

等価重み粒子フィルタによる非線形モデルの時変パラメータ推定

佐藤 峰斗

総合研究大学院大学 統計科学専攻 博士課程(5年一貫制)5年

1. 概要

目的: 気象や海洋などの高次元・非線形システムの予測精度向上に向け、予測精度を左右するモデルパラメータの推定手法を提案する。

課題: 粒子フィルタは非線形モデルにも適用可能だが、退化の問題がある。

アプローチ: 全粒子の重みを等しくすることで退化を抑制する、等価重み粒子フィルタ (IEWPF) [1] をパラメータ推定に拡張する。

2. 提案手法

2-1. 変数・パラメータに相関のある拡大状態空間モデル

下記のような一般的な拡大状態空間モデルへの拡張では、変数とパラメータの摂動項(システムノイズ)が独立である。(n: 時間ステップ)

$$\begin{pmatrix} x^n \\ \theta^n \end{pmatrix} = \begin{pmatrix} f(x^{n-1}, \theta^{n-1}) \\ \theta^{n-1} \end{pmatrix} + \begin{pmatrix} \beta^n \\ \eta^n \end{pmatrix}, \quad \beta \sim N(0, Q_\beta), \quad \eta \sim N(0, Q_\eta). \quad (1)$$

非線形モデル f へのパラメータの寄与を以下のように一次近似すると

$$f(x^{n-1}, \theta^{n-1}) \cong f(x^{n-1}, \theta^{n-2}) + \frac{\partial f}{\partial \theta} (\theta^{n-1} - \theta^{n-2}), \quad (2)$$

システムモデルは以下のように相関のある形で表される。

$$\begin{pmatrix} x^n \\ \theta^{n-1} \end{pmatrix} = \begin{pmatrix} f(x^{n-1}, \theta^{n-2}) + \frac{\partial f}{\partial \theta} \eta^{n-1} + \beta^n \\ \theta^{n-2} + \eta^{n-1} \end{pmatrix} = \begin{pmatrix} f(x^{n-1}, \theta^{n-2}) \\ \theta^{n-2} \end{pmatrix} + \tilde{\beta}^n, \quad (3)$$

ここで

$$\tilde{\beta}^n \sim N(0, \tilde{Q}^n), \quad \tilde{Q} = \begin{pmatrix} Q_\beta + \frac{\partial f}{\partial \theta} Q_\eta \frac{\partial f^T}{\partial \theta} & \frac{\partial f}{\partial \theta} Q_\eta \\ Q_\eta \frac{\partial f^T}{\partial \theta} & Q_\eta \end{pmatrix}. \quad (4)$$

2-2. 等価重み粒子フィルタの実現方法

Zhu et al. によって提案された The Implicit Equal-Weights Particle Filter (IEWPF) [1] は、提案分布を以下の式(5)で与える。

$$x_i^n = x_i^{n,a} + \alpha_i^{1/2} P^{1/2} \xi_i, \quad \xi_i \sim N(0, \mathbf{I}) \quad (5)$$

ここで、 $x_i^{n,a}$ 、 P は以下の最適提案分布の平均と分散共分散行列である。

$$x_i^{n,a} = f(x_i^{n-1}) + QH^T(HQH^T + R)^{-1}(y^n - Hf(x_i^{n-1})), \quad P = (Q^{-1} + H^T R^{-1} H)^{-1} \quad (6)$$

式(5)は提案分布 $q(x^n | x_{1:n}^{n-1}, y^n) = \frac{q(\xi)}{\|\frac{dx}{d\xi}\|}$ 導入による変数変換 $x_i \rightarrow \xi_i$

を表し、各粒子の重みが等しくなるために α_i が満たすべき条件は、

$$-2 \log w_i^n = -2 \log w_i^{n-1} - 2 \log \left(\frac{p(y^n | x_i^n) p(x_i^n | x_i^{n-1})}{q(\xi)} \left\| \frac{dx}{d\xi} \right\| \right) \quad (7)$$

と表される。ここで w_i^n は粒子 i , ステップ n における重みを表す。観測・システムノイズをガウス分布、観測モデル H を線形とすると、

$$e^{-\frac{\alpha_i \gamma_i}{2}} (\alpha_i \gamma_i)^{\frac{N_x}{2}-1} \left| \frac{d(\alpha_i \gamma_i)}{d\gamma_i} \right| = e^{-\frac{\gamma_i}{2}} \gamma_i^{\frac{N_x}{2}-1} e^{-\frac{c_i}{2}} \quad (8)$$

と変形できる[1]。ただし $\gamma_i = \xi_i^T \xi_i$, c は重みの定数項を示す。式(8)は、不完全ガンマ関数 Γ を用いて

$$\pm \Gamma\left(\frac{N_x}{2}, \frac{\alpha_i \gamma_i}{2}\right) = \Gamma\left(\frac{N_x}{2}, \frac{\gamma_i}{2}\right) e^{-\frac{c_i}{2}} \quad (9)$$

と表される[1]。この式(9)を満たす α_i は、高次元の仮定(変数 x の次元 $N_x \rightarrow \infty$)の下で、解析解は Lambert W function で表される。

図1に各時間ステップで算出された α_i の分布を示す。図1に示すように、 $\alpha = 1$ を境に2つの branch をもつため、 $\alpha \leq 1$ と $\alpha \geq 1$ から適切に選択する必要がある。

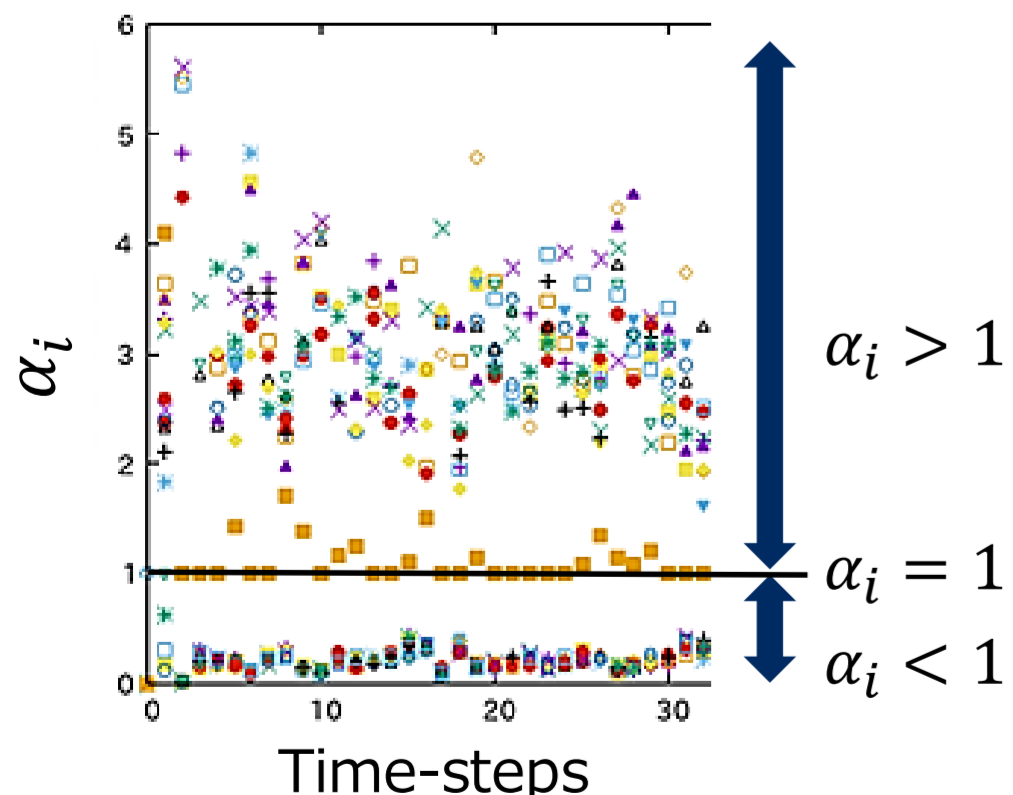


図1. 算出された時系列 α_i の分布の例

References

- Zhu, Mengbin, Peter Jan Van Leeuwen, and Javier Amezcua. "Implicit equal-weights particle filter." Quarterly Journal of the Royal Meteorological Society 142.698 (2016): 1904-1919.
- Kingma, D. P., and Ba, J. (2014). Adam: A method for stochastic optimization. arXiv preprint arXiv, 1412.(6980).

2-3. パラメータ予測へのオンライン最適化手法の導入

式(5)(6)より、観測値があるステップ n , 粒子 i の事後分布(フィルタ分布)からのサンプリングは、

$$\begin{pmatrix} x_i^n \\ \theta_i^{n-1} \end{pmatrix} = \begin{pmatrix} f(x_i^{n-1}, \theta_i^{n-2}) \\ \theta_i^{n-2} \end{pmatrix} + K(y^n - Hf(x_i^{n-1}, \theta_i^{n-2})) + \alpha_i^{1/2} P^{1/2} \xi_i \quad (10)$$

と表される。ただし、 $K = \tilde{Q}H^T(H\tilde{Q}H^T + R)^{-1}$, $P = (\tilde{Q}^{-1} + H^T R^{-1} H)^{-1}$.

\tilde{Q} は式(4)で与えられる。観測値のないステップは、観測データ y^n の情報を入れた提案分布 $q(\theta^n | \theta_i^{n-1}, y^n)$ を用いて、パラメータの予測分布を

$$p(\theta^n | \theta_i^{n-1}, y^{1:n}) = \frac{1}{N} \sum_{i=1}^{N_p} \frac{p(\theta^n | \theta_i^{n-1})}{q(\theta^n | \theta_i^{n-1}, y^n)} q(\theta^n | \theta_i^{n-1}, y^n) \quad (11)$$

と表す。この提案分布 q を以下のように生成し、

$$q(\theta^n | \theta_i^{n-1}, y^n) = N(\theta^{n-1} - \lambda g_i^n, Q) \quad \lambda: \text{Step size factor} \quad (12)$$

関数 g_i^n をステップ n , 粒子 i のロス関数:

$$L_i^n(\theta) = (y^n - Hf(x_i^{n-1}, \theta_i^{n-2}))^T (HQH^T + R)^{-1} (y^n - Hf(x_i^{n-1}, \theta_i^{n-2})) \quad (13)$$

の勾配を用いて計算すると、式(12)は、

$$\theta^n \leftarrow \theta^{n-1} - \lambda g^n \quad (g^n \propto \nabla L_i^n) \quad (14)$$

と、パラメータ θ をステップ毎にロス関数の勾配で更新することを示す。式(14)の更新には、最適化で用いられる各種アルゴリズムが適用できる。

3. 数値実験: Lorenz-96 モデルによる双子実験

3-1. 外力項にパラメータを導入したモデル

Lorenz-96 モデルを用いて、高次元・非線形システムにおける時間変化するパラメータ推定の妥当性を評価する。Lorenz-96 モデル:

$$\frac{d}{dt} x_j = (x_{j+1} - x_{j-2})x_{j-1} - x_j + F_j \quad (15)$$

の外力項 F_j を、3つのパラメータ ($\theta_0, \theta_1, \theta_2$) を導入して以下のように表す:

$$F_j = \theta_{0\text{true}} \theta_0 + \theta_{1\text{true}} \theta_1 \sin\left(\frac{2\pi}{\theta_{2\text{true}} \theta_2} j\right) \quad (16)$$

($\theta_{0\text{true}}, \theta_{1\text{true}}, \theta_{2\text{true}}$) = (8, 4, 1000) で、パラメータ3つの真値を 1.0 から変化させて疑似観測データを生成した。変数と観測データの分散共分散行列 Q_β , R は、それぞれ対角項 0.1, 隣接(上下)対角項 0.025、 $R = 0.01 I$ とし、疑似観測データ生成時と推定時で同じ値を用いた。パラメータの分散共分散行列 Q_η は対角とし、観測データ生成時は 0、推定時は 1.0×10^{-5} とした。

3-2. 時変パラメータ推定の手法間比較 (1000次元)

各パラメータの真値と粒子軌跡の比較を図2に示す。変数 x の次元は1000で、全ての変数が4ステップ毎に観測される条件とし、粒子数 $N_p = 20$ とした。

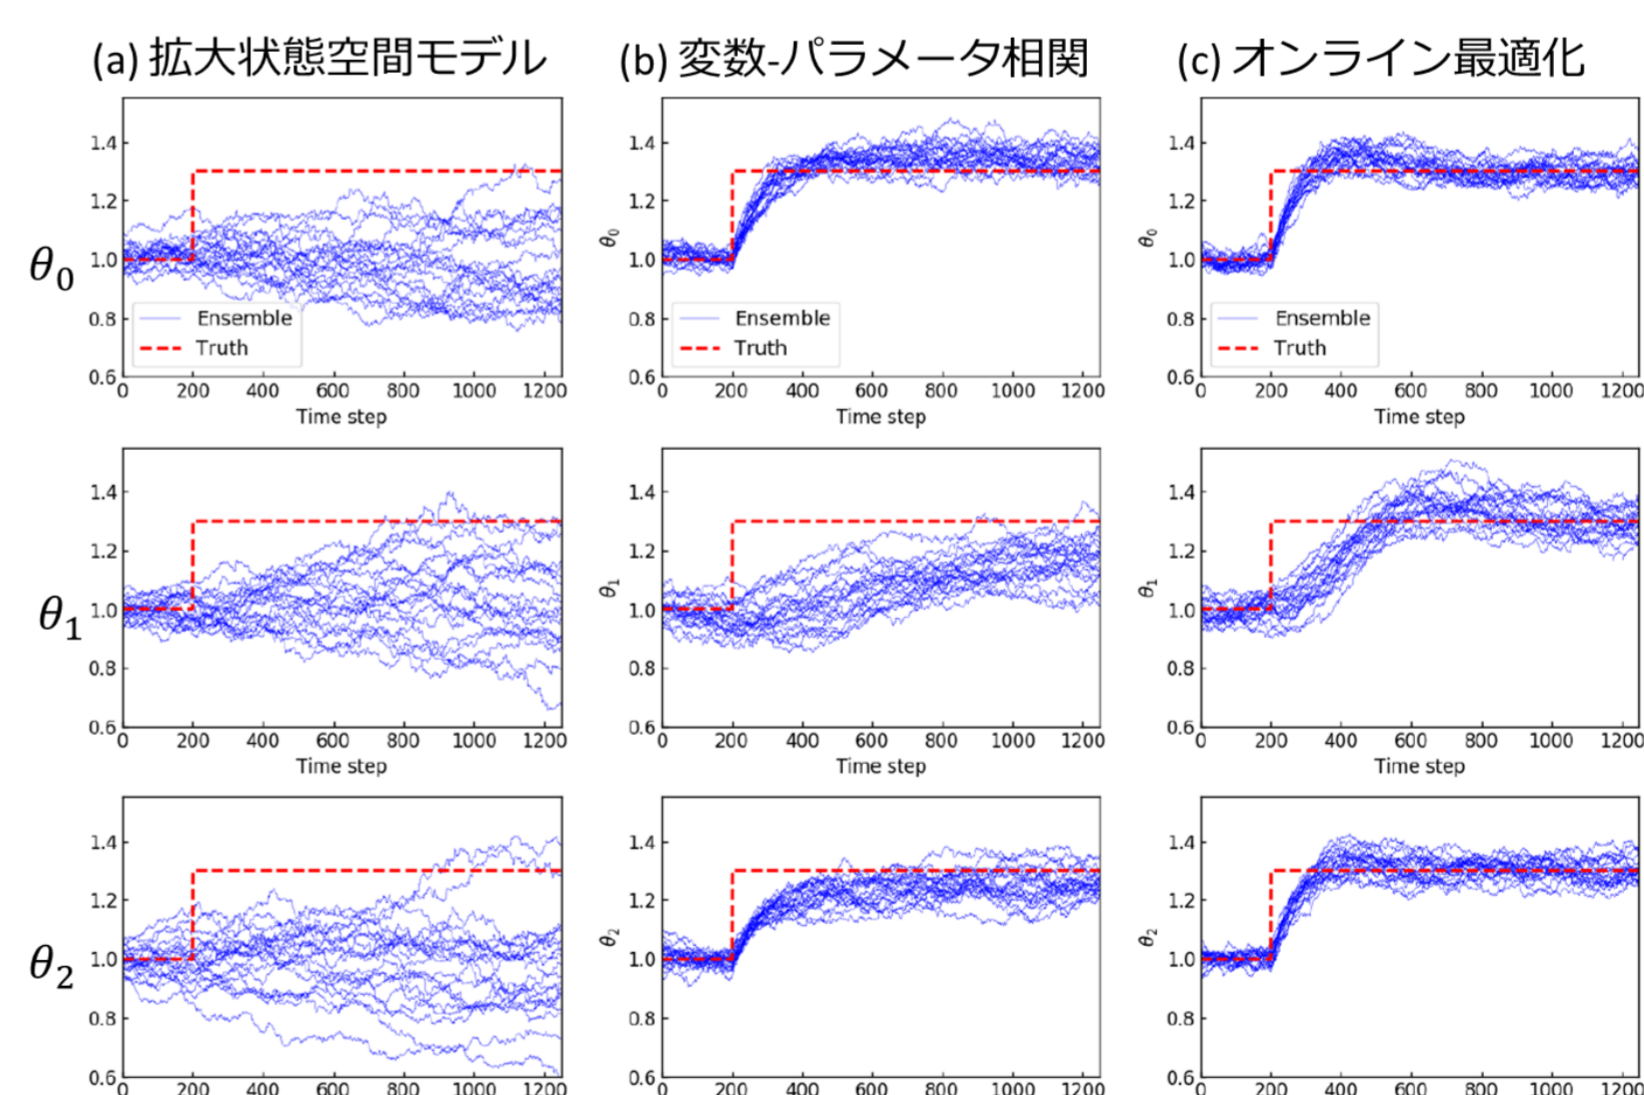


図2. 各パラメータの真値(200ステップで+30%)と粒子軌跡の手法間比較

4. 結論

等価重み粒子フィルタを拡張し、高次元・非線形モデルのパラメータ推定における提案手法の有効性を、1000次元・20粒子の条件で確認した。特にオンライン最適化の導入は、パラメータ変動への追従性向上に効果的であった。