

PF とその周辺

竹田航太

2023 年 5 月 18 日

目次

| | | |
|-----|----------------------------------|---|
| 1 | 仮定 | 1 |
| 2 | 全体 [1] | 1 |
| 2.1 | Proposal density [1] | 2 |
| 2.2 | Transportation [1] | 2 |
| 3 | LPF | 4 |
| 4 | OTPF | 4 |
| 5 | Linear Ensemble Transform Filter | 4 |

1 仮定

$\boldsymbol{x} \in \mathbb{R}^N$.

$$X = [\boldsymbol{x}_1, \dots, \boldsymbol{x}_M] \in \mathbb{R}^{N \times M}$$

2 全体 [1]

PF のサーベイ [1] によると, PF の課題は一つの particle に重みが集中する “weight degeneracy” であり, それを改善する 4 つの方向性について紹介している.

- (1) proposal density: 高次元で課題
- (2) ensemble transform: localization or multi-step
- (3) local Particle Filter

(4) combination with EnKF

通常の PF

$$p(\mathbf{x}^n) \approx \sum_{i=1}^M w_i^{n-1} p(\mathbf{x}^n | \mathbf{x}_i^{n-1})$$
$$p(\mathbf{x}^n | y^n) \approx \sum_{i=1}^M w_i^{n-1} \frac{p(y^n | \mathbf{x}^n)}{p(y^n)} p(\mathbf{x}^n | \mathbf{x}_i^{n-1})$$

と近似し $p(\mathbf{x} | \mathbf{x}_i^{n-1})$ に従うサンプル \mathbf{x}_i^{n-1} を用いて $p(\mathbf{x} | \mathbf{x}_i^{n-1}) \approx \delta(\mathbf{x} - \mathbf{x}_i^{n-1})$ と近似する。重みの update を

$$w_i^n = w_i^{n-1} \frac{p(y^n | \mathbf{x}^n)}{p(y^n)}$$

で行う。

2.1 Proposal density [1]

proposal density のアイデアは proposal density $q(x^n | x^{n-1}, y^n)$ を用いて

$$p(\mathbf{x}^n | y^n) \approx \sum_{i=1}^M w_i^{n-1} \frac{p(y^n | \mathbf{x}^n)}{p(y^n)} \frac{p(\mathbf{x}^n | \mathbf{x}_i^{n-1})}{q(x^n | x^{n-1}, y^n)} q(x^n | x^{n-1}, y^n)$$

と変形し $q(x^n | x^{n-1}, y^n)$ に従うサンプル x_i^n と通常のを修正した重み

$$\hat{w}_i^n = w_i^n \frac{p(\mathbf{x}^n | \mathbf{x}_i^{n-1})}{q(x^n | x^{n-1}, y^n)}$$

を用いて $p(x^n | y^n)$ を近似する。

nudging(relaxation) を proposal にする方法や EnKF(PO 法) を proposal にする方法がある。いずれの場合も proposal density は Gaussian で書くことができる。

2.2 Transportation [1]

Ensemble DA において prior を posterior に移す変換 D を deterministic に探す方法。

$$X^a = X^f D.$$

2.2.1 ETPF

(Cheng-Reich) たとえば, ETPF は OT を用いて変換 D を求める [2].

2.2.2 Tempering

変換を多段階に分けて行う tempering という方法もある.

$$p(y|\mathbf{x}) = p(y|\mathbf{x})^{\gamma_1} \dots p(y|\mathbf{x})^{\gamma_K}, \quad \sum_{k=1}^K \gamma_k = 1$$

と分けて

$$p_1(\mathbf{x}|y) = \frac{p(y|\mathbf{x})^{\gamma_1}}{p(y)} p(\mathbf{x})$$
$$p_k(\mathbf{x}|y) = \frac{p(y|\mathbf{x})^{\gamma_{k-1}}}{p(y)} p_{k-1}(\mathbf{x}|y)$$

と K 回に分けて particle Filter を行う.

2.2.3 Particle Flow Filter

ある dynamics に従って重みの等しい prior particles を重みの等しい posterior particles に移す方法, またそのような dynamics を決める方法.

$$\frac{d}{ds} \mathbf{x} = \mathbf{f}(\mathbf{x}, s)$$

density に対する方程式は Liouville 方程式となる.

$$\partial p(\mathbf{x}, s) = -\nabla_{\mathbf{x}} \cdot (p \mathbf{f}), \quad p(\mathbf{x}, 0) = p(\mathbf{x}), \quad p(\mathbf{x}, s_{final}) = p(\mathbf{x}|y).$$

2 種類の PFF が考えられる. 一つ目は tempering のステップを細かくした極限 $\gamma_k = 1/K = \Delta s \rightarrow 0$ を考えること.

もう一つは Langevin Dynamics(LD) から始めるものである. posterior $p^*(\mathbf{x}) = p(\mathbf{x}|y)$ を不変測度にもつ LD を考え, 対応する Fokker-Planck 方程式を導く. それは KL-divergence d_{KL} を用いて

$$\frac{dp_s}{ds} = -\nabla_p d_{KL}(p|p^*)|_{p=p_s}$$

と書ける. これを particle の方程式に戻す. ここで $p(\mathbf{x}|s)$ の評価が必要となってくる.

具体的な計算について, たとえば RKHS を導入することで $p(\mathbf{x}|s)$ の評価を近似できる. RKHS による d_{KL} の particle 近似の微分を用いて, 各 particle を動かす. 離散勾配法を用いた実装は [3].

3 LPF

[4] は Particle Filter における Localization を提案している．まず，通常の resampling は各 grid j における解析 m -th ensemble の参照元予報 ensemble 番号 $a(j, m)$ を用いて，以下のように各 ensemble を置き換える

$$X_{PF}^a[j, m] = X^b[j, a(j, m)]$$

ただし，通常の PF では $a(j, m)$ は $j \in 1, \dots, N$ に対して一様．

LPF では通常の PF に対して，各 grid j の近くの grid $n \in N_j$ から決まる ensemble $X^b[j, a(n, m)]$ の寄与も加える．

$$X_{LPF}^a[j, m] = \frac{1}{2} X_{PF}^a[j, m] + \frac{1}{2 \#N_j} \sum_{n \in N_j} X^b[j, a(n, m)]$$

1/2 に必要性はないように見える．

[5] は LPF を Gaussian Mixture に拡張したと言っている．まず，事前 PDF を Gaussian Mixture と考える．

$$p^b(x) \approx \sum_{i=1}^M w^{b(i)} \mathcal{N}(x^{b(i)}, \gamma P^b)$$

ここで， P^b は ensemble ベースの誤差共分散であり，各 **Gaussian kernel はそれに基づいて一様に取られている**．解析ステップでは (1) 各 ensemble を KF で mean-update する．この時，誤差共分散は LETKF のように ensemble ベースで計算する．(2) 次に，LPF に従って transform する．計算過程は LETKF と LPF を順番に行うようなものであり，それらを足したコストがかかる．

4 OTPF

[6] は事前分布と観測分布の補完を Wasserstein 距離を用いて定義した．事前分布と観測分布を Dirac 測度で表している．OT 的最適化時にはエントロピー正則化を行なっている．同化後も分布のサポート点数を保つため multinomial sampling scheme を使っているらしい．

Remark 4.1. 観測が分布として得られている必要がある．誤差解析をできていない．補完比率や正則化パラメータに対する解析がない．

5 Linear Ensemble Transform Filter

SIR, EnKF, ETPF

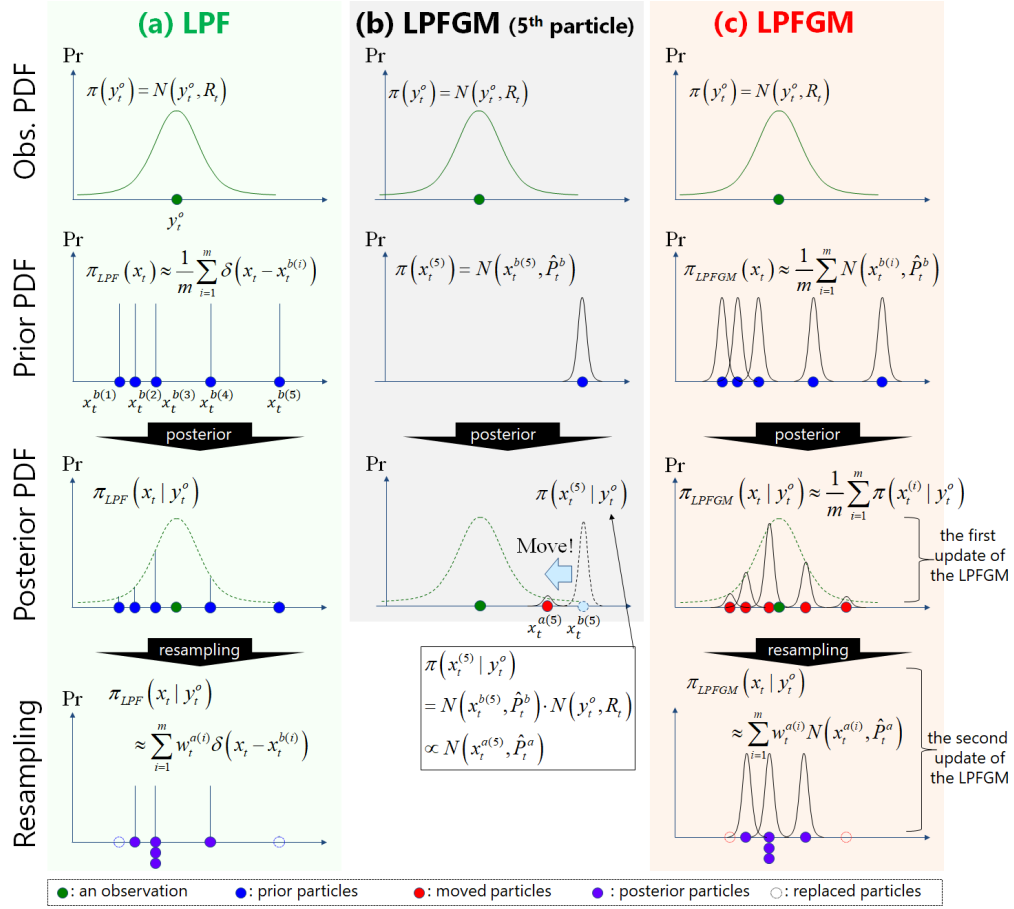


図1 [5] の Fig.2

参考文献

- [1] Peter Jan van Leeuwen, Hans R. Künsch, Lars Nerger, Roland Potthast, and Sebastian Reich. Particle filters for high-dimensional geoscience applications: A review. *Quarterly Journal of the Royal Meteorological Society*, 145(723):2335–2365, 2019.
- [2] Sebastian Reich. A nonparametric ensemble transform method for bayesian inference. *SIAM JOURNAL ON SCIENTIFIC COMPUTING*, 35(4):A2013–A2024, 2013.
- [3] Sahani Pathiraja and Sebastian Reich. Discrete gradients for computational bayesian inference. *Journal of Computational Dynamics*, 6,number = 2,pages = 385-400, 2019.
- [4] Stephen G. Penny and Takemasa Miyoshi. A local particle filter for high-dimensional geophysical systems. *NONLINEAR PROCESSES IN GEOPHYSICS*, 23(5):391–405, NOV 4 2016.

- [5] S. Kotsuki, T. Miyoshi, K. Kondo, and R. Potthast. A local particle filter and its gaussian mixture extension implemented with minor modifications to the letkf. *Geoscientific Model Development*, 15(22):8325–8348, 2022.
- [6] Sagar K. Tamang, Ardeshir Ebtehaj, Peter J. van Leeuwen, Dongmian Zou, and Gilad Lerman. Ensemble riemannian data assimilation over the wasserstein space. *NONLINEAR PROCESSES IN GEOPHYSICS*, 28(3):295–309, JUL 6 2021.
- [7] Chih-Chi Hu and Peter Jan van Leeuwen. A particle flow filter for high-dimensional system applications. *QUARTERLY JOURNAL OF THE ROYAL METEOROLOGICAL SOCIETY*, 147(737):2352–2374, APR 2021.
- [8] S. Reich and C. Cotter. *Probabilistic Forecasting and Bayesian Data Assimilation*. Cambridge University Press, 2015.