

状態推定フィルタ統合シミュレータ “StefAny” の開発

○森田賢¹ 西田健¹ (¹九州工業大学)

StefAny: State Estimation Filter Simulator for Any Practical Models

*M. Morita¹ and T. Nishida¹ (¹Kyushu Institute of Technology.)

Abstract: We developed state estimation filter simulator for any practical model (StefAny), which makes it easy to understand and compare behaviors of filters such as Kalman filter and particle filter. The key feature of StefAny is to show, when a system designer applies particle filter, a detailed graph representing relationship among distribution and weights of all particles on an arbitrary time through simulation. The time can be specified on another time series graph of estimation about each filter. In this paper we suggest how StefAny helpful for understanding detailed properties of the filters, and also introduce some knowledge found with StefAny.

Key Words: 状態推定フィルタ, カルマンフィルタ, パーティクルフィルタ, 統合シミュレータ

1 序論

確率分布のノイズを陽に扱う状態推定手法に、カルマンフィルタ (KF)¹⁾がある。しかし、KFはノイズのガウス性を仮定しているため、非ガウス性のノイズが混入するシステムでは適切な状態推定が難しい。一方、パーティクルフィルタ (PF)は非線形性・非ガウス性を有する状態空間モデルに対しても有効なフィルタであり、かつアルゴリズムが簡潔で実装が容易であるということから近年注目を集めている。それに伴い、解説を目的とした論文²⁾や書籍³⁾⁴⁾の出版、研究会の活動⁵⁾が行われており、ロボットや画像処理をはじめとする幅広い応用分野での適用事例が数多く報告されている。

一方でPFはその原理的な万能性と実装の容易さとは対照的に、実動作時には多数の粒子の挙動を把握することが難しいので、その推定特性を理解することが難しい。その理由として、非線形な事後確率分布を表現する上で重要な役割を果たす粒子に関するパラメータ (各粒子の重みや尤度、全粒子の状態空間方向のヒストグラムなど)がPFの推定に複雑に関連しあっており、かつ時系列でもその影響が伝搬していくので、それらの関連性の理解が難しいことが挙げられる。

PFはこのような複雑な特性を理解せずとも実装できることが利点ではあるが、特性の理解を曖昧にしたまま実装した場合、PFの性能を十分に発揮できない、あるいはPFによる推定が失敗する場合の対策を取ることができないという問題が生じる。これらの問題を解決し、システム設計者のPFに対する理解度と適用効果を向上させるためには、上述した粒子に関するパラメータ (粒子パラメータ)を可視化することが有効である。

従来より樋口²⁾や生駒³⁾による解説をはじめとする様々な文献において、粒子パラメータが推定結果に及ぼす定性的な影響について詳しい説明がなされている。更に踏み込み、実際に多数の粒子を用いたPF動作時における粒子パラメータの時系列推移を可視化して詳細な考察を加える取組みがCappéら⁶⁾によりなされている。しかし、可視化した情報を利用してPFの設計を容易化するためのツール開発に関する報告は見つからない。

そこで我々は状態推定フィルタに関するパラメータの可

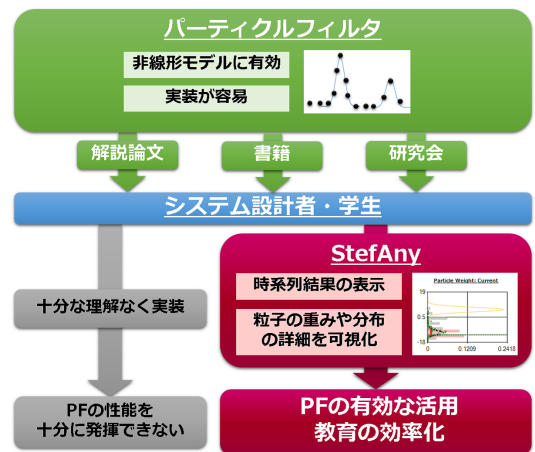


Fig. 1: StefAnyの開発コンセプト。

視化を目的として、Fig. 1に示す開発コンセプトのもと、統合シミュレータ state estimation filter simulator for any practical model (StefAny)を開発した。本論文ではその特長と有効性を示す。

StefAnyの特長は、時系列推定結果を表示するグラフと詳細な粒子パラメータを表示するグラフという二種類のグラフから構成されている点、前者のグラフ上で指定した時刻に対して後者の表示情報が常に同期されている点、の二点である。これらの機能により、任意の時刻における粒子パラメータと推定結果の関係を観察できるようにした点がStefAnyが有する最大の特長である¹⁾。外観をFig. 2に示す。

本論文の構成は次の通りである。2節においてStefAnyの画面構成と機能を示し、3節において本ツールでPFの評価シミュレーションの可視化結果を示し、有効性を検証する。有効性の検証に際し、現実のシステムで想定される多峰性モデルの推定特性の理解を深めることを目的に、ガウス性を有するモデルと多峰性を有するモデルに対する推定特性の比較シミュレーションを実施した。その結果を可視化したグラフと共に、StefAnyを活用したからこそ得られた知見を説明する。さらに、4節においてStefAnyを活

¹現在、本ツールが扱える信号の次元数は1次元である。



Fig. 2: StefAny の外観.

用したパラメータ設計方法について述べ、5 節で今後の展望を述べる。

2 画面構成と機能

本節では StefAny に関して、(1) ツール全体の画面構成概要、(2) 粒子パラメータグラフの詳細、について述べる。前者については、StefAny の画面全体を構成する要素のうち、主要なものについて機能の説明を行う。後者については、粒子パラメータの詳細情報を表示するグラフの詳細な機能を説明する。

2.1 ツール画面構成および機能

ここでは、Fig. 3 に示す StefAny の画面を構成する 4 つの主要な項目とそれらの機能について説明する。

画面要素 1: 粒子パラメータグラフ (Fig. 3 (a))

フィルタの推定に関する詳細情報 (e.g., 事前・事前推定値, 粒子重み・ヒストグラムなど) を表示する。マルコフ性を仮定したモデルの解析を想定し、指定時刻とその一時刻前の情報を同時に表示する。詳細を 2.2 で述べる。

画面要素 2: 時系列グラフ (Fig. 3 (b))

シミュレーションの時系列情報 (e.g., 真値, 観測値, フィルタ推定値, 推定誤差など) を表示する。

画面要素 3: モデル選択・フィルタパラメータ設定領域 (Fig. 3 (c))

シミュレーション時に必要となるモデルやフィルタのパラメータの設定 (e.g., 状態空間モデルの選択, PF の粒子数の設定など) を行う領域である。

画面要素 4: 表示項目選択領域 (Fig. 3 (d))

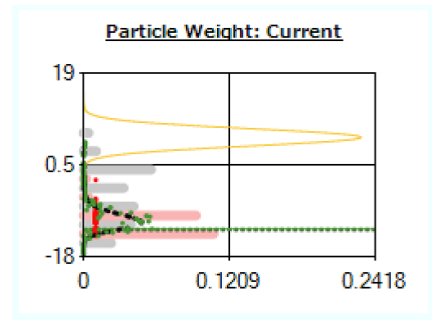
グラフに表示させる項目 (e.g., 真値, 観測値, 推定値表示対象のフィルタ, 粒子パラメータ) を選択する。着目したいパラメータだけの表示や、異なる複数のフィルタの推定結果の表示が可能である。

2.2 粒子パラメータグラフの詳細


ここでは、StefAny 最大の特長である粒子パラメータの表示について述べる。表示項目は、(1) KF の事前・事後推定値、(2) PF の各粒子の分布と重み、(3) PF の各粒子のリサンプリング後の分布と重み、(4) 点推定値、の四点である。(1) で KF の情報を表示した理由は、(2) ~ (4) で示す PF の特性との比較を行えるようにするためである。これらの表示方法を StefAny の画面と対応させて説明する。

詳細表示 1: KF の事前・事後推定値


Fig. 4 (a) において、KF の事前推定値を破線で、事後




(a) 粒子パラメータグラフ.



(b) 時系列グラフ.



(c) モデル選択・フィルタパラメータ設定領域.



(d) 表示項目選択領域.

Fig. 3: StefAny の主要な構成要素.

推定値を実線で示している。観測値を同時に示すことで、事前推定値から事後推定値が計算される過程の直観的な理解を支援する。また真値を同時に示すことで、事後推定値との誤差の評価を可能とする。

詳細表示 2: PF の各粒子分布・重み (リサンプリング前)

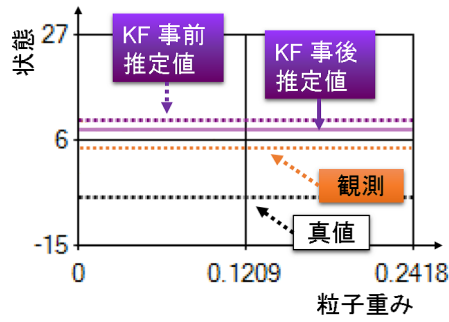
Fig. 4 (b) において、PF の各粒子の重みを黒色の丸による散布図で、粒子分布のヒストグラムを灰色の棒グラフで示している。

詳細表示 3: PF の各粒子分布・重み (リサンプリング後)


Fig. 4 (c) において、リサンプリング後の各粒子の重みを赤色の丸による散布図で、粒子の状態に対する分布のヒストグラムを赤色の棒グラフで示している。詳細表示 1 と比較することで、リサンプリング前後における粒子分布とヒストグラムの変化を観察できる。

詳細表示 4: PF の点推定値


Fig. 4 (d) において、粒子の事後確率分布を緑色の丸で、それから抽出した唯一の点推定値を緑の実線で示している。一般に、PF による事後推定から唯一の推定値 (特性値) を導出する点推定の手法として最小事情誤差 (MMSE: minimum mean square error) 推定もしくは最大事後確率 (MAP: maximum a posteriori) 推定が用いられ、Fig. 4 (d) には後者の手法の一つである pf-MAP 推定⁷⁾ による例を示す。点推定値が重みの頂点とは異なる位置にあることを



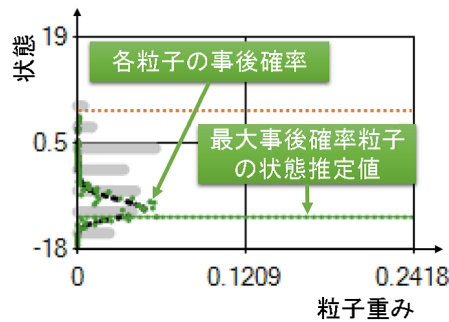
(a) KF の事前・事後推定値.



(b) PF の各粒子分布・重み (リサンプリング前).



(c) PF の各粒子分布・重み (リサンプリング後).



(d) PF の事後確率と点推定値.

Fig. 4: 粒子パラメータグラフの詳細.

確認できるが、それに関する考察と他の点推定手法との特性の比較について 3 節で述べる。

なお、ここ述べた詳細項目は画面要素 4 により選択的に表示させることができる。着目したいパラメータや解析の目的によってユーザが見やすい画面を設定できる。

3 有効性の検証

ここでは、StefAny を活用することで、PF の粒子パラメータが (1) ガウス性を有するモデルと、(2) 非ガウス性

Algorithm 1 Particle Filter

```

1: loop
2:   for  $m := 1$  to  $M$  do
3:      $\tilde{\mathbf{x}}_k^{(m)} = \mathbf{f}(\mathbf{x}_{k-1}^{(m)}, \mathbf{v}_k)$  //Sampling step
4:      $\tilde{\pi}_k^{(m)} = \pi_{k-1}^{(m)} \cdot p(\mathbf{y}_k | \tilde{\mathbf{x}}_k^{(m)})$  //Likelihood evaluation step
5:   end for
6:    $\tilde{\pi}_k^{(m)} := \tilde{\pi}_k^{(m)} / \sum_{i=1}^M \tilde{\pi}_k^{(i)}$ 
7:   point estimation
8:    $ESS = 1 / \sum_{i=1}^M (\tilde{\pi}_k^{(i)})^2$  //calculation of ESS
9:   for  $m := 1$  to  $M$  do
10:    if  $ESS < ESS_{th}$  then
11:       $\mathbf{x}_k^{(m)} := \begin{cases} \tilde{\mathbf{x}}_k^{(1)} & \text{with prob. } \tilde{\pi}_k^{(1)} \\ \vdots & \vdots \\ \tilde{\mathbf{x}}_k^{(M)} & \text{with prob. } \tilde{\pi}_k^{(M)} \end{cases}$  //Resampling step
12:       $\pi_k^{(m)} := 1/M$ 
13:    else
14:       $\mathbf{x}_k^{(m)} := \tilde{\mathbf{x}}_k^{(m)}$ 
15:       $\pi_k^{(m)} := \tilde{\pi}_k^{(m)}$ 
16:    end if
17:  end for
18:   $k := k + 1$ 
19: end loop

```

を有するモデル、の両モデルについて、状態推定に与える影響を観察できる点で有効性を備えることを述べる。

前者では、KF と PF の複数の点推定法による推定特性の違いを観察し考察する。後者では、PF で非ガウス性 (多峰性) を有するモデルに対する複数の点推定法の特性の違い、特に推定が成功するケースと失敗するケースを比較する。

3.1 PF のアルゴリズム

以下では離散時間を $k = 1, 2, \dots$ で表す。対象はマルコフ性を有する離散時間システムであり、その時間遷移は次の一般状態空間モデル

$$\mathbf{x}_k = \mathbf{f}(\mathbf{x}_{k-1}, \mathbf{v}_k) \quad (1)$$

$$\mathbf{y}_k = \mathbf{h}(\mathbf{x}_k, \mathbf{w}_k) \quad (2)$$

で表現するものとする。ここで、 \mathbf{x}_k は状態、 \mathbf{y}_k は観測、 \mathbf{v}_k はシステムノイズ、 \mathbf{w}_k は観測ノイズ、 $\mathbf{f}(\cdot)$ と $\mathbf{g}(\cdot)$ は非線形関数である。

PF は、状態 \mathbf{x}_k を M 個の重み付けされた粒子の集合 $\{(\mathbf{x}_k^{(m)}, \pi_k^{(m)})\}_{m=1}^M$ を用いて表現するために、各時刻における集合を Algorithm 1 によって更新する。ここで、 m は粒子の番号、 $\mathbf{x}_k^{(m)}$ は粒子の状態、 $\pi_k^{(m)} \geq 0$ は粒子の重み、4 行目の $p(\mathbf{y}_k | \tilde{\mathbf{x}}_k^{(m)})$ は各粒子の尤度である。リサンプリングの有無は有効サンプルサイズ (ESS: effective sample size) ³⁾ によって判定する。

3.2 PF の点推定手法

7 行目の点推定には、一般に MMSE 推定もしくは MAP 推定が用いられる。StefAny を活用することでこれらの推定の特性を観察することができる。前者は計算の容易さから特性値として多くの研究で利用されており、事後確率分布がガウス分布になる場合は適切な推定となることが知られているが、事後確率分布が非ガウス分布となる場合には適切な特性値とならない⁷⁾。現実のシステムにおいて事後確率分布が多峰性となる場合は多く存在するが、そのような場合に MMSE 推定は事後確率分布の峰と峰の間の谷の部分に算出される。一方、後者は導出のための計算

量は増加するものの、非ガウス分布に対して精度の高い特性値を与える。本論分では評価対象の点推定手法として、(1) MMSE 推定、(2) 最大重み (Maximum Weight: MW) 推定、(3) pf-MAP 推定⁷⁾、の三つの手法を比較する。(2) と (3) は MAP 推定法である。

MMSE 推定による特性値は

$$\hat{\mathbf{x}}_k^{\text{MMSE}} = \sum_{i=1}^M \pi_k^{(i)} \mathbf{x}_k^{(i)} \quad (3)$$

のように算出する。一方、MAP 推定で特性値を求める場合、事後確率密度 $p(\mathbf{x}_k^{(m)} | \mathbf{y}_{1:k})$ を最大化する $\mathbf{x}_k^{(m)}$ を

$$\hat{\mathbf{x}}_k^{\text{MAP}} = \arg \max_{\mathbf{x}_k^{(m)}} p(\mathbf{x}_k^{(m)} | \mathbf{y}_{1:k}) \quad (m \in [1, M]) \quad (4)$$

によって求める。MAP 推定には解析的な導出が難しい事後確率の最大化が必要であるため、単に最大重みを持つ粒子が MAP 推定として利用されることも多い。しかし、最大重みを有する粒子は必ずしも妥当な MAP 推定とならないことが示されている⁸⁾。一方、PF の事後確率からオンラインで MAP 推定を行うための手法としては pf-MAP が有効であることも報告されている⁸⁾。pf-MAP は式 (5) をモンテカルロ積分で近似した

$$\hat{\mathbf{x}}_k^{\text{MAP}} = \arg \max_{\mathbf{x}_k^{(m)}} p(\mathbf{y}_k | \mathbf{x}_k^{(m)}) \sum_i p(\mathbf{x}_k^{(m)} | \mathbf{x}_{k-1}^{(i)}) \pi_{k-1}^{(i)} \quad (5)$$

により事後確率を求める手法である⁷⁾。後述するシミュレーションでは MAP 推定について MW と pf-MAP の二手法を StefAny により観察した。

3.3 ガウス性モデルに対する状態推定

3.3.1 仮定

(a) シミュレーション対象のモデル

シミュレーション対象とする状態空間モデルを

$$x_k = x_{k-1} + 1 + v_k \quad (6)$$

$$y_k = x_k + w_k \quad (7)$$

とする。いずれもスカラー変数である。PF の推定特性の理解を支援する StefAny の開発目的を達成するために、等速直線運動という挙動の把握が容易なモデルを採用した。また、各ノイズは

$$v_k \sim \mathcal{N}(0, \sigma_v^2) \quad (8)$$


$$w_k \sim \mathcal{N}(0, \sigma_w^2) \quad (9)$$

とした。ただし、 σ_v^2 はシステムノイズの分散、 σ_w^2 は観測ノイズの分散である。本シミュレーションでは $\sigma_v^2 = 1$ 、 $\sigma_w^2 = 3$ とした。


KF のアルゴリズムとしては、線形カルマンフィルタ (LKF) を採用した。

(b) 初期値

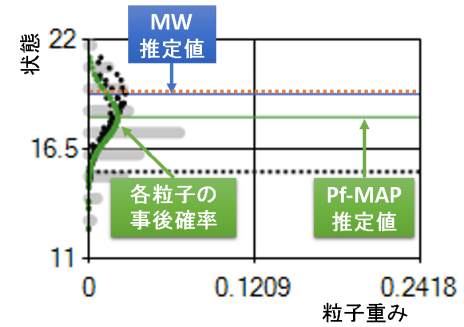
状態の初期値を $x_0 = -20 + v_0$ 、KF の推定の初期値を -20 、PF の粒子数を 100、粒子の初期状態を $x_0^{(m)} \sim \mathcal{N}(-20, \sigma_v^2)$ と設定した。



(a) KF.



(b) MMSE.



(c) MW と pf-MAP.

Fig. 5: ガウス性モデルに対する点推定結果.

3.3.2 KF の事後推定と PF の点推定の比較と考察

ここでは、Fig. 5 (a) に示す KF の事後推定値と対比しながら PF の複数の点推定手法の特性について考察する。 $k = 36$ における各点推定手法のシミュレーション結果のグラフを Fig. 5 に、推定値の一覧表を Table 1 に示す。

まずは、Fig. 5 (b) に示す MMSE 推定の結果について考察する。MMSE 推定では全粒子の重み付き平均を取るため、過去の推定の影響を引き継いでいる粒子の分布の影響を残すような特性値を算出する。したがって、観測に瞬間的に大きなノイズが乗り尤度関数の峰が真値から外れるような場合でも、推定値を大きく外す結果とはなりにくい。

次に、Fig. 5 (c) の MAP 推定の結果に着目する。MW 推定、観測に近い特性値となっているが、pf-MAP 推定では観測と粒子分布ヒストグラムの峰の間の特性値が抽出されている。前者は、観測尤度の影響を強く受ける特性を示している。後者は、式 (5) の $\sum_i p(\mathbf{x}_k^{(m)} | \mathbf{x}_{k-1}^{(i)}) \pi_{k-1}^{(i)}$ の部分が MAP 推定結果に大きく寄与する。この働きにより、pf-MAP 推定は MW 推定と比べて、粒子のヒストグラムの峰寄りの位置に得られるのであるが、それがこのツールで時系列前後のパラメータを観察することで理解できる。

Table 1: ガウス性モデルのシミュレーションにおける Fig. 5 の KF との PF の推定結果.

推定手法	KF	MMSE	pf-MAP	MW	Truth
推定値 ($k = 36$)	18.241	18.420	18.108	19.273	16.634
RSME	1.636	1.5824	2.166	2.167	-

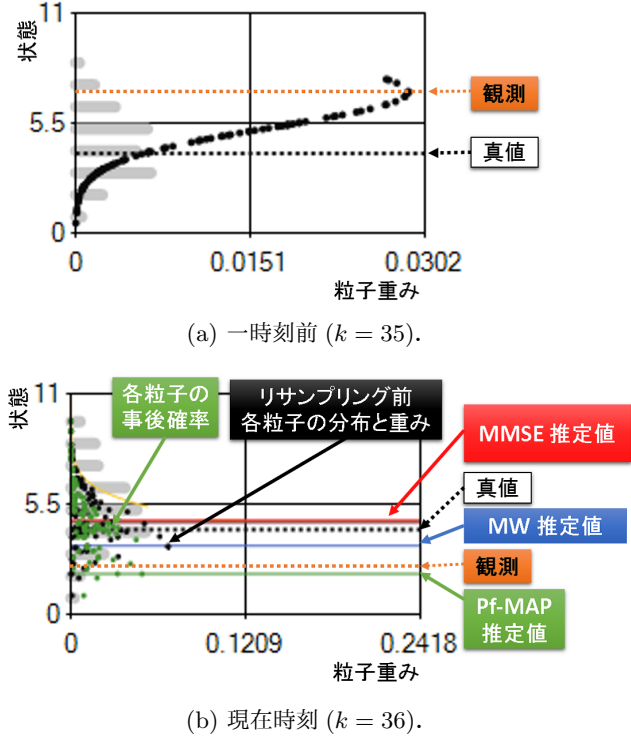


Fig. 6: ガウス性モデルに対して pf-MAP の推定が失敗する場合 ($k = 36$) の粒子パラメータグラフ.

以上の結果から、評価した手法のうち、MW のみが観測の影響を過度に受けており、確かに MW が妥当ではない推定値を算出したことが分かる。また、Table 1 に示したシミュレーション時間全体の root mean square error (RSME) を見ると、MMSE 推定がよい精度を出している。この結果が生じる過程を直感的に理解できるようにした点、StefAny の特長である。

3.3.3 PF の MAP 推定が失敗するケース

Table 1 に示す RSME から、MW 推定よりも改善された手法である pf-MAP 推定の精度が悪いことが分かる。そこで、pf-MAP 推定が失敗する時刻に着目し、原因について考察する。例えば $k = 23$ のときの推定結果を StefAny で観察すると Fig. 6 のようになっており、pf-MAP 推定が妥当ではない。これは、一時刻前と現時刻の状態に観測がノイズによって大きく変動することによって、前時刻までの推定が現時刻の推定に強く影響を与えるためである。この現象は、例えば一時刻前のグラフでは観測値は真値に対して大きく正に偏った値をとる一方で、現在時刻において観測値が真値に対して大きく負の値をとる場合に発生する。隣接する時刻で状態量や観測値がノイズから大きな影響を受けると、一時刻前では重みが大きく現在時刻では尤度が小さい粒子、あるいは反対に一時刻前では重みが小さく現在時刻では尤度が大きい粒子が多数出現する。

一時刻前の重み $\pi_{k-1}^{(m)}$ が極端に小さな値である場合には、

現在時刻の尤度 $p(\mathbf{y}_k | \hat{\mathbf{x}}_k^{(m)})$ が大きな値をとったとしても、現在時刻の重み $\pi_k^{(m)}$ がリサンプリング処理を経ずに適切な値となるためには、数ステップの時間を要する。これにより、短時間ではあるが、不正確な事後確率分布が形成されたことが、推定精度低下の原因と考えられる。重みを元に計算を行う事後確率も同様の分布をとる。重みと尤度の大小関係が逆転しても同様の現象が生じることが観察された。このような不正確な推定分布から MAP 推定を行うと正確な特性値を抽出するのは困難となる。

一方、上記と同じ粒子の分布に対する MMSE 推定に着目すると、全粒子の重み付き平均をとるために事後分布が不正確な値をとった場合でも妥当な推定値を算出できることが観察された。

3.4 非ガウス性ノイズを有するモデルに対する状態推定

3.4.1 仮定

(a) シミュレーション対象のモデル

ここでは観測を二つに増やし、非ガウス性ノイズを有するモデルを仮定する。シミュレーション対象とする状態空間モデルを

$$x_k = x_{k-1} + 1 + v_k \quad (10)$$

$$y_k^1 = x_k + w_k^1 \quad (11)$$

$$y_k^2 = x_k + w_k^2 \quad (12)$$

と定義する。いずれもスカラー変数である。 y_k^1 は正しい観測値、 y_k^2 はバイアスを持つ誤った観測値であることを想定したモデルである。ノイズは

$$v_k \sim \mathcal{N}(0, \sigma_v^2) \quad (13)$$

$$w_k^1 \sim \mathcal{N}(b_1, \sigma_{w_1}^2) \quad (14)$$

$$w_k^2 \sim \mathcal{N}(b_2, \sigma_{w_2}^2) \quad (15)$$

とする。ただし、 σ_v^2 はシステムノイズの分散、 b_1 は一つ目の観測ノイズの期待値、 b_2 は二つ目の観測ノイズの期待値、 $\sigma_{w_1}^2$ は一つ目の観測ノイズの分散、 $\sigma_{w_2}^2$ は二つ目の観測ノイズの分散である。本シミュレーションでは $b_0 = 0$ 、 $b_1 = -6$ 、 $\sigma_v^2 = 1$ 、 $\sigma_{w_1}^2 = \sigma_{w_2}^2 = 3$ とした。3.3.1 に比べて分散を大きくしたのは非ガウス性による二つの峰を捉えやすくするためである。

(b) 初期値

状態の初期値を $x_0 = -20 + v_0$ 、KF 推定の初期値を -20 、PF の粒子数を 100、粒子の初期状態を $x_0^{(m)} \sim \mathcal{N}(-20, \sigma_v^2)$ と設定した。






Fig. 7: 非ガウス性モデルに対する MMSE 推定結果 (左: $k = 10$, 右: $k = 14$)。橙色の実線で示す観測値 2 がバイアスを含む。



(a) $k = 10$. 妥当な推定値を与える場合.



(b) $k = 14$. 妥当ではない推定値を与える場合.

Fig. 8: 非ガウス性モデルに対する MAP 推定結果

3.4.2 PF 点推定特性の比較

3.3 と同様に MMSE 推定, MW 推定, pf-MAP 推定の比較を行った. MAP 推定が成功する場合と失敗する場合の比較を行うため, ある二つの時刻 ($k = 10, k = 14$) に着目した.

まず, 非ガウス性モデルに対する MMSE 推定の結果を Fig. 7 に示す. 観測値 2 がバイアスを加えた誤った観測値である. 二つの観測の中央周辺に特性値が算出されており, 不適切な推定となっていることが分かる.

次に, MW 推定の結果を Fig. 8 (a) の青色の線で示す. 二つの観測値のどちらかに近い特性値をとるが, どちらをとるかは定まらず振動的であり, これも適切な特性値とは言えない.

最後に, pf-MAP 推定の結果を Fig. 8 (a) の緑色の線で示す. 3.3.2 で述べた pf-MAP 推定の特長により, プロセスモデルに従った事前推定の結果を反映させた妥当な確率分布と点推定結果を得ている. この点で, pf-MAP 推定は非ガウス性モデルに対する優位な推定特性を備えていると言える.

3.4.3 pf-MAP による点推定が失敗するケース

非ガウス性モデルに対する pf-MAP 推定の結果が妥当ではない場合には, (1) 観測の尤度が大きくなるように粒子と観測の分布が形成された, (2) 現時刻において評価が困難なまばらな粒子の分布をとる, という現象が起きていることを観察した.

(1) が発生した際のグラフを Fig. 8 (b) に示す. バイアスを含む誤った観測値の尤度の方が大きくなるような分布を粒子と観測がとると, 事後確率分布で最大値をとる峰が誤った観測側の影響を強く受ける結果となる.

(2) が発生した際の現象は Fig. 6 と同様の結果となる. 3.3.3 で示した状況と同様であり, 大きなノイズが発生する場合に急速に対応できないことがある. これは粒子数が十分でないことや, サンプルによる粒子の分布に十分な多様性が確保されていないことが原因である. また, PF は観測の尤度, 粒子の重み, 粒子の分布のいずれかにおいて設計で想定した以上の誤差が生じた場合にその推定が崩壊することを, StefAny による可視化で確認できた.

4 StefAny による PF 設計方法の提案

StefAny を活用することで, 点推定のみでは評価が難しいパラメータの可視化により, 推定が失敗する場合の詳細な検証が可能となる.

例えば, Fig. 6 で生じるような粒子が分布を十分に表現しきれない現象が生じたことが観察された場合には, 粒子数を大きくすれば良い. ただし, その数をどの程度大きくすれば十分に分布を表現できるかを判断する際に StefAny による可視化が有効となる. あるいは, StefAny は粒子分布のヒストグラムも可視化できるため, サンプル時の確率分布関数やその分散をさまざまに変えてみながら, 対象モデルに対して適切なノイズの設定を行うことができる.

さらに, 推定対象のモデルに対してどの点推定手法を選択すべきかを判断する場合にも, StefAny を使って各推定手法の特性を俯瞰できる.

5 まとめと今後の展望

特性の把握が難しい PF の重要なパラメータを可視化するシミュレータ StefAny の機能と有効性について説明した. その特性を KF と対比させたり, 粒子の重みに加え粒子のヒストグラムや MAP 推定の事後確率も同時に可視化することで PF の推定特性の把握に有効であることを示した. マルコフ性を考慮し, その粒子パラメータを二時刻連続で表示させる点も本ツール独自の長所である.

今後の展望としては, 非線形モデルを対象としたり, 他の種類のノイズのモデルを適用した場合の挙動の観察を可能にすることが挙げられる. また, 扱えるモデルを多次元に拡張したり, 実観測データを取り込んでオフライン解析を可能とする機能の追加が考えられる.

将来的には, 本ツールで評価した PF のパラメータ設計によって実機での推定特性の向上に寄与させることを目指す. さらに, StefAny を九州工業大学西田研究室のホームページ⁹⁾ で近日公開予定である.

参考文献

- 1) 足立, 丸田: カルマンフィルタの基礎, 東京電機大学出版局 (2012).
- 2) 樋口: 粒子フィルタ, 電子情報通信学会誌, **88**, 12, pp. 989–994 (2005).
- 3) 生駒: 「21 世紀の統計科学」第 III 巻, 第 11 章逐次モンテカルロ法とパーティクルフィルタ, pp. 290–326, 東京大学出版会 (2008).
- 4) S. Thrun, W. Burgard, D. Fox, 上田: 確率ロボティクス, MYCOM ROBOT books, 毎日コミュニケーションズ (2007).
- 5) パーティクルフィルタ研究会. <http://www.sys.ecs.kyutech.ac.jp/~ikoma/PF/>, (Accessed: 2015-07-14).
- 6) O. Cappé, S. J. Godsill and E. Moulines: An overview of existing methods and recent advances in sequential Monte Carlo, Proceedings of the IEEE, **95**, 5, pp. 899–924 (2007).
- 7) H. Driessen and Y. Boers: MAP estimation in particle filter tracking, Proceedings of the IET the IET Seminar on Target Tracking and Data Fusion: Algorithms and Applications, IET, pp. 41–45 (2008).
- 8) S. Saha, Y. Boers, H. Driessen, P. K. Mandal and A. Bagchi: Particle based MAP state estimation: A comparison, Information Fusion, 2009. FUSION'09. 12th International Conference on IEEE, pp. 278–283 (2009).
- 9) 九州工業大学 西田研究室. <http://lab.cntl.kyutech.ac.jp/~nishida/>, (Accessed: 2015-07-20).