデルの状態推定にはカルマンフィルタを用いた。

5.1 人工データに対する結果

次の条件で図2のデータを作成した。

特徴点の初期位置: (100, 100)

速度 (横方向, 縦方向): (0, 4) ($t < 50$), (5, 0.5) ($50 \leq t < 55$), (0, 4) ($55 \leq t < 100$)

ノイズ: 横方向: 尺度 50 のコーシー分布 ($\text{mod}(t/15) = 0, t \neq 0$), 分散 2 のガウス分布 (otherwise), 縦方向: 分散 0.5 のガウス分布

この人工データに対し、線形ガウス型モデルにカルマンフィルタを用いたもの (LG)、3.1.1 および 3.2 で示した線形非ガウス型モデルに MCF を用いたもの (LNG)、3.1.2 および 3.2 で示した非線形非ガウス型モデルに MCF を用いたもの (NLNG) のそれぞれで、フィルタリングおよび固定ラグスムージングを行った。固定ラグスムージングでの遅れは $L = 25$ とした。LNG, NLNG での粒子数は $m = 2000$ である。状態の初期分布は、平均が $[x(1), y(1), x(1), y(1)]^T$ または $[x(1), y(1), x(1), y(1), \log \sigma^2(1), \log \tau^2(1)]^T$ で、共分散行列が単位行列のガウス分布とした。

状態推定によって得られた分布は、 m 個の粒子により表現されている。これらの粒子から分布の代表値を計算し、これを状態推定値とする。特徴点の座標に対しては 2 次元ヒストグラムを、また、モデルパラメータに対しては 1 次元ヒストグラムを作り、そのモードを求めた。そして、モードの近傍での重み付き平均を状態推定値とした。

表 1: 人工データの状態推定結果と真値との平均 2 乗誤差。F: フィルタリング、S: スムージング。

LG		LNG		NLNG	
F	S	F	S	F	S
0.328	0.277	0.139	0.127	0.210	0.127

LG, LNG のモデルパラメータは、観測系列 Y_t に対するモデルパラメータの尤度 $l(\theta) = \sum_{t=1}^N p(y_t | Y_{t-1}; \theta)$, $\theta = \{\sigma, \tau\}$ に基づき設定した [11]。この尤度は、フィルタリングの過程で計算できる (式 (12))。パラメータの候補 $\sigma^2, \tau^2 = \{1, 2, \dots, 20\}$ の 400 通りの組み合わせについて尤度を計算し、尤度を最大とするパラメータ $\hat{\theta} = \arg \max_{\theta} l(\theta)$ を求めた。その結果、LG では $\sigma^2 = 10.0, \tau^2 = 1.0$ 、LNG では $\sigma^2 = 1.0, \tau^2 = 1.0$ となった。NLNG では、適当なモデルパラメータの初期値をユーザーが設定した。これは、モデルパラメータをオンライン推定する NLNG は、オフライン処理での $\hat{\theta}$ の計算が困難な場合に用いることを想定しているためである。初期値は、観測誤差を許容し滑らかさを優先した $\sigma^2/\tau^2 > 1$ であるパラメータ対の一つの $\sigma^2(1) = 3.0, \tau^2(1) = 1.0$ とした。

状態推定の結果、LG に比べ LNG、NLNG では外れ値の影響が軽減され、観測ノイズ分布の非ガウス化の有効性が確認された (図 4)。この効果は、雑音のない真の軌跡 (図 2 の original trajectory) と推定された軌跡との平均 2 乗誤差より、定量的にも確認された (表 1) *。

LNG と NLNG を比較する。フィルタリングでは、NLNG は LNG より推定誤差が大きくなった (表 1)。これはユーザーが設定した初期分布への依存性があり、状態推定によって全ての外れ値に対して有効なモデルパラメータが得られない場合もあるためと考えられる (図 4(e))。このフィルタリングの推定は、モデルパラメータの初期分布の変更により改善可能であると考えられ、より詳細な考察は今後の課題の一つである。スムージングでは、誤差が同じである。これはフィルタリングよりも多くの観測値に基づいて推定を行うため、モデルパラメータの影響が小さかったためと考えられる。

*LNG と NLNG では、異なる乱数で 101 回状態推定を行い、それらの誤差の中央値を示している。図 4(c)-(f) は、その中央値に対する結果である。



図 3: 特徴点の追跡. 左: 第 1 フレーム. 右: 第 60 フレーム. 黒い四角は追跡した特徴点である.

5.2 実データに対する結果

時系列画像の第 1 フレームで、コーナー検出フィルタ [13] により特徴点を抽出した。その追跡を 60 フレームに渡り行った (図 3)。その結果得られた運動軌跡 (図 5(a)) には、類似した明るさをもつ特徴点が多い背景の壁の格子や、誤ってコーナーが抽出された本の表紙の斜めの直線部分等に、多くの誤対応が含まれている。

固定ラグスムージングの結果を示す。固定ラグスムージングの遅れ L 、粒子数 m 、状態の初期分布は人工データの場合と同じである。モデルパラメータの設定のため、全ての運動軌跡に対しオフライン処理で最尤推定値 $\hat{\theta}$ を求めることは、計算時間の観点からオンライン処理である特徴追跡との整合性が悪い。そのため、ユーザーが適当なモデルパラメータを設定した。滑らかな軌跡と誤対応を含む軌跡が混在していることを考慮し、全ての方法で $\sigma^2 = 3.0$, $\tau^2 = 1.0$ を用いた (NLNG では初期値)。

処理の結果、LG、LNG、NLNG のいずれの場合も元の運動軌跡より滑らかな軌跡を得た (図 5(b)-(d))。しかし、実データにおいても、LG に比べ LNG、NLNG では外れ値の影響が軽減された。図 5(e),(f) は外れ値を含む運動軌跡に対する結果である。図 5(e) では、2 個所に見られる 8~12 画素の誤対応の影響が LNG、NLNG により軽減されている。また、図 5(f) では、約 25 画素の誤対応の影響が軽減されている。この結果より、実データに対しても、観測ノイズ分布の非ガウス化の有効性が確認された。

6 まとめ

特徴点の運動軌跡に含まれる誤対応に伴う外れ値の影響を軽減するために、裾の重い観測ノイズ分布をもつ非ガウス型状態空間モデルと、そのモデルパラメータのオンライン推定を導入した。その状態推


定方法としては、逐次モンテカルロ法を用いた。人工データおよび実データを用いた実験において線形ガウス型モデルとの比較を行い、観測ノイズ分布の非ガウス化により外れ値の影響を軽減できることを確認した。

謝辞

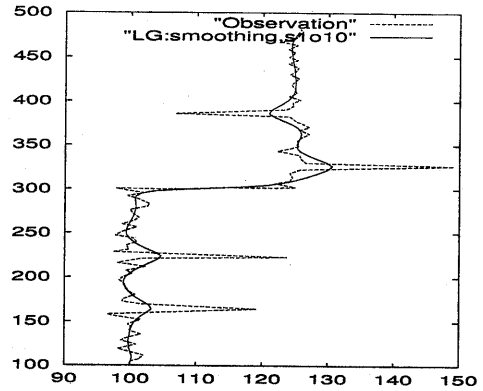
本研究の機会を与えて下さいました電総研知能情報部、大津展之部長に感謝致します。

参考文献


- [1] 浅田 稔: “ダイナミックシーンの理解,” 電子情報通信学会編, 1994
- [2] J.S. Meditch: “Stochastic optimal linear estimation and control,” McGraw-Hill, 1969
- [3] 片山 徹: “応用カルマンフィルタ,” 浅倉書店, 1983
- [4] C. J. Masreliez and R. D. Martin: “Robust Bayesian estimation for the liner model and robustifying the Kalman filter,” IEEE Trans. on Automatic Control, Vol.AC-22, No.3, pp.361-371, 1977
- [5] D. L. Alspach and H. W. Sorenson: “Nonlinear Bayesian estimation using Gaussian sum approximations,” IEEE Trans. on Automatic Control, Vol.AC-17, No.4, pp.439-448, 1972
- [6] 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
- [7] G.Kitagawa: “Monte Carlo filter and smoother for non-Gaussian nonlinear state space models,” J. Computational and Graphical Statistics, Vol.5, No.1, pp.1-25, 1996
- [8] M. Isard and A. Blake: “Condensation - Conditional density propagation for visual tracking,” Internat. J. Comp. Vis., Vol.29, No.1, pp.5-28, 1998
- [9] J. S. Liu and R. Chen: “Sequential Monte Carlo methods for dynamic systems,” J. Amer. Statist. Assoc., Vol.93, pp.1032-1044, 1998
- [10] G. Kitagawa: “Non-Gaussian state-space modeling of nonstationary time series,” J. Amer. Statist. Assoc., Vol.82, pp.1032-1063, 1987
- [11] H. Akaike: “Likelihood and the Bayes procedures,” Bayesian Statistics, pp.143-166, 1980
- [12] G. Kitagawa: “A self-organizing state-space model,” J. Amer. Statist. Assoc., Vol.93, pp.1203-1215, 1998
- [13] F. Chabat, G.Z. Yang and D.M. Hansell: “A corner orientation detector,” Im. and Vis. Comp., Vol.17, pp.761-769, 1999




(a)



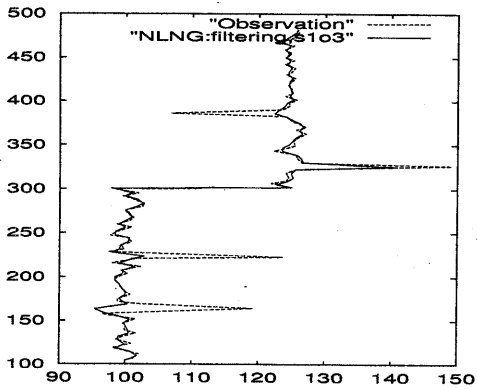
(b)



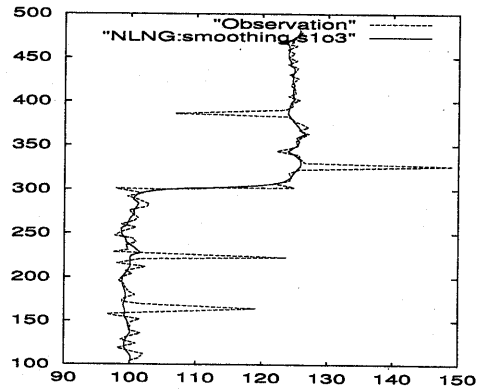
(c)



(d)




(e)




(f)


図 4: 人工データに対するフィルタリングおよび固定ラグスムージングの結果. 線形ガウス型モデルおよび線形非ガウス型モデルでは、モデルパラメータを尤度を用いて設定した。(a),(b) 線形ガウス型モデル。(c),(d) 線形非ガウス型モデル。(e),(f) 非線形非ガウス型モデル。



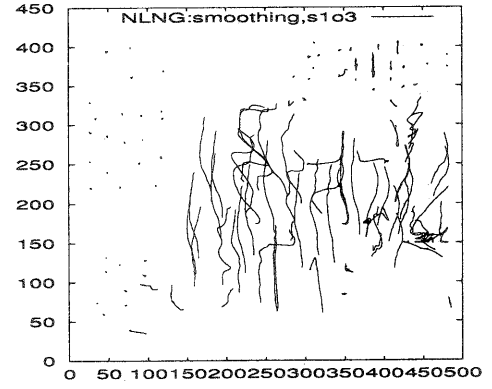
(a)




(b)




(c)



(d)



(e)



(f)

図 5: 時系列画像から得られた特徴点の運動軌跡に対する固定ラグスムージングの結果. (a) 観測値. (b) 線形ガウス型モデル. (c) 線形非ガウス型モデル. (d) 非線形非ガウス型モデル. (e),(f) 外れ値を含む運動軌跡に対する各方法による結果.