



# データ同化モデルにおける観測ノイズ分散共分散行列のベイズ推定法

1. 状態空間モデル
2. 観測ノイズ分散共分散行列の推定



上野玄太 (統計数理研究所)

# 準備：状態空間モデル

- シミュレーションモデルでは思うように現象が再現・予測できない。そのため、シミュレーションモデルの大規模化・精緻化・階層化などを進める [いわゆる「演繹一本槍」]
- シミュレーションモデルと観測データの間にも自由度を持った関係を構築する。
- 以上の2つをそれぞれシステムモデル、観測モデルと呼び、それらを合わせて状態空間モデルという。データ同化の基本となるモデルである。

# シミュレーション (1/2)

$x$  の時間発展を与える微分方程式

$$\frac{dx}{dt} = g(x, t)$$


$$\frac{\partial u}{\partial t} + (u \cdot \nabla)u = -\frac{1}{\rho} \nabla p + \nu \nabla^2 u + f$$

$$\frac{\partial f}{\partial t} + v \cdot \frac{\partial f}{\partial x} + \frac{F}{m} \frac{\partial f}{\partial v} = \left( \frac{\delta f}{\delta t} \right)_{coll}$$



離散化

$$\frac{x_t - x_{t-1}}{\Delta t} = g(x_{t-1}, t)$$



移項

$$\begin{aligned} x_t &= x_{t-1} + g(x_{t-1}, t) \Delta t \\ &=: f_t(x_{t-1}) \end{aligned}$$

# シミュレーション (2/2)

## シミュレーションモデル

$$x_t = f_t(x_{t-1}), \quad t = 1, 2, \dots, T$$

- $x$ : シミュレーション変数をまとめたベクトル量で、状態もしくは状態ベクトルと呼ぶ。
- $x_0$ : 初期状態もしくは初期条件と呼ぶ。シミュレーションの計算の前にあらかじめ与える

上の設定から当たり前のことではあるが、初期状態  $x_0$  を与えると、その後の状態の列  $(x_1, x_2, \dots, x_T)$  が一意に決まる。

# 時間発展の不確定性、システムノイズ

$$x_t = f_t(x_{t-1}) \rightarrow x_t \approx f_t(x_{t-1}), \quad t = 1, 2, \dots, T$$

近似等号を表現するために、付加項  $v_t$  を含めて等号で結ぶ：

$$\rightarrow x_t = f_t(x_{t-1}) + v_t, \quad t = 1, 2, \dots, T$$

付加項  $v_t$  の確率分布を仮定する：

$$v_t \sim p(v_t), \quad t = 1, 2, \dots, T$$

$v_t$  をシステムノイズと呼ぶ。

# システムモデル


## シミュレーションモデル

$$x_0 = x_0^{(1)}$$

$$x_t = f_t(x_{t-1}), \quad t = 1, 2, \dots, T$$

初期条件はこうだ！

時間発展はこうだ！



初期条件はこのあたりか？

時間発展はこんなものか？

## システムモデル

$$x_0 \sim p\left(x_0; x_0^{(1)}, V_0\right)$$

$$x_t = f_t(x_{t-1}) + v_t, \quad t = 1, 2, \dots, T$$

$$v_t \sim p\left(v_t; Q_t\right), \quad t = 1, 2, \dots, T$$

初期状態の確率分布

システムノイズの確率分布

# モデルとデータのつき合わせ

状態

$x_t, t=1,2,\dots,T$   
 $k$ 次元ベクトルの列



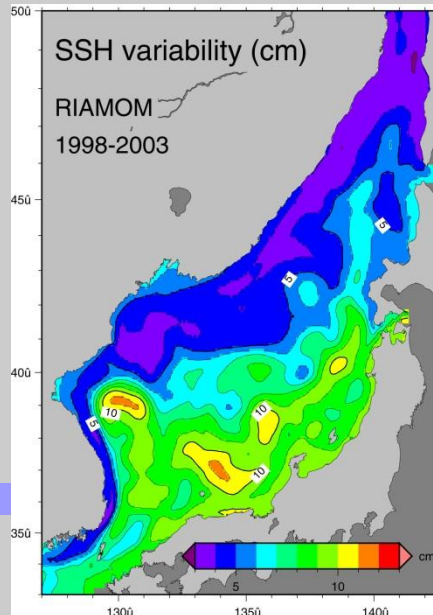
つき合わせたい

観測データ

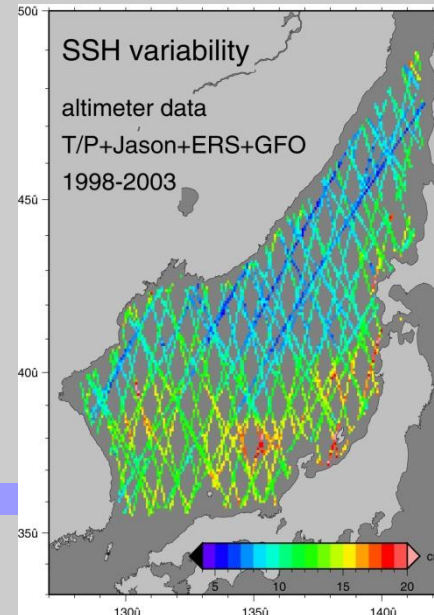
$y_t, t=1,2,\dots,T$   
 $l$ 次元ベクトルの列

状態は多くの変数を要素に持つベクトルであるが、実際に観測されるのは一部の変数である ( $l < k$ )。

$x_t$



$y_t$



広瀬・万田  
(2006)

# 観測モデル、観測ノイズ

考え方：得られた状態は観測に近い

$$y_t \approx h_t(x_t), \quad t=1,2,\dots,T$$

近似等号を表現するために、付加項  $w_t$  を含めて等号で結ぶ：

$$\rightarrow y_t = h_t(x_t) + w_t, \quad t=1,2,\dots,T$$

付加項  $w_t$  の確率分布を仮定する：

$$w_t \sim p(w_t; R_t), \quad t=1,2,\dots,T$$

観測モデル

$w_t$  を観測ノイズと呼ぶ。



# 観測ノイズ

- 観測ノイズ  $w_t$  の定義は、観測とモデルの差  $y_t - h_t(x_t)$
- 観測機器の特性に起因する、いわゆる「測定誤差」は、観測ノイズに寄与する要素の一部と考えるべき  
[観測ノイズ、という言葉から類推しないでください]
- 極端な例として、観測ノイズと「測定誤差」が一致する場合を考えると、モデルが観測機器をとりまく自然現象を完璧に再現できる場合に対応
- 通常はモデルにはそこまでの能力はないため、モデルが再現し切れない部分も差としてカウントされる

# 状態空間モデル

システムモデル、観測モデルからなるモデルを状態空間モデルと呼ぶ。

## システムモデル

$$x_0 \sim p\left(x_0; x_0^{(1)}, V_0\right)$$

$$x_t = f_t(x_{t-1}) + v_t, \quad t = 1, 2, \dots, T$$

$$v_t \sim p\left(v_t; Q_t\right), \quad t = 1, 2, \dots, T$$

## 観測モデル

$$y_t = h_t(x_t) + w_t, \quad t = 1, 2, \dots, T$$

$$w_t \sim p\left(w_t; R_t\right), \quad t = 1, 2, \dots, T$$

(狭い意味で) データ同化では、初期状態の確率分布、システムノイズの確率分布、観測ノイズの確率分布を与えたときに、観測データに基づいて、状態の確率分布を求める。

# データ同化における状態空間モデル

- データ同化 = 状態変数  $x_t$  を推定する問題

$$\begin{array}{l} x_t \approx f_t(x_{t-1}) \\ y_t \approx h_t(x_t) \end{array} \Leftrightarrow \begin{array}{l} x_t = f_t(x_{t-1}) + v_t \\ y_t = h_t(x_t) + w_t \end{array} \begin{array}{l} \text{(システムモデル)} \\ \text{(観測モデル)} \end{array}$$

- $x_t$ : タイムステップ  $t$  でのシミュレーションの全変数をまとめたベクトル ( $x_0$ : 初期条件)
- $y_t$ : タイムステップ  $t$  での観測される全変数
- $v_t$ : システムノイズ. シミュレーションの不確定部分を表現する確率変数 (不確定部分: 境界条件、パラメータ、...)
- $w_t$ : 観測ノイズ

変数の次元	$x_t: 10^4 \sim 10^6$	$y_t: 10^2 \sim 10^5$	$\dim(x_t) \gg \dim(y_t)$
-------	-----------------------	-----------------------	---------------------------

# データ同化における共分散行列

状態空間モデル

$$x_t = f_t(x_{t-1}, v_t)$$

システムモデル

$$y_t = h_t(x_t) + w_t$$

観測モデル

共分散行列

システム  
ノイズ

$$v_t \sim N(0, Q_t)$$

観測  
ノイズ

$$w_t \sim N(0, R_t)$$

初期値

$$x_0 \sim N(x_{0|0}, V_{0|0})$$

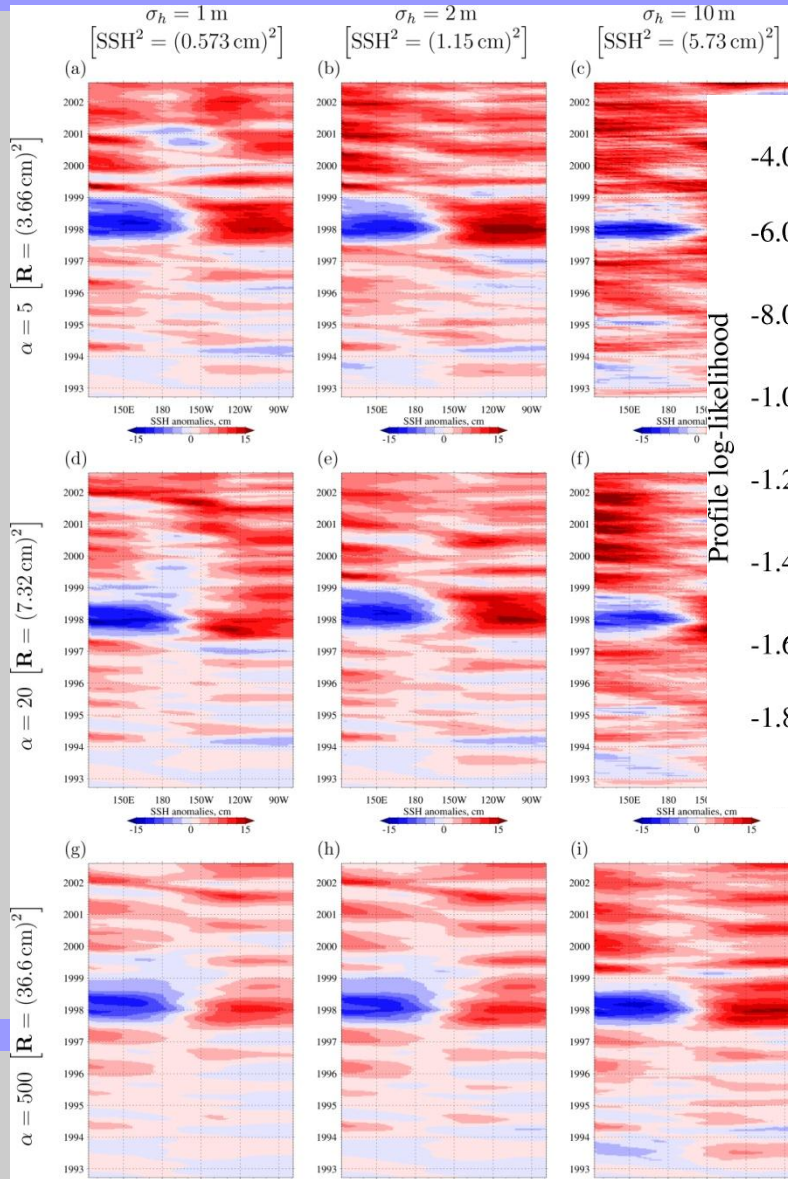
$Q_t$  小  $\rightarrow$  モデルよりの状態推定値  
 $R_t$  小  $\rightarrow$  データよりの状態推定値  
 $V_{0|0}$  小  $\rightarrow x_{0|0}$  よりの初期値

•  $\theta = (V_{0|0}, Q_{1:T}, R_{1:T})$  の最尤推定


# データ同化結果

Q大  
( $\sigma_h$ 大)

R大  
( $\alpha$ 大)




Observation noise magnitude



どれがいいのか？

# 尤度とは

与えられた観測値  $y_{\text{obs}}$  が得られるような、一番もっともらしい確率分布はどれか？



もっともらしさ = 尤度  $L(\tau) = p(y_{\text{obs}}|\theta)$

上の例では  $\theta_3$  が一番もっともらしい。

# 時系列の尤度

$$\begin{aligned}L(\theta) &= p(y_1, y_2, \dots, y_T | \theta) \\ &= p(y_1 | \theta) \cdot p(y_2 | y_1, \theta) \cdot p(y_3 | y_1, y_2, \theta) \cdots p(y_T | y_1, y_2, \dots, y_{T-1}, \theta) \\ &= \prod_{t=1}^T p(y_t | y_{1:t-1}, \theta)\end{aligned}$$

この量を最大とするような $\theta$ を求める。

実際上は、対数を最大とするようにすると扱いやすい。

$$\begin{aligned}\ell(\theta) &\equiv \log p(y_{1:T} | \theta) \\ &= \sum_{t=1}^T \log p(y_t | y_{1:t-1}, \theta)\end{aligned}$$

# 時系列の尤度

$$\begin{aligned}\ell(\theta) &= \sum_{t=1}^T \log p(y_t | y_{1:t-1}, \theta) \\ &= \sum_{t=1}^T \log \int_{-\infty}^{\infty} p(y_t | x_t, \theta) p(x_t | y_{1:t-1}, \theta) dx_t\end{aligned}$$

尤度

予測分布

観測モデルから決まる

$$\begin{aligned}y_t &= H_t x_t + w_t \\ w_t &\sim N(0, R_t)\end{aligned} \Rightarrow N(H_t x_t, R_t)$$


一般にガウス分布ではない  
[力学モデルが非線型なので]

でもガウス  
だと思おうと  $N(x_t^f, P_t^f)$




# 分布のアンサンブル近似

ガウス分布




厳密に  
表現可能



$$N(x_t | j, V_t | j)$$

カルマンフィルタ (KF)

非ガウス分布



アンサンブル  
近似/粒子近似




アンサンブルカルマンフィルタ (EnKF),  
粒子フィルタ (PF)

# シミュレーションの抽象的表現

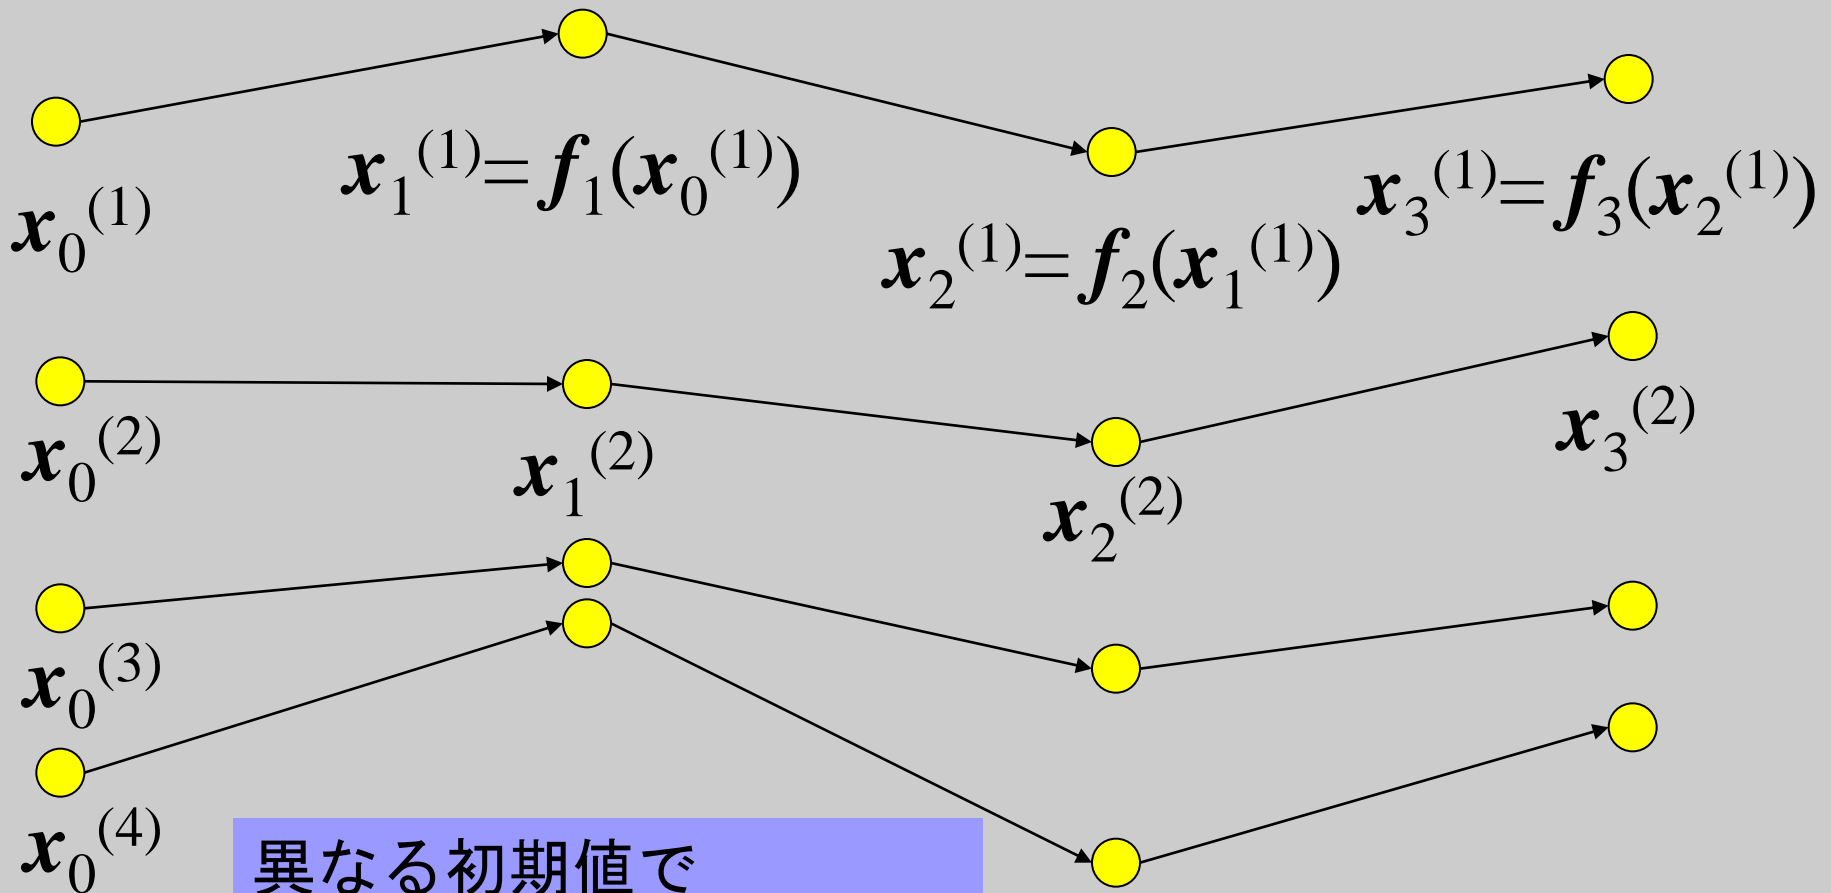
$x$  : 状態 ある時点での全格子点上の  
全物理量をまとめて表すベクトル

$x_t = f(x_{t-1})$  シミュレーションによる状態の時間発展

初期値



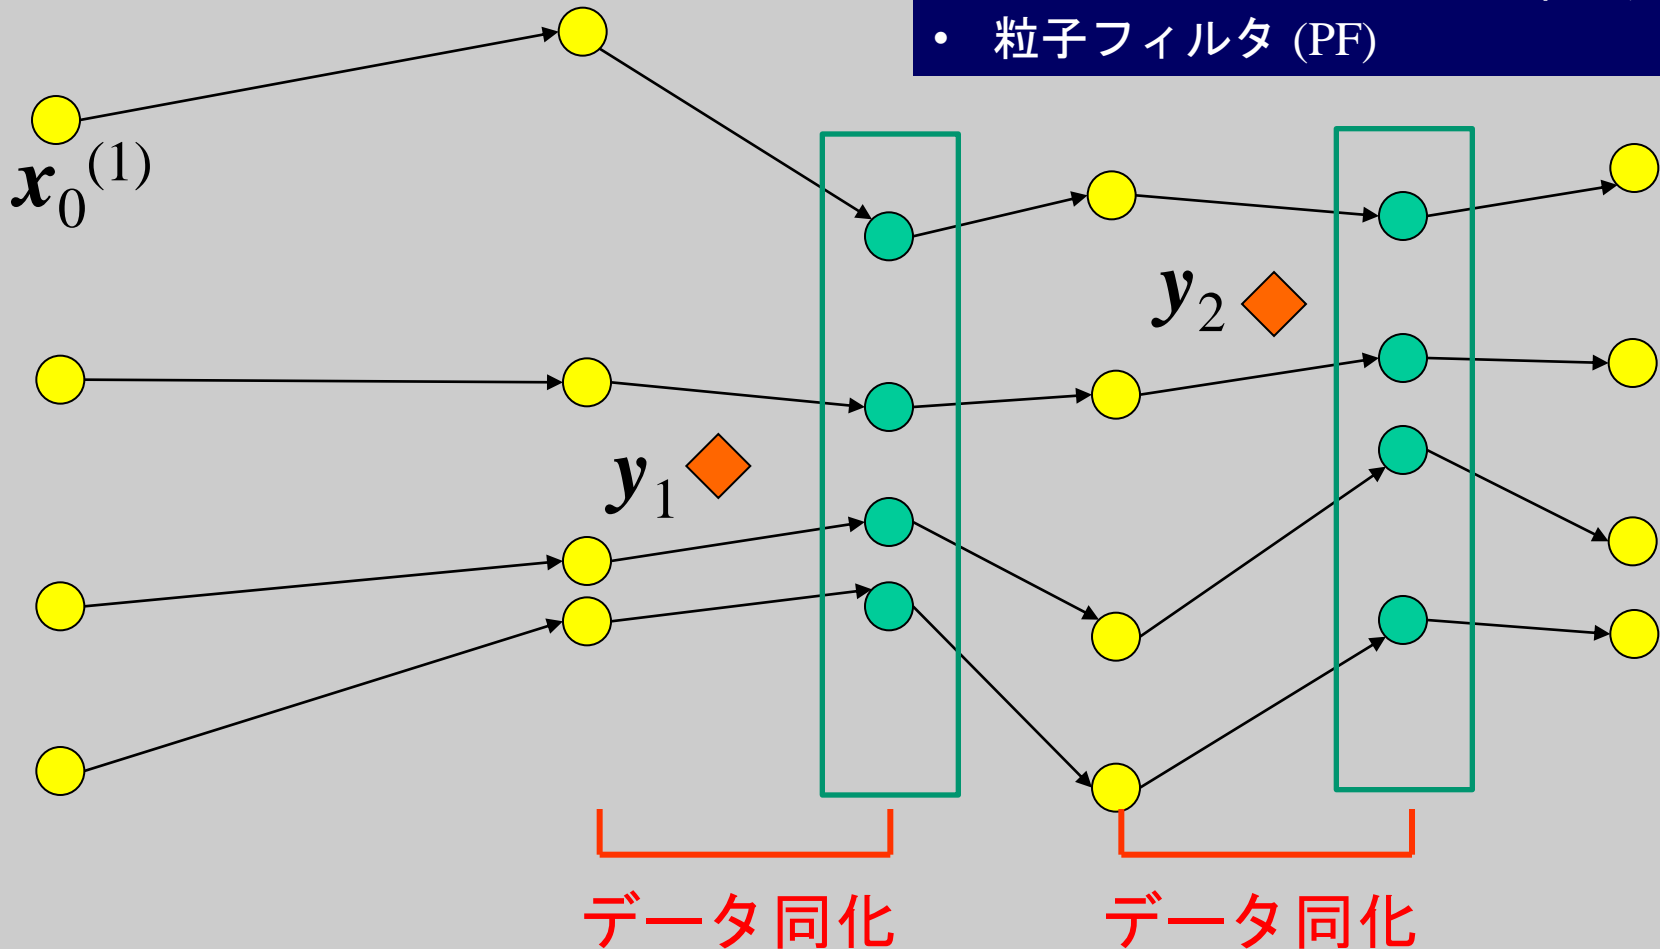
# アンサンブル予測



異なる初期値で  
シミュレーションを実施

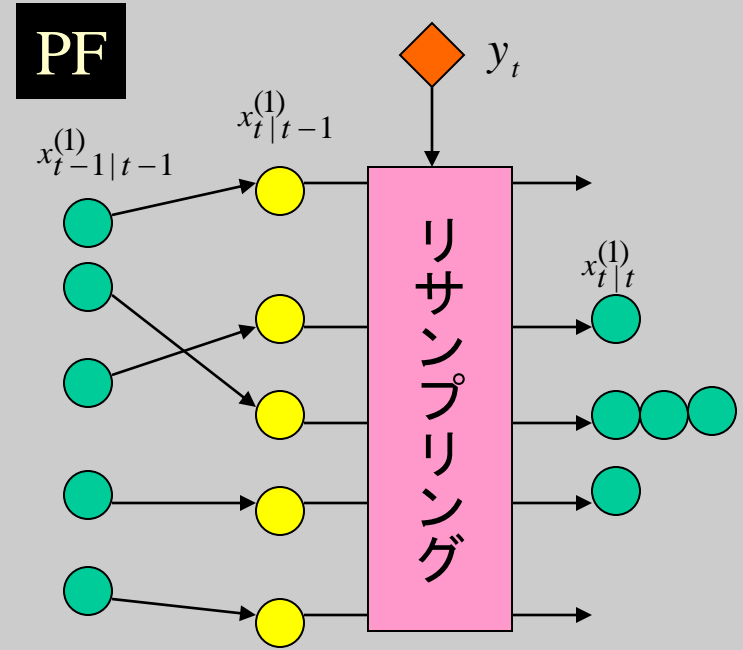
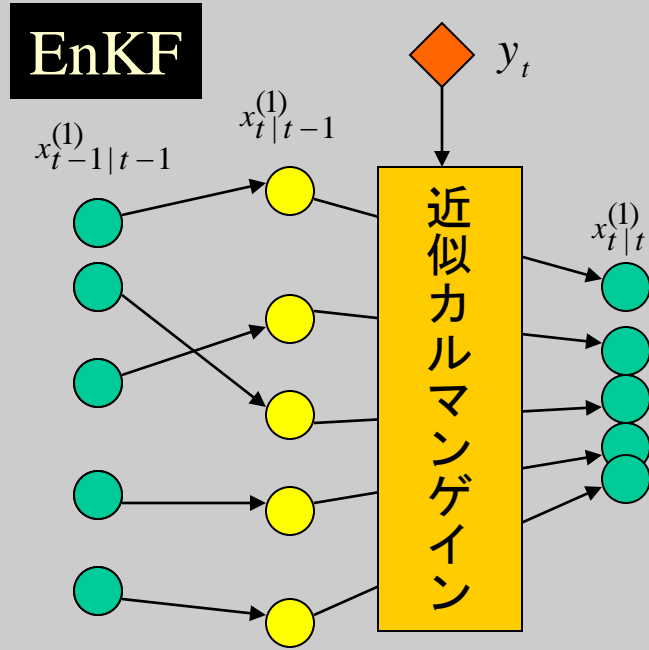
# アンサンブル型データ同化

- アンサンブルカルマンフィルタ (EnKF),
- 粒子フィルタ (PF)



データに応じて、アンサンブルを改変


# EnKF と PF



$$K_t = \bar{V}_{t|t-1} H_t \left( H_t \bar{V}_{t|t-1} H_t' + \bar{R}_{t|t-1} \right)^{-1}$$

$$x_{t|t}^{(n)} = x_{t|t-1}^{(n)} + \bar{K}_t \left( y_t + w_t^{(n)} - H_t x_{t|t-1}^{(n)} \right)$$

$$p\left(y_t | x_{t|t-1}^{(n)}\right)$$



# 問題意識

- 状態推定の結果は、あらかじめ設定した  $\theta$  によって、いかようにもできる (正則化パラメータと同様)
- $\theta = (V_{0|0}, Q_{1:T}, R_{1:T})$ 
  - $V_{0|0}$ : 初期状態の分散共分散行列 (Bと書くことあり)
  - $Q_t$ : システムノイズの分散共分散行列
  - $R_t$ : 観測ノイズの分散共分散行列
- なるべくデータの情報を取り込む設定に興味がある
- グリッドサーチ (総当たり)、リサンプリング
  - ✓ 計算が大変
  - ✓ 探索範囲にどうしても限界がある (候補を自分で用意するため)

# 尤度のアンサンブル近似

尤度は各アンサンブルメンバー  $x_{t|t-1}^{(n)}$  の尤度の平均で近似できる

$\ell(\theta)$

$$\equiv \log p(y_{1:T} | \theta)$$

$$\square \sum_{t=1}^T \left\{ -\frac{\dim y_t}{2} \log 2\pi - \frac{1}{2} \log |R_t| \right.$$

$$\left. + \log \sum_{n=1}^N \exp \left[ -\frac{1}{2} \left( y_t - h_t \left( x_{t|t-1}^{(n)} \right) \right)' R_t^{-1} \left( y_t - h_t \left( x_{t|t-1}^{(n)} \right) \right) \right] - \log N \right\}$$

$$y_t = h_t(x_t) + w_t$$
$$w_t \sim N(0, R_t)$$

- この量 (対数尤度) を最大化する  $\theta$  を求める。

# 観測誤差共分散行列の尤度

今回  $\theta = (B, Q_{1:T}, R_{1:T})$  のうち、 $R_{1:T}$  のみに着目

$$R_{1:T} \equiv \{R_1, R_2, \dots, R_T\}$$

対数尤度

$$\ell(R_1, R_2, \dots, R_T) = \sum_{t=1}^T \ell_t(R_{1:t})$$

但し  $\ell_t(R_{1:t}) = -\frac{\dim y_t}{2} \log 2\pi - \frac{1}{2} \log |R_t|$

$+ \log \sum_{n=1}^N \exp \left[ -\frac{1}{2} \left( y_t - h_t \left( x_{t|t-1}^{(n)} \right) \right)' R_t^{-1} \left( y_t - h_t \left( x_{t|t-1}^{(n)} \right) \right) \right]$

$-\log N$



# 推定の方針

$$\begin{aligned}
 \ell_t(R_{1:t}) &= -\frac{\dim y_t}{2} \log 2\pi - \frac{1}{2} \log |R_t| \\
 &+ \log \sum_{n=1}^N \exp \left[ -\frac{1}{2} \left( y_t - h_t \left( x_{t|t-1}^{(n)} \right) \right)' R_t^{-1} \left( y_t - h_t \left( x_{t|t-1}^{(n)} \right) \right) \right] \\
 &- \log N
 \end{aligned}$$

- $\ell_t(R_{1:t})$  は  $R_t$  の推定のためだけに用いる
- 本来は  $R_{1:t-1}$  もパラメータだが、これらは過去の対数尤度  $\ell_1(R_1), \dots, \ell_{t-1}(R_{1:t-1})$  で推定され、現時点では固定とする
- 各時点  $t$  で、 $R_t$  が推定される
- 各時点で  $y_t$  に応じて  $R_t$  を推定するので、ばたばたするかも
- 時点に依存しない一定の  $R$  を推定することはできない

• これで最尤推定ができる。のだが、

# 観測誤差共分散行列のベイズ推定

- 動機その 1 :

最尤推定では、 $R_t$  がスカラー一倍か対角の場合でしかうまくいかない。本当は非対角（理想は全成分） $R_t$  の推定がしたい。

- 動機その 2 :

$R_t$  が激しく時間変化するというのはいかなるものか

- $R_t$  に事前分布を与えたベイズ推定へ

# ベイズ推定

尤度 (今まで)

$$p\left(y_t \mid R_t, y_{1:t-1}\right) \propto \sum_{n=1}^N \frac{1}{N} \phi\left(y_t; h_t\left(x_{t|t-1}^{(n)}\right), R_t\right)$$

事後分布

$$\begin{aligned} p\left(R_t \mid y_{1:t}\right) &\propto p\left(y_t \mid R_t, y_{1:t-1}\right) p\left(R_t \mid y_{1:t-1}\right) \\ &\propto \sum_{n=1}^N \frac{1}{N} \phi\left(y_t; h_t\left(x_{t|t-1}^{(n)}\right), R_t\right) p\left(R_t \mid y_{1:t-1}\right) \end{aligned}$$

尤度

事前分布

# EMアルゴリズム

- 対数事後分布の最適性条件

$$\frac{\partial \log p\left(R_t \mid y_{1:t}, S, \nu\right)}{\partial R_t} = 0 \Rightarrow$$

E ステップ

$$z_n^{(k)} = \frac{\phi\left(y_t; h_t\left(x_{t|t-1}^{(n)}\right), R_t^{(k)}\right)}{\sum_{n=1}^N \phi\left(y_t; h_t\left(x_{t|t-1}^{(n)}\right), R_t^{(k)}\right)}$$

M ステップ

$$R_t^{(k+1)} = (1-\lambda) \sum_{n=1}^N z_n^{(k)} \left( y_t - h_t\left(x_{t|t-1}^{(n)}\right) \right) \left( y_t - h_t\left(x_{t|t-1}^{(n)}\right) \right)' + \lambda S$$

where


$$\lambda = \frac{\nu - m - 1}{\nu - m}$$

標本共分散と事前共分散の線型和



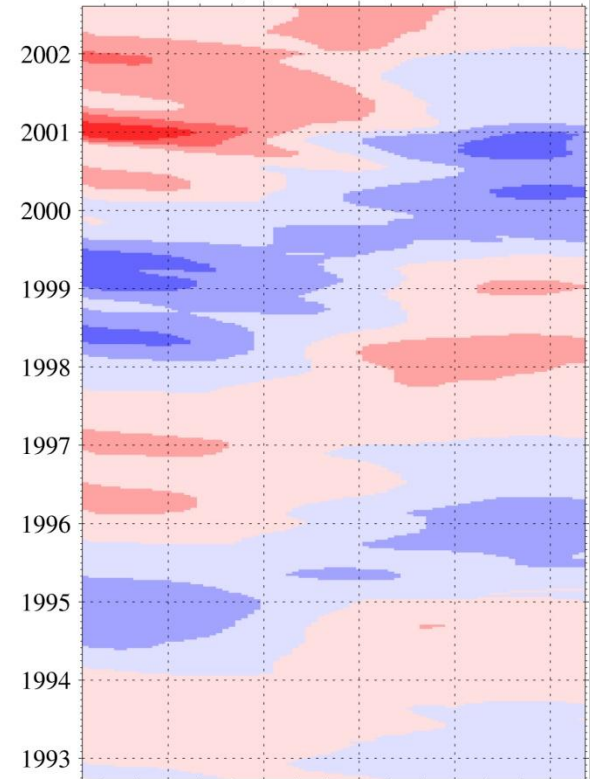
# データとシミュレーション

年

(a) TOPEX / POSEIDON



(b) ZC model



経度

$$\dim y_t = 503$$

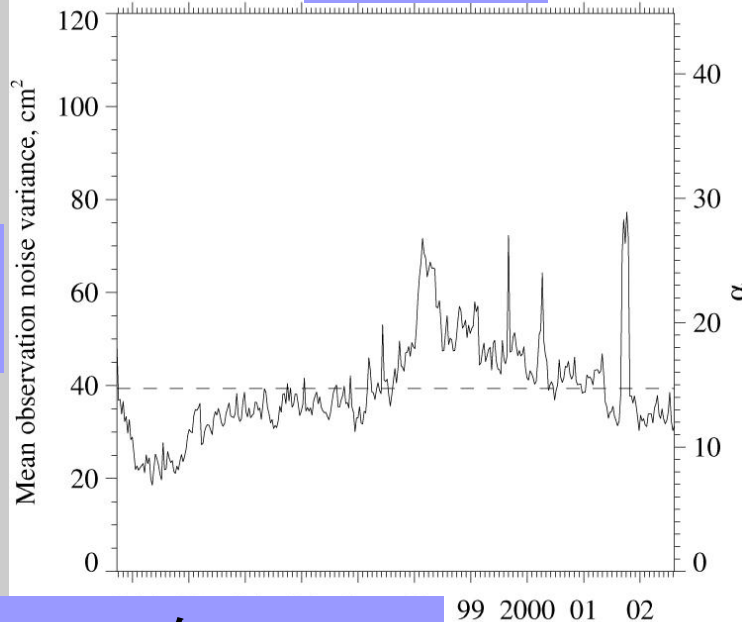
$R_t : 503 \times 503$  行列

色は海面高度の変動を示している

# 最尤推定値 [いかななものか]


分散

$$(a) R_t = \alpha_t \Sigma$$



1992- 年 -2002

$$R_t = \text{diag}(r_1, \dots, r_m)$$




- いずれも、1998年あたりで大
- 平均値はいずれも40cm<sup>2</sup>
- $\alpha_t \Sigma$ は振幅小、diag  $r_t$ は振幅大

# ベイズ推定値 (事前重み 0.95)


分散

$$R_t = \alpha_t \Sigma, S = \hat{\alpha}_{t-1} \Sigma$$



1992- 年 -2002

$$(b) R_t = \text{diag } r_t, S = \text{diag } \hat{r}_{t-1}$$




- ばたばた感は解消
- 事前情報に重み0.95


# ベイズ推定値 (事前重み推定)

分散

$$(a) \quad R_t = \alpha_t \Sigma, S = \hat{\alpha}_{t-1} \Sigma$$



$$(b) \quad R_t = \text{diag } r_t, S = \text{diag } \hat{r}_{t-1}$$



1992- 年 -2002


- ばたばた感は解消
- 事前情報に重み




# ベイズ推定値 (全要素推定)

分散



General  $R_t, S = \text{diag} \hat{R}_{t-1}$



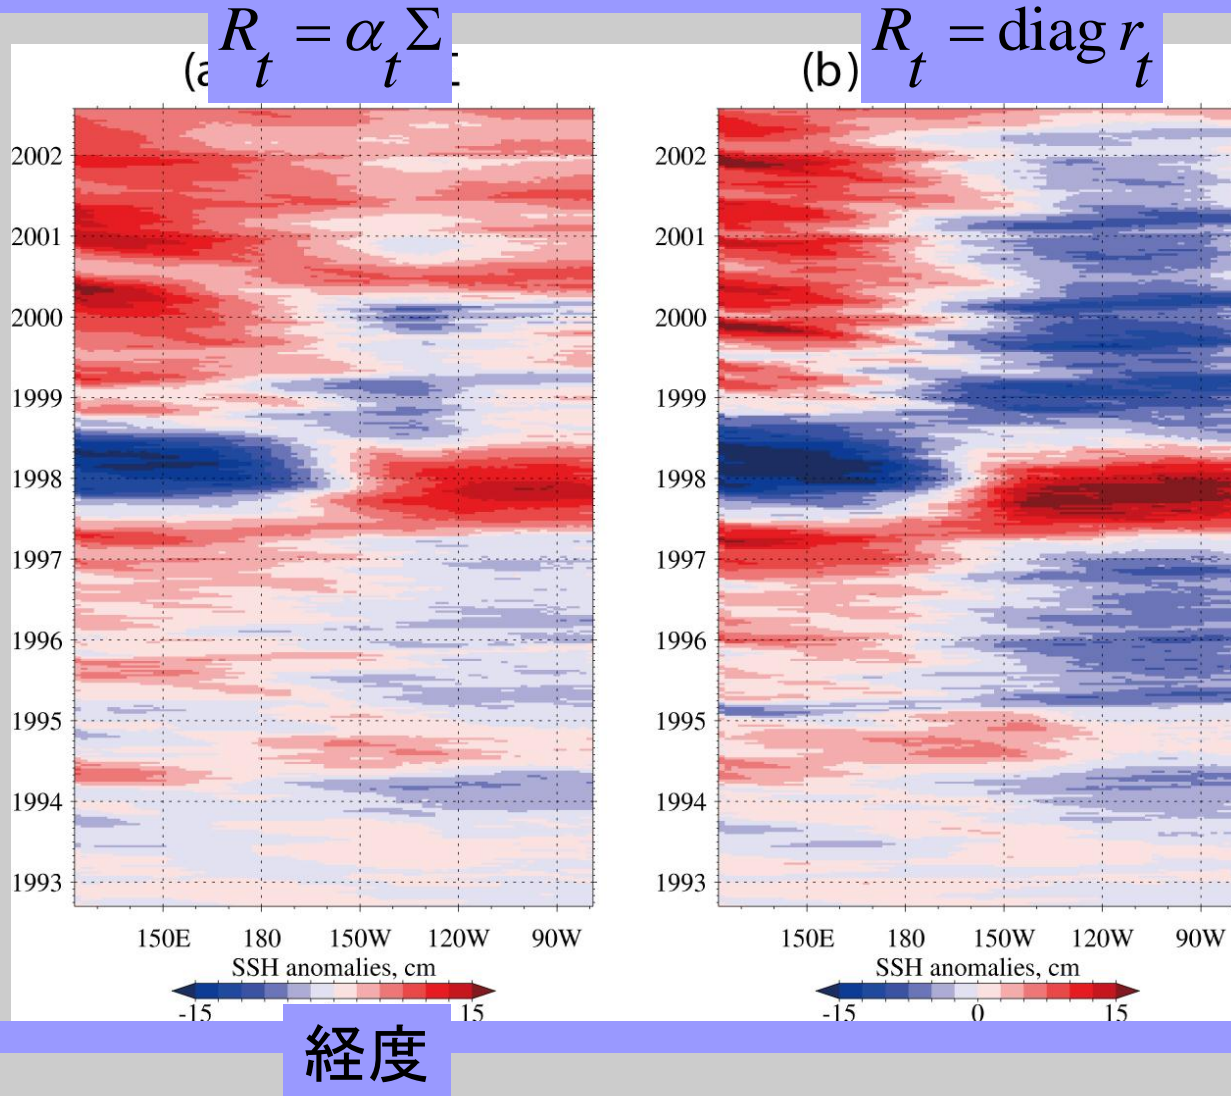
General  $R_t, S = 20\Sigma$



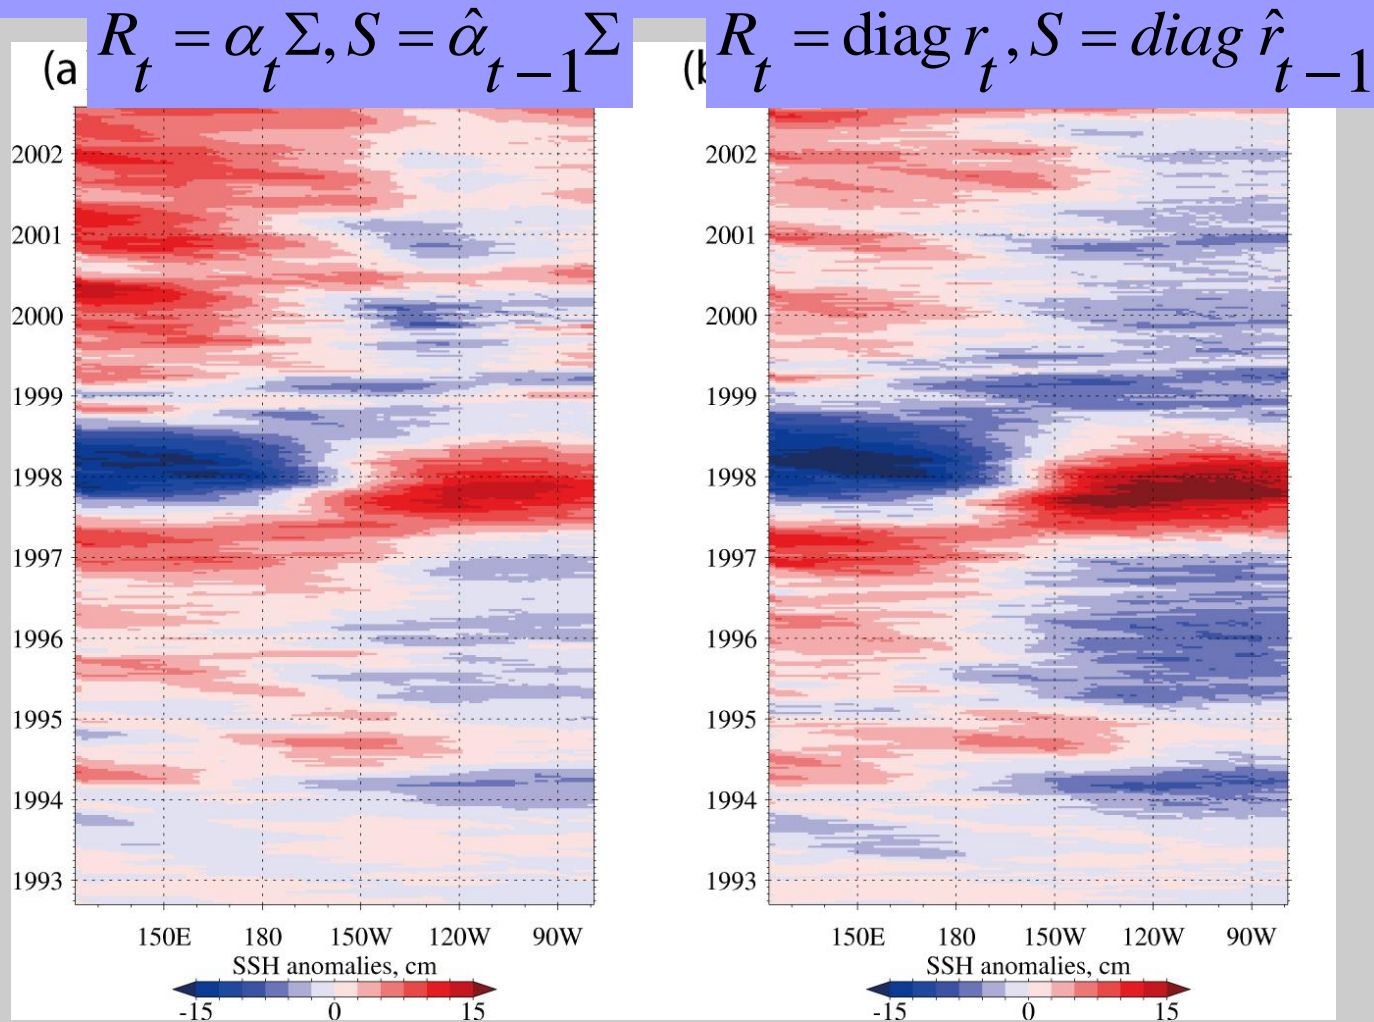
共分散



# 平滑化推定値 ( $R_t$ : 最尤推定)



# 平滑化推定値 (Rt: ベイズ推定)



- ばたばた感が解消した分、データへの追従も抑制気味

# まとめ

- 観測ノイズの共分散行列  $R_t$  のベイズ推定
- 全成分を推定することが可能
- 時間変化を滑らかにすることが可能
- EMアルゴリズムを構成 [最尤推定の場合と同様]
- 事前分布のパラメータは直前推定値、経験値、周辺尤度などから
- エルニーニョモデルを用いた数値実験
- 必要な反復回数は5,6回程度