

データ同化の基礎について

同志社大学理工学部

山根 省三

はじめに

データ同化 …… 観測と数値モデルを組み合わせて、
実際の状態を推定する方法。
数学的には統計的推定論の応用と
見なせる(淡路ほか、2009)。

気象の分野では、

- 数値天気予報の初期値作成
- 再解析データの作成


などに用いられる。

データ同化の手法:

最適内挿法、変分法(3次元、4次元)、カルマン・フィルタ

予側値 14°C 予測誤差の標準偏差 2°C
観測値 17°C 観測誤差の標準偏差 1°C


誤差は正規分布に従うものとする。



予側値 14°C 予測誤差の標準偏差 2°C
観測値 17°C 観測誤差の標準偏差 1°C



解析値 16.4°C 解析誤差の標準偏差 $\sqrt{0.8}$ °C



平均 μ 、標準偏差 σ の正規分布:

$$f(x) = \frac{1}{\sqrt{2\pi}\sigma} \exp\left(-\frac{(x-\mu)^2}{2\sigma^2}\right)$$

予側値 x_f 予測誤差の標準偏差 σ_f
観測値 x_o 観測誤差の標準偏差 σ_o とする。

予測と観測の確率密度分布の積が最大となる x が最適な推定値(解析値)となる。

$$\Rightarrow \frac{(x-x_f)^2}{2\sigma_f^2} + \frac{(x-x_o)^2}{2\sigma_o^2} \quad (\text{指数部分の逆符号のもの})$$

が最小となる x が最適な推定値(解析値)

変形すると、


$$\frac{(x-x_f)^2}{2\sigma_f^2} + \frac{(x-x_o)^2}{2\sigma_o^2} = \frac{\left(x - \frac{\sigma_o^2 x_f + \sigma_f^2 x_o}{\sigma_f^2 + \sigma_o^2}\right)^2}{2\left(\frac{\sigma_f^2 \sigma_o^2}{\sigma_f^2 + \sigma_o^2}\right)} + \frac{(x_f - x_o)^2}{\sigma_f^2 + \sigma_o^2}$$

なので、最適な推定値(解析値) x_a は、

$$x_a = \frac{\sigma_o^2 x_f + \sigma_f^2 x_o}{\sigma_f^2 + \sigma_o^2} = x_f + \frac{\sigma_f^2}{\sigma_f^2 + \sigma_o^2} (x_o - x_f)$$

また、その誤差の標準偏差 σ_a は、

$$\sigma_a^2 = \frac{\sigma_f^2 \sigma_o^2}{\sigma_f^2 + \sigma_o^2} \iff \sigma_a^{-2} = \sigma_f^{-2} + \sigma_o^{-2}$$



$$x_a = x_f + \frac{\sigma_f^2}{\sigma_f^2 + \sigma_o^2} (x_o - x_f)$$

解析値は分散の比で決まる。

$$\sigma_a^{-2} = \sigma_f^{-2} + \sigma_o^{-2}$$


解析値の誤差の分散の逆数は、予測と観測の誤差の分散の逆数の和で与えられる。

2次元の場合

誤差は正規分布に従うものとする


神戸の気温(°C)

2地点の気温の予測の誤差の間に正の相関がある。

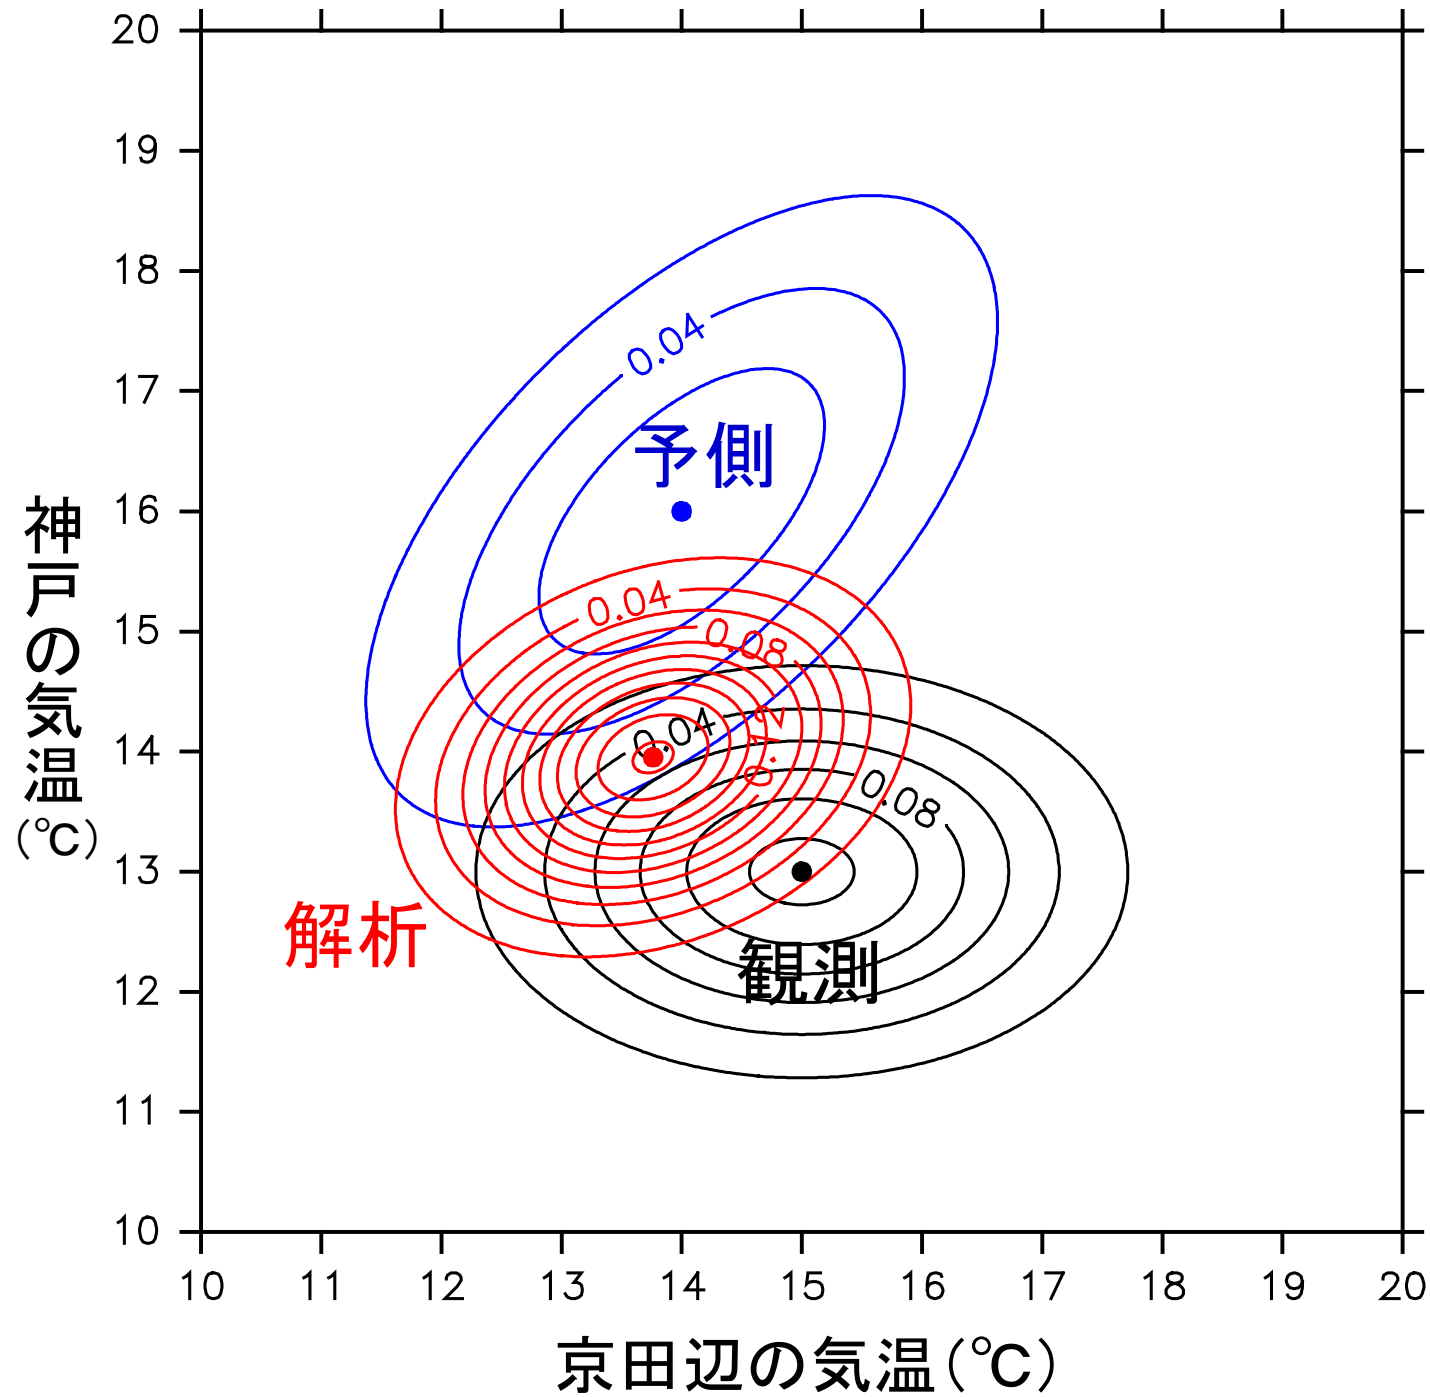


分布のイメージ
10000 サンプル

神戸の気温
(°C)




京田辺の気温(°C)



分布のイメージ
10000 サンプル

神戸の気温
(°C)



京田辺の気温(°C)

平均 $\boldsymbol{\mu}$ 共分散行列 \mathbf{S} の n 次元正規分布:

$$f(\mathbf{x}) = \frac{1}{(\sqrt{2\pi})^n \sqrt{|\mathbf{S}|}} e^{-\left(\frac{1}{2}(\mathbf{x}-\boldsymbol{\mu})^T \mathbf{S}^{-1}(\mathbf{x}-\boldsymbol{\mu})\right)}$$

予測値 \mathbf{x}_f 予測値の誤差共分散行列 \mathbf{P}_f
観測値 \mathbf{y} 観測値の誤差共分散行列 \mathbf{R}

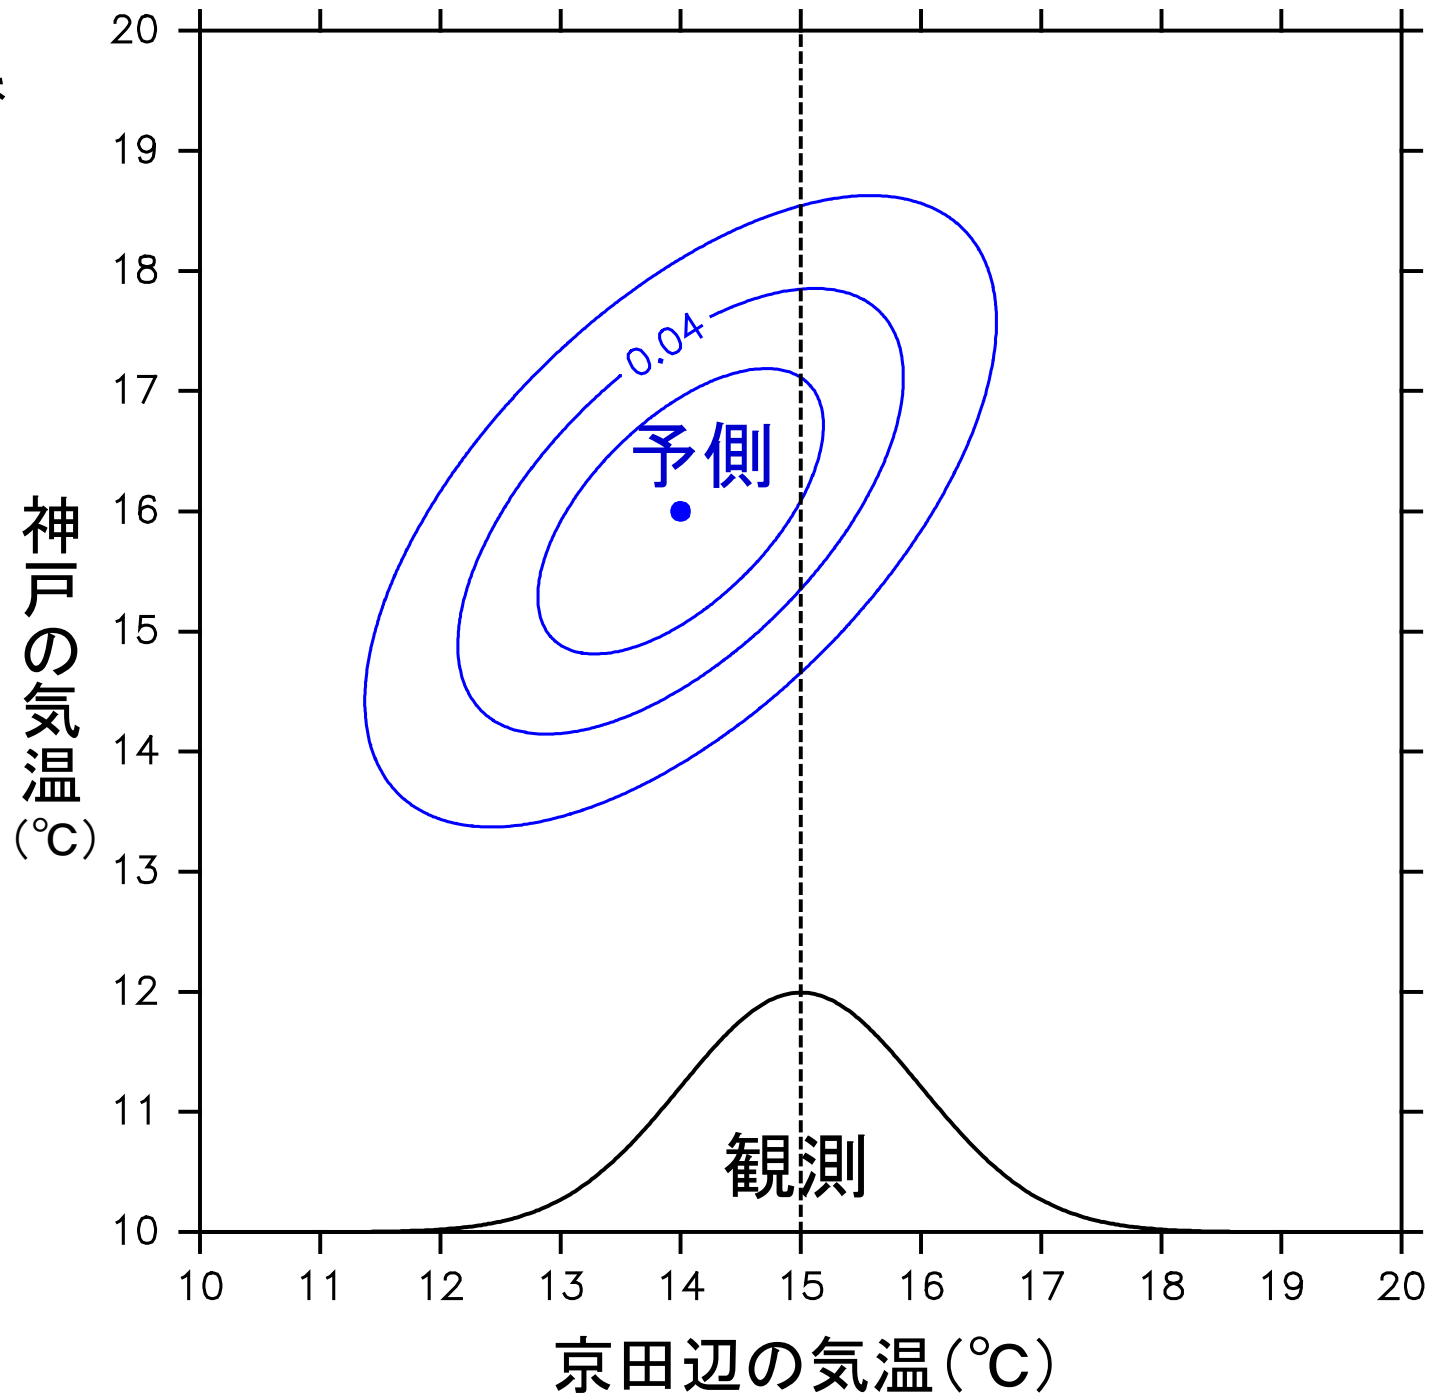



解析値 \mathbf{x}_a 解析値の誤差共分散行列 \mathbf{P}_a

$$\mathbf{x}_a = \mathbf{x}_f + \mathbf{P}_f (\mathbf{P}_f + \mathbf{R})^{-1} (\mathbf{y} - \mathbf{x}_f)$$

$$\mathbf{P}_a^{-1} = \mathbf{P}_f^{-1} + \mathbf{R}^{-1}$$

1地点だけで
気温を観測





1地点の観測で
2地点の気温が
修正される。

予測値や解析値を考えている世界と
観測値を考えている世界とが異なる場合は、
観測演算子 H でこの二つの世界をつなぐ。


$$H \quad \mathbf{x} \mapsto \mathbf{y}$$

解析値の次元が n で、観測の数が m 個の場合、
 H は $m \times n$ の行列。
(H は n 次元から m 次元への写像を表す。)

2地点のうち1地点で観測している場合の H は、

$$H = \begin{pmatrix} 1 & 0 \end{pmatrix}$$

である。



(淡路ほか 2009 より)

3地点のうちの中間の2地点で観測した場合の \mathbf{H} は、

$$\mathbf{H} = \begin{pmatrix} 0.5 & 0.5 & 0 \\ 0 & 0.5 & 0.5 \end{pmatrix}$$

となる。

$$\mathbf{H} \mathbf{x} = \begin{pmatrix} 0.5 & 0.5 & 0 \\ 0 & 0.5 & 0.5 \end{pmatrix} \begin{pmatrix} x_1 \\ x_2 \\ x_3 \end{pmatrix}$$

m 個の観測値の確率分布は、

$$\frac{1}{(\sqrt{2\pi})^m \sqrt{|\mathbf{R}|}} \exp\left(-\frac{1}{2}(\mathbf{H}\mathbf{x} - \mathbf{y})^T \mathbf{R}^{-1}(\mathbf{H}\mathbf{x} - \mathbf{y})\right)$$

と表せる。よって最小値問題は、

$$J(\mathbf{x}) = \frac{1}{2}(\mathbf{x} - \mathbf{x}_f)^T \mathbf{P}_f^{-1}(\mathbf{x} - \mathbf{x}_f) + \frac{1}{2}(\mathbf{H}\mathbf{x} - \mathbf{y})^T \mathbf{R}^{-1}(\mathbf{H}\mathbf{x} - \mathbf{y})$$

を最小とする \mathbf{x} について考えることになる。

予測値 \mathbf{x}_f 予測値の誤差共分散行列 \mathbf{P}_f
観測値 \mathbf{y} 観測値の誤差共分散行列 \mathbf{R}



解析値 \mathbf{x}_a 解析値の誤差共分散行列 \mathbf{P}_a


$$\mathbf{x}_a = \mathbf{x}_f + \mathbf{P}_f \mathbf{H}^T (\mathbf{H}_f \mathbf{H}^T + \mathbf{R})^{-1} (\mathbf{y} - \mathbf{H}_f \mathbf{x}_f)$$

$$\mathbf{P}_a^{-1} = \mathbf{P}_f^{-1} + \mathbf{H}^T \mathbf{R}^{-1} \mathbf{H}$$

数値予報の初期値作成の場合の データ同化のサイクル

解析値を初期値として
次の解析時刻まで予報する。

$$\mathbf{x}_f = M(\mathbf{x}_a)$$



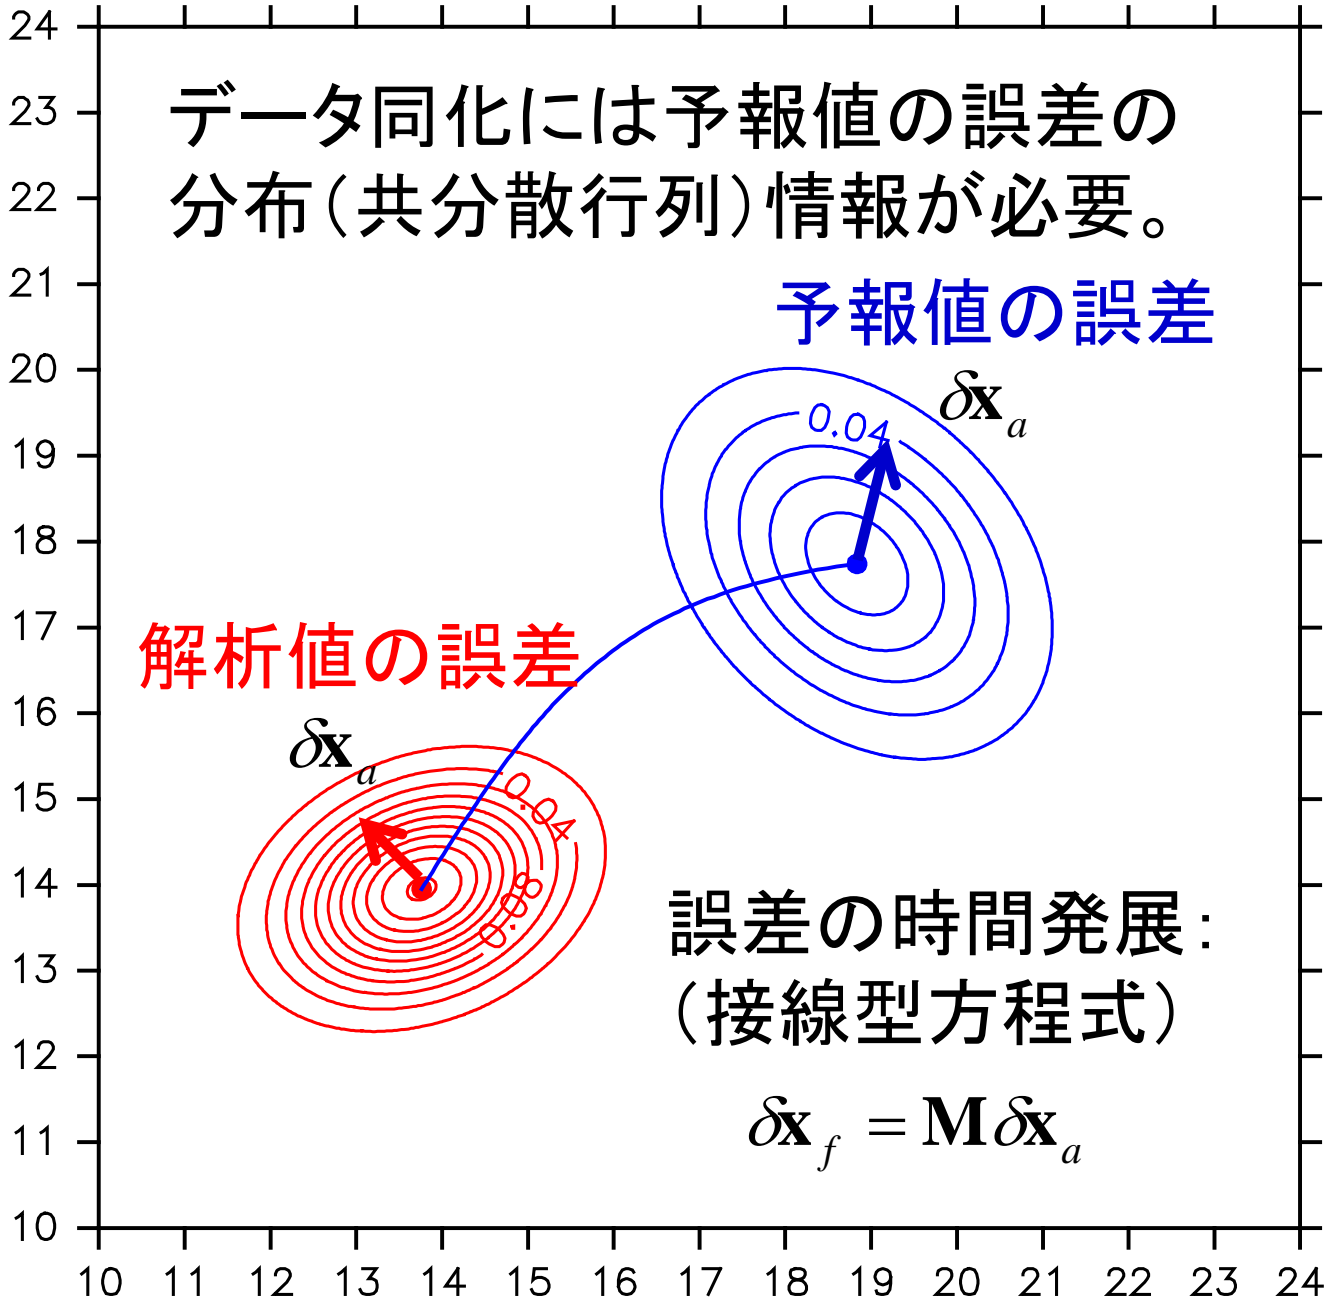
データ同化には予報値の誤差の分布(共分散行列)情報が必要。

予報値の誤差

解析値の誤差

誤差の時間発展:
(接線型方程式)

$$\delta \mathbf{x}_f = \mathbf{M} \delta \mathbf{x}_a$$



誤差の時間発展を線形と仮定すれば、

$$\delta \mathbf{x}_f = \mathbf{M} \delta \mathbf{x}_a \quad (\text{接線形方程式})$$

解析誤差共分散行列は、

$$\mathbf{P}_a = \langle \delta \mathbf{x}_a \delta \mathbf{x}_a^T \rangle \quad (\langle \quad \rangle \text{ は期待値を表す})$$

なので、次の時刻の予報誤差共分散行列は、

$$\mathbf{P}_f = \langle \delta \mathbf{x}_f \delta \mathbf{x}_f^T \rangle = \mathbf{M} \langle \delta \mathbf{x}_a \delta \mathbf{x}_a^T \rangle \mathbf{M}^T = \mathbf{M} \mathbf{P}_a \mathbf{M}^T$$

から求めることができる。

実際には誤差の発展は線形ではなく、
また、予報モデルは完全ではないので、
予報誤差共分散行列 \mathbf{P}_f は、

$$\mathbf{P}_f = \mathbf{M} \alpha \mathbf{M}^T \mathbf{P} + \mathbf{Q}$$

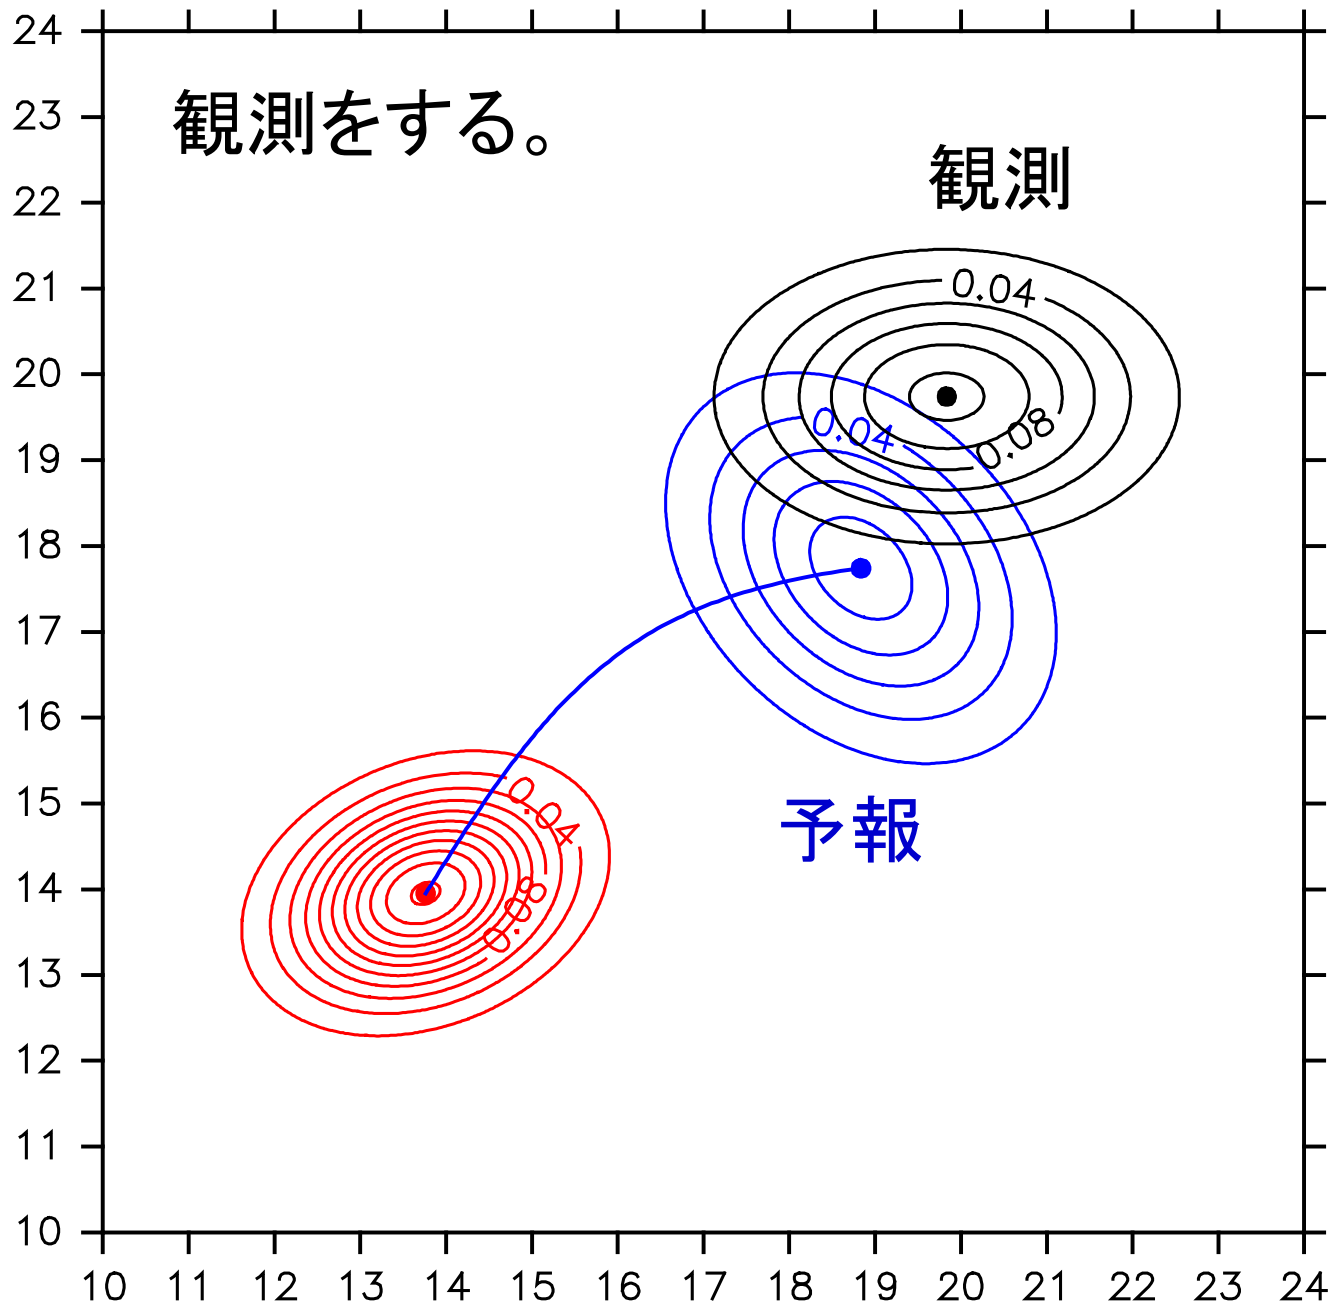
と記述される。 \mathbf{Q} はよく分からない量である。


上式の代わりに、


$$\mathbf{P}_f = \mathbf{M} \alpha \mathbf{M}^T (\mathbf{P} + \alpha)$$

$(\alpha > 0 : \text{イン})$

が用いられたりする。







データ同化には、共分散行列の情報が必要であるが、
数値予報のような大きな次元では取り扱いが難しい。

最適内挿法、3次元変分法

- ・・・ 予報誤差共分散行列 P_f は時間変化しないとする。

カルマン・フィルタ、4次元変分法

- ・・・ P_f の時間変化を取り扱う。

データ同化実験の例

Lorenz(1996)モデルを用いて

Lorenz(1996)モデル (Lorenz and Emanuel 1998)

40変数のモデル

$$\frac{d}{dt} X_j = (X_{j+1} - X_{j-2})X_{j-1} - X_j + F \quad j = 1, 2, \dots, 40$$


移流 散逸 強制 (サイクリック)

$t = 1$ を5日と考える。時間刻み幅 6時間。

$F = 8$ のとき


- カオス解 (約2.1日で摂動の大きさ2倍になる)
- 長時間積分の平均 2.3、標準偏差 3.6

X_j の時間変化



ホフメラー図

時刻
(日)





地点番号 j

ホフメラー図

時刻
(日)

● 観測
20地点
12時間毎
観測誤差の
標準偏差1



地点番号 j

実験1： データ同化なし


観測のあった地点の予測値を観測値に置き換えて、それを解析値とする。

真の値


第一推定値

解析値

● 観測




真の値 第一推定値 解析値 ● 観測



誤差(二乗平均平方根 RMSE)の時間変化

第一推定値 解析値



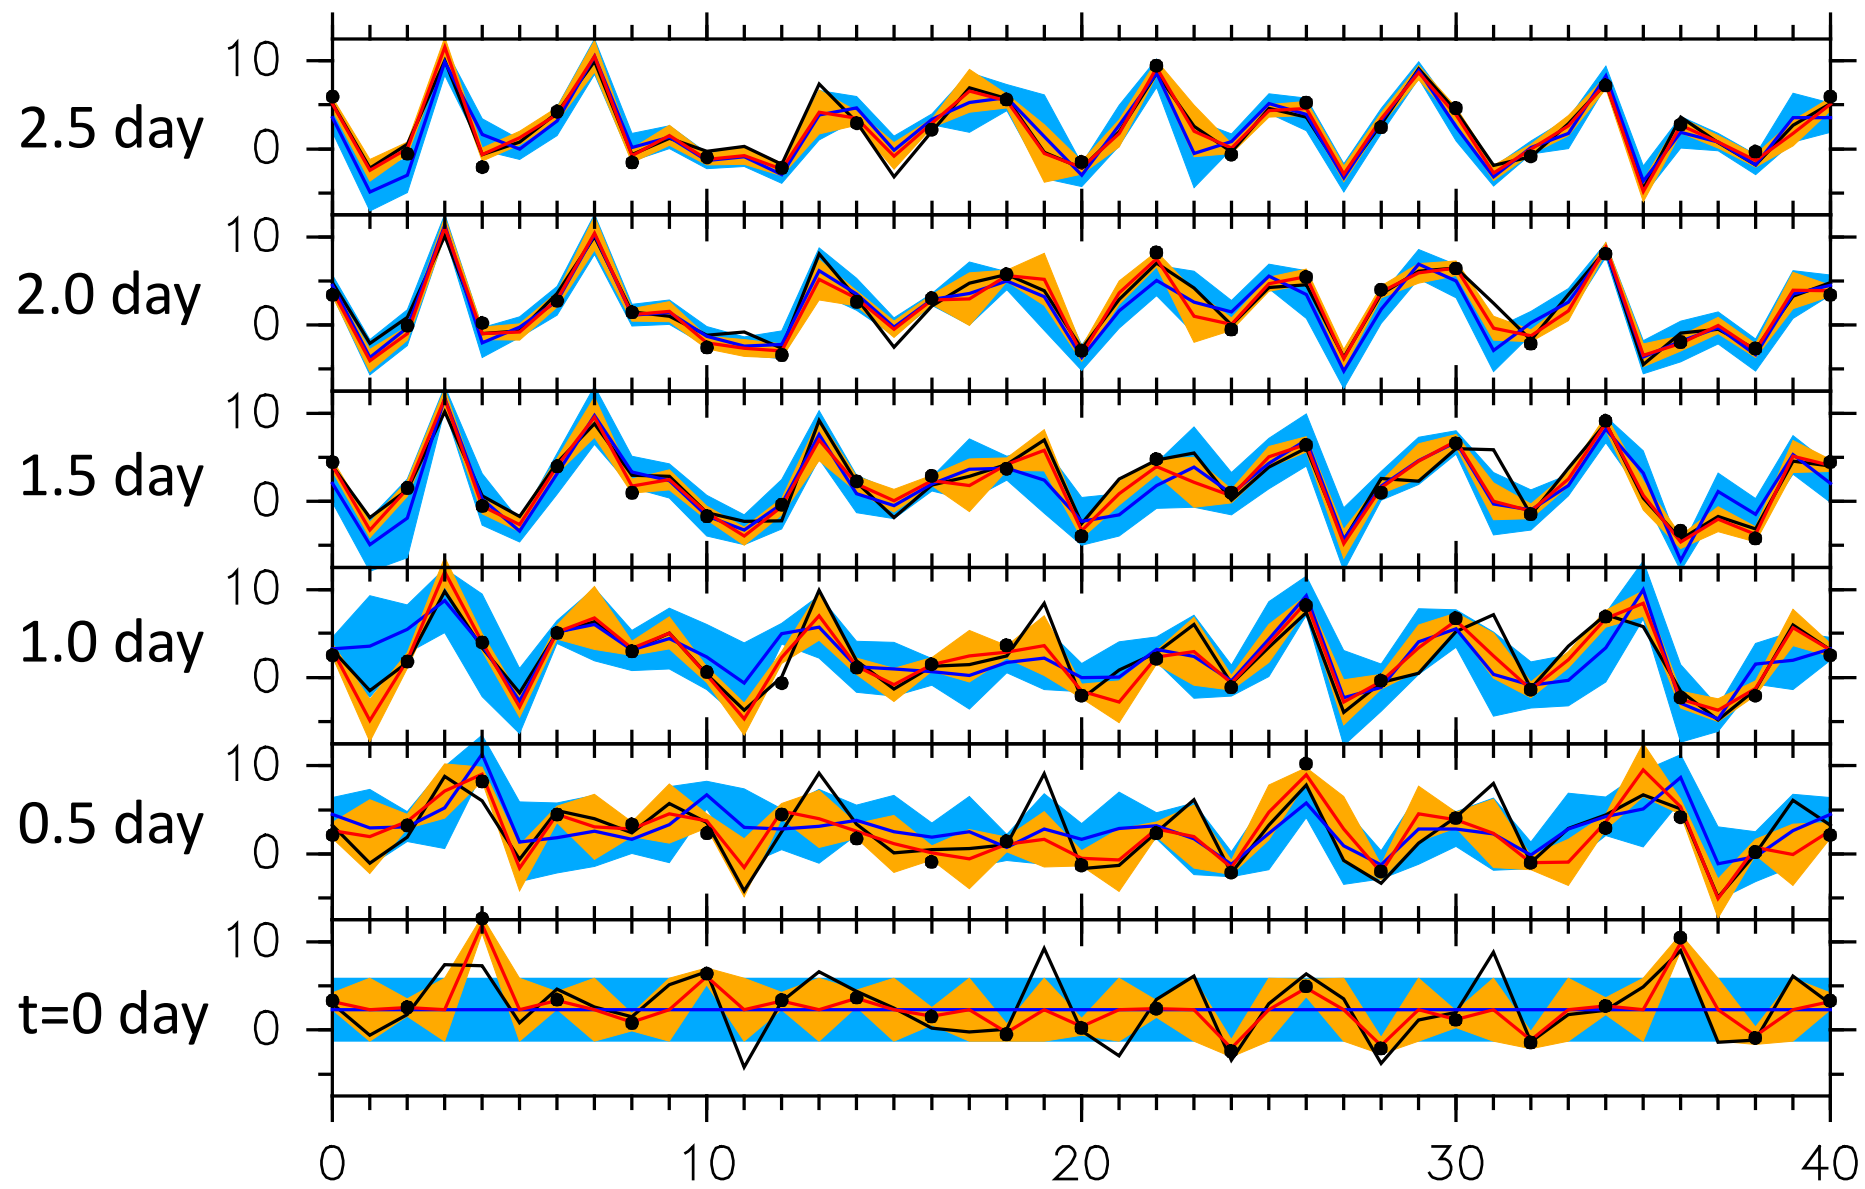
実験2: データ同化(カルマン・フィルタ)

最初の第一推定値 ... 気候学的平均 $X_j = 2.3$

最初の誤差共分散行列 ... 分散 3.6^2 の対角行列

インフレーション: $\alpha = 0.5$

真の値 第一推定値 解析値 ● 観測



影は±1標準偏差の領域

地点番号 j

真の値

第一推定値

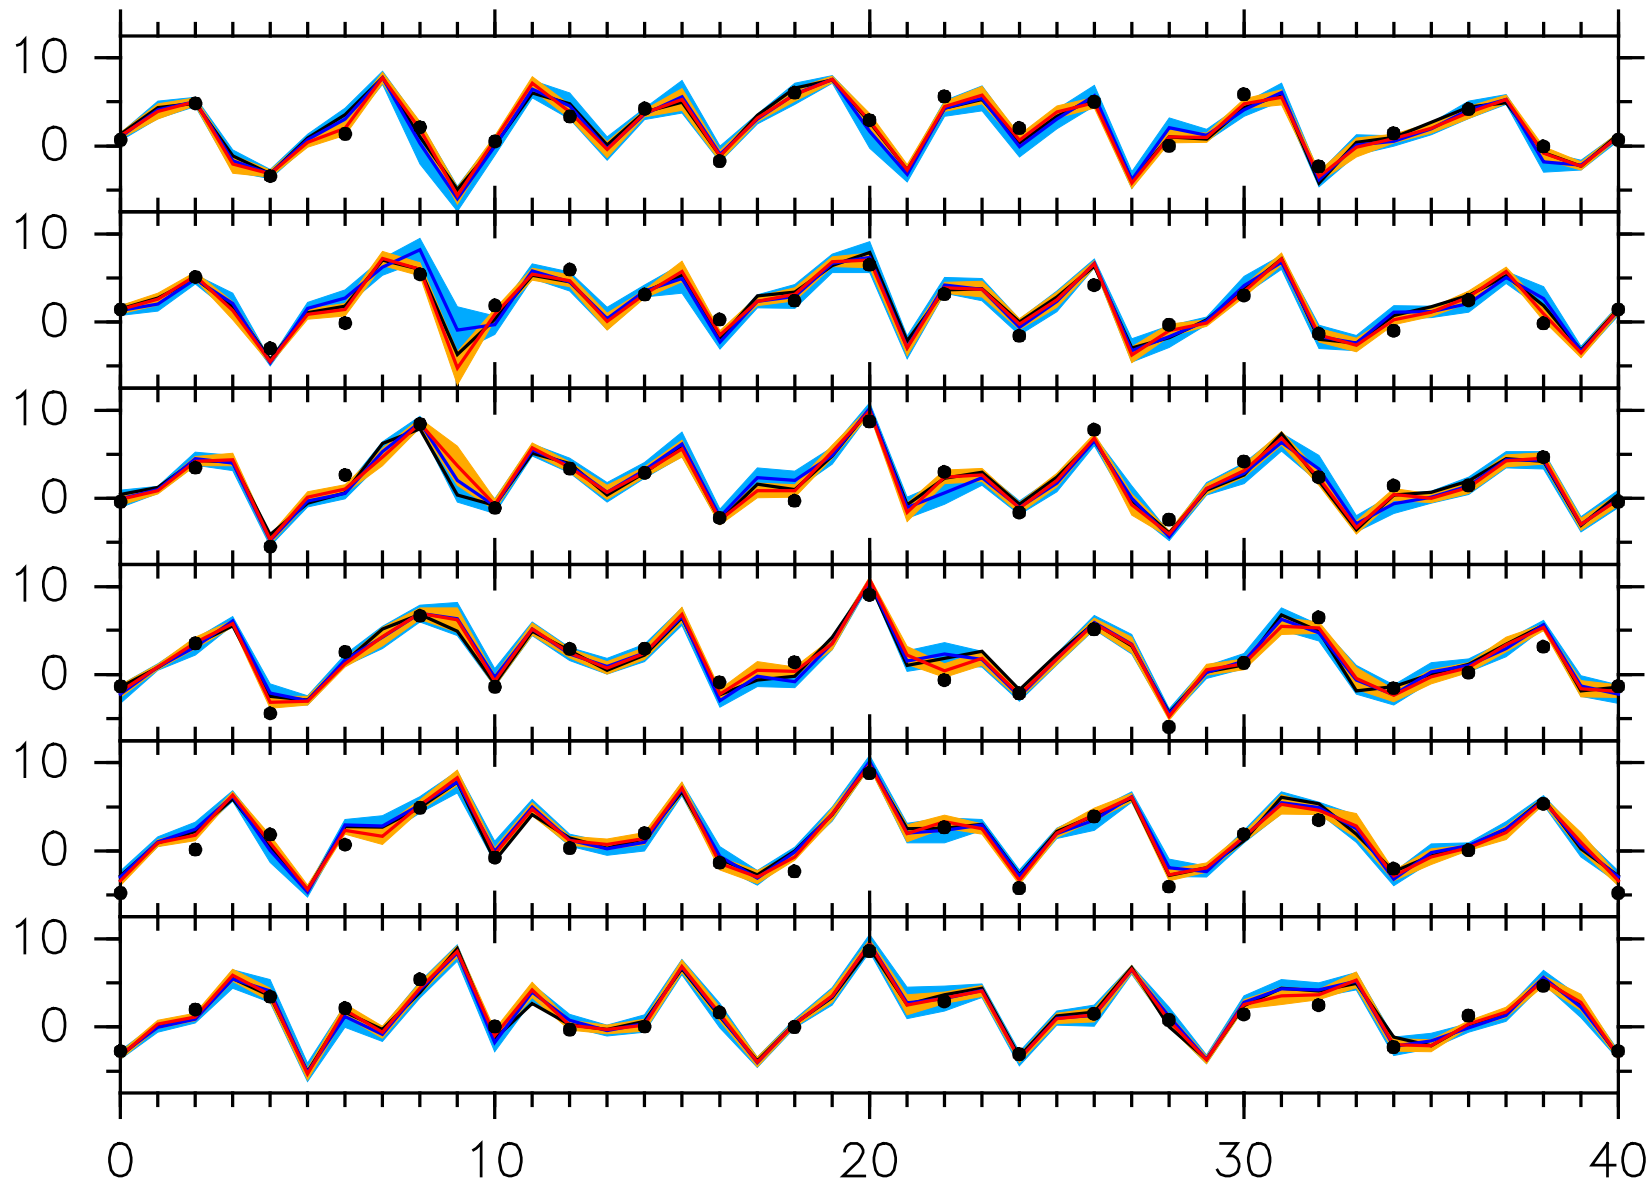
解析値

● 観測

32 day

31 day

30 day




影は±1標準偏差の領域

地点番号 j

誤差(二乗平均平方根 RMSE)の時間変化

第一推定値 解析値



第一推定値の誤差共分散行列の時間変化

