


SCA-7216 Introduction à l'assimilation de données



Notions statistiques de base

- **Variable aléatoire** ϕ est caractérisée par sa distribution (ou densité) de probabilité $p(\phi)$

→ Valeur moyenne: $\langle \phi \rangle = E(\phi) = \int_{-\infty}^{+\infty} \phi p(\phi) d\phi$

→ Variance: $\langle (\phi - \langle \phi \rangle)^2 \rangle = \int_{-\infty}^{+\infty} (\phi - \langle \phi \rangle)^2 p(\phi) d\phi$
 $= \langle \phi^2 \rangle - \langle \phi \rangle^2$

→ Général: $\langle f(\phi) \rangle = \int_{-\infty}^{+\infty} f(\phi) p(\phi) d\phi$

- **Propriété:** si D représente l'ensemble des valeurs possibles (ou admissibles) de ϕ , alors

$$\int_D p(\phi) d\phi = \int_{-\infty}^{+\infty} p(\phi) d\phi = 1$$

- **Médiane** μ :

$$\int_{-\infty}^{\mu} p(x) dx = \int_{\mu}^{+\infty} p(x) dx$$

- **Mode statistique:**


$$\frac{dp}{dx}(m) = 0$$

Distribution gaussienne

- **Définition**

$$p(T) = \frac{1}{\sigma\sqrt{2\pi}} e^{-\frac{(T-\bar{T})^2}{2\sigma^2}}$$

$$\int_{-\infty}^{+\infty} p(T) dT = 1$$



- **Propriétés (exercice)**


$$\langle (T - \langle T \rangle)^n \rangle = \begin{cases} 0 & \text{si } n \text{ est impair} \\ 1 \cdot 3 \cdot 5 \dots (2m-1) \sigma^{2m} & \text{si } n = 2m \end{cases}$$

- **Exercice:** montrer que la probabilité que $\langle T \rangle - \sigma < T < \langle T \rangle + \sigma$ est de 68.26%

- **Moyenne, médiane et mode coïncident**

SCA-7216 Introduction à l'assimilation de données

Estimation d'une distribution de probabilité



SCA-7216 Introduction à l'assimilation de données

Distribution log-normale

- Variable q définie positive: humidité, concentrations, etc.
- Définit: $\xi = \ln q/\gamma$ où γ représente les unités de q
- Distribution gaussienne exprimée en termes de ξ :

$$p(\xi) = \frac{1}{\sigma\sqrt{2\pi}} \exp\left(-\frac{(\xi - \xi_0)^2}{2\sigma^2}\right)$$

$$= \frac{1}{\sigma\sqrt{2\pi}} \exp\left(-\frac{(\ln(q/q_0))^2}{2\sigma^2}\right) = f(q)$$


$$\int_{-\infty}^{+\infty} p(\xi) d\xi = \int_0^{+\infty} f(q) \frac{dq}{q} = \int_0^{+\infty} p(q) dq$$

- Distribution log-normale est alors:

$$p(q) = \frac{f(q)}{q} = \frac{1}{\sigma\sqrt{2\pi}} \frac{1}{q} \exp\left(-\frac{(\ln(q/q_0))^2}{2\sigma^2}\right)$$


- Mode m : $q_0 e^{-\sigma^2}$
- Médiane: q_0
- Moyenne: $q_0 e^{\sigma^2/2}$

Distribution log-normale



Exemple: distribution de Rayleigh

$$p(T) = \begin{cases} \frac{T}{a^2} e^{-T^2/2a^2} & x \geq 0 \\ 0 & x < 0 \end{cases}$$



- Moyenne: $\langle T \rangle = a \frac{\sqrt{2\pi}}{2}$
- Médiane: $\mu = \sqrt{2 \ln 2} a$
- Mode: $m = a$

SCA-7216 Introduction à l'assimilation de données

Distribution conjointe pour N variables aléatoires

- Considère n variables aléatoires ϕ_1, \dots, ϕ_n

Distribution de probabilité conjointe est $p(\phi_1, \dots, \phi_n)$ est telle que

$$\int_V p(\phi_1, \dots, \phi_n) d\phi_1 \dots d\phi_n = 1$$

- Distribution marginale de probabilité de ϕ_k

probabilité que ϕ_k prenne une valeur sans égard aux autres variables

$$p_k(\phi_k) = \int_{V \setminus \{\phi_k\}} p(\phi_1, \dots, \phi_n) d\phi_1 \dots d\phi_k \dots d\phi_n$$

où l'intégration se fait sur toutes les variables sauf ϕ_k

- Variables sont statistiquement indépendantes si

$$p(\phi_1, \dots, \phi_n) = p_1(\phi_1) p_2(\phi_2) \dots p_n(\phi_n)$$

Propriétés de la moyenne statistique

- 1/ Si a_1, \dots, a_n sont des constantes alors:

$$\langle a_1 \phi_1 + \dots + a_n \phi_n \rangle = a_1 \langle \phi_1 \rangle + \dots + a_n \langle \phi_n \rangle$$

- 2/ Si A est une matrice (m x n) alors:

$$\Phi = \begin{pmatrix} \phi_1 \\ \phi_2 \\ \vdots \\ \phi_{n-1} \\ \phi_n \end{pmatrix} \quad \langle \mathbf{A}\Phi \rangle = \mathbf{A}\langle \Phi \rangle$$

Covariances, corrélations et moments statistiques

- Moments statistiques (de deuxième ordre):

$$\langle \phi_k \phi_j \rangle = \int_D \phi_k \phi_j p(\phi_1, \dots, \phi_n) d\phi_1 \dots d\phi_n$$

→ Pour des variables *statistiquement indépendantes*:

$$\langle \phi_j \phi_k \rangle = \begin{cases} \sigma_j^2 + \mu_j^2 & j = k \\ \mu_j \mu_k & j \neq k \end{cases}$$

- Covariances et variances:

$$\text{cov}(\phi_j, \phi_k) = \langle (\phi_j - \mu_j)(\phi_k - \mu_k) \rangle$$

$$\langle \phi_j \phi_k \rangle = \text{cov}(\phi_j, \phi_k) + \mu_j \mu_k$$

$$\sigma_k^2 = \text{cov}(\phi_k, \phi_k)$$

- Corrélations:

$$\rho(\phi_j, \phi_k) = \frac{\text{cov}(\phi_j, \phi_k)}{\sigma_j \sigma_k}$$

Estimateur statistique de la moyenne

- Moyenne statistique est estimée par la moyenne arithmétique de N mesures indépendantes:

$$\bar{\phi} = \frac{1}{N} \sum_{i=1}^N \phi_i$$

$$\Phi = \Phi(\phi_1, \dots, \phi_n)$$

$$p(\Phi) = p(\phi_1, \dots, \phi_n) = p(\phi_1) \dots p(\phi_n)$$

$$p(\phi_k) = \frac{1}{\sigma\sqrt{2\pi}} \exp\{-\frac{(\phi_k - \mu)^2}{2\sigma^2}\}$$

- Moyenne statistique de Φ : $\langle \bar{\phi} \rangle = \frac{1}{N} \sum_{k=1}^N \langle \phi_k \rangle = \mu$

→ Précision de cet estimateur:

$$\langle (\bar{\phi} - \mu)^2 \rangle = \left\langle \left(\frac{1}{N} \sum_{k=1}^N (\phi_k - \mu) \right)^2 \right\rangle = \frac{1}{N^2} \left\langle \left(\sum_{k=1}^N (\phi_k - \mu) \right) \left(\sum_{j=1}^N (\phi_j - \mu) \right) \right\rangle$$

$$= \frac{1}{N^2} \sum_{k=1}^N \langle (\phi_k - \mu)^2 \rangle + \frac{1}{N^2} \sum_{k=1}^N \sum_{j=1, j \neq k}^N \langle (\phi_k - \mu)(\phi_j - \mu) \rangle = \frac{\sigma^2}{N} + \frac{1}{N^2} \sum_{k \neq j} \sigma_{jk} = \frac{\sigma^2}{N}$$

$$\frac{1}{N^2} \sum_{k=1}^N \sum_{j \neq k}^N \langle (\phi_k - \mu)(\phi_j - \mu) \rangle$$

SCA-7216 Introduction à l'assimilation de données

Estimateur de la variance

On pose:

$$S^2 = \frac{1}{C} \sum_{k=1}^N (\phi_k - \bar{\phi})^2 = \frac{1}{C} \sum_{k=1}^N \left(\phi_k - \frac{1}{N} \sum_{j=1}^N \phi_j \right)^2 = \frac{1}{C} \sum_{k=1}^N \left[\phi_k^2 - \frac{2}{N} \sum_{j=1}^N \phi_k \phi_j + \frac{1}{N^2} \sum_{j=1}^N \sum_{m=1}^N \phi_j \phi_m \right]$$

où C est une constante à déterminer

Moyenne statistique de l'estimateur doit correspondre à celle de la variance

$$\langle S^2 \rangle = \frac{1}{C} \sum_{k=1}^N \left[\langle \phi_k^2 \rangle - \frac{2}{N} \sum_{j=1}^N \langle \phi_k \phi_j \rangle + \frac{1}{N^2} \sum_{j=1}^N \sum_{m=1}^N \langle \phi_j \phi_m \rangle \right]$$

Comme $\langle \phi_j \phi_k \rangle = \begin{cases} \sigma^2 + \mu^2 & j = k \\ \mu^2 & j \neq k \end{cases}$, il s'ensuit que

$$-\frac{2}{N} \sum_{j=1}^N \langle \phi_k \phi_j \rangle = -\frac{2}{N} ((\sigma^2 + \mu^2) + (N-1)\mu^2)$$

$$\frac{1}{N^2} \sum_{j=1}^N \sum_{m=1}^N \langle \phi_j \phi_m \rangle = \frac{1}{N^2} (N(\sigma^2 + \mu^2) + N(N-1)\mu^2)$$

Conséquemment,

$$\begin{aligned} \langle S^2 \rangle &= \frac{1}{C} [N(\sigma^2 + \mu^2) - 2(\sigma^2 + \mu^2 + (N-1)\mu^2) + (\sigma^2 + \mu^2) + (N-1)\mu^2] \\ &= \frac{1}{C} [(N-1)\sigma^2] \end{aligned}$$

En choisissant C = N-1, on obtient un estimateur correct (non biaisé) de la variance.

Estimateur

- Moyenne d'ensemble de N mesures indépendantes

$$\bar{\phi} = \frac{1}{N} \sum_{k=1}^N \phi_k$$

- Ecart par rapport à la valeur réelle de la moyenne

$$\langle (\bar{\phi} - \langle \phi \rangle)^2 \rangle = \frac{\sigma^2}{N}$$

- Estimateur non biaisé de la variance

$$S^2 = \frac{1}{(N-1)} \sum_{k=1}^N (\phi_k - \bar{\phi})^2$$

$$\langle S^2 \rangle = \sigma^2$$

- Ecart par rapport à la valeur réelle de la variance (von Storch et Zwiers, ch.5)

$$\langle (S^2 - \sigma^2)^2 \rangle = \frac{2}{N-1} \sigma^4$$

Distribution gaussienne à plusieurs variables

Cas où ϕ_1, \dots, ϕ_n sont statistiquement indépendantes

$$\begin{aligned} p(\phi_1, \dots, \phi_n) &= p_1(\phi_1) \cdots p_n(\phi_n) \\ &= \frac{1}{\sigma_1 \sqrt{2\pi}} \exp\left\{-\frac{(\phi_1 - \mu_1)^2}{2\sigma_1^2}\right\} \cdots \frac{1}{\sigma_n \sqrt{2\pi}} \exp\left\{-\frac{(\phi_n - \mu_n)^2}{2\sigma_n^2}\right\} \\ &= \frac{1}{\sigma_1 \sigma_2 \cdots \sigma_n (2\pi)^{n/2}} \exp\left\{-\frac{1}{2} \mathbf{c}^T \mathbf{B}^{-1} \mathbf{c}\right\} \end{aligned}$$

où B est la matrice de covariance

$$\mathbf{c} = \begin{pmatrix} \phi_1 - \mu_1 \\ \vdots \\ \phi_n - \mu_n \end{pmatrix} \quad \mathbf{B} = \begin{pmatrix} \sigma_1^2 & 0 & \cdots & 0 \\ 0 & \sigma_2^2 & \ddots & \vdots \\ \vdots & \ddots & \ddots & 0 \\ 0 & \cdots & 0 & \sigma_n^2 \end{pmatrix}$$

SCA-7216 Introduction à l'assimilation de données

Covariances, variances et corrélations

Vecteur d'écart
à la moyenne

$$\mathbf{c} = \begin{pmatrix} (\phi_1 - \mu_1) \\ (\phi_2 - \mu_2) \\ \vdots \\ (\phi_{n-1} - \mu_{n-1}) \\ (\phi_n - \mu_n) \end{pmatrix}$$

Covariances

$$\mathbf{B} = \langle \mathbf{c}\mathbf{c}^T \rangle = \begin{pmatrix} \langle c_1^2 \rangle & \langle c_1 c_2 \rangle & \cdots & \langle c_1 c_{n-1} \rangle & \langle c_1 c_n \rangle \\ \langle c_2 c_1 \rangle & \langle c_2^2 \rangle & \ddots & \langle c_2 c_{n-1} \rangle & \langle c_2 c_n \rangle \\ \vdots & \ddots & \ddots & \ddots & \vdots \\ \langle c_{n-1} c_1 \rangle & \cdots & \cdots & \langle c_{n-1}^2 \rangle & \langle c_{n-1} c_n \rangle \\ \langle c_n c_1 \rangle & \langle c_n c_2 \rangle & \cdots & \langle c_n c_{n-1} \rangle & \langle c_n^2 \rangle \end{pmatrix}$$

Remarque: l'erreur est considérée débiaisée

$$\mathbf{c} = \phi - \langle \phi \rangle$$

• Matrice de corrélation C

$$C_{ij} = \frac{\langle c_i c_j \rangle}{\langle c_i^2 \rangle^{1/2} \langle c_j^2 \rangle^{1/2}} = \frac{B_{ij}}{\sigma_i \sigma_j}$$

Corrélations

• Forme matricielle

$$\mathbf{B} = \Sigma \mathbf{C} \Sigma = \begin{pmatrix} \sigma_1 & 0 & \cdots & 0 \\ 0 & \sigma_2 & \ddots & \vdots \\ \vdots & \ddots & \ddots & 0 \\ 0 & \cdots & 0 & \sigma_n \end{pmatrix} \begin{pmatrix} 1 & C_{12} & \cdots & C_{1n} \\ C_{21} & 1 & \ddots & \vdots \\ \vdots & \ddots & \ddots & C_{n-1,n} \\ C_{n1} & \cdots & C_{n,n-1} & 1 \end{pmatrix} \begin{pmatrix} \sigma_1 & 0 & \cdots & 0 \\ 0 & \sigma_2 & \ddots & \vdots \\ \vdots & \ddots & \ddots & 0 \\ 0 & \cdots & 0 & \sigma_n \end{pmatrix}$$

• Corrélations exprimées en termes d'erreur normalisées

$$\mathbf{d} = \begin{pmatrix} c_1 / \sigma_1 \\ c_2 / \sigma_2 \\ \vdots \\ c_n / \sigma_n \end{pmatrix} \quad \mathbf{C} = \langle \mathbf{d}\mathbf{d}^T \rangle$$

Représentation des matrices de covariances

Propriété: B et C sont des matrices symétriques définies positives car pour tout vecteur \mathbf{x} ,

$$\mathbf{x}^T \mathbf{B} \mathbf{x} = \langle (\mathbf{x}^T \mathbf{e}) (\mathbf{e}^T \mathbf{x}) \rangle > 0$$

Propriété des matrices symétriques définies positives:

valeurs propres sont réelles, distinctes et positives. De plus, les vecteurs propres $\mathbf{v}_1, \dots, \mathbf{v}_n$ sont orthonormaux. Ainsi,

$$\mathbf{B} = (\mathbf{v}_1 \ \cdots \ \mathbf{v}_n) \begin{pmatrix} \lambda_1^2 & 0 & \cdots & 0 \\ 0 & \lambda_2^2 & \ddots & \vdots \\ \vdots & \ddots & \ddots & 0 \\ 0 & \cdots & 0 & \lambda_n^2 \end{pmatrix} (\mathbf{v}_1 \ \cdots \ \mathbf{v}_n)^T \equiv \mathbf{V}^T \mathbf{D} \mathbf{V}$$

V est une transformation orthogonale

Propriété: $\mathbf{V}^{-1} = \mathbf{V}^T$
 $\det(\mathbf{V}) = 1$

Orthogonalité des vecteurs propres d'une matrice réelle symétrique

• Considère deux vecteurs propres distincts de A

$$\mathbf{A} \mathbf{v}_1 = \lambda_1 \mathbf{v}_1 \quad \mathbf{A} \mathbf{v}_2 = \lambda_2 \mathbf{v}_2$$

$$\mathbf{v}_2^T \mathbf{A} \mathbf{v}_1 = \lambda_1 \mathbf{v}_2^T \mathbf{v}_1 \quad \mathbf{v}_1^T \mathbf{A} \mathbf{v}_2 = \lambda_2 \mathbf{v}_1^T \mathbf{v}_2$$

$$(\lambda_1 - \lambda_2) \mathbf{v}_1^T \mathbf{v}_2 = 0$$

• Conséquemment

$$\mathbf{v}_1^T \mathbf{v}_2 = 0$$

SCA-7216 Introduction à l'assimilation de données

Orthogonalité des vecteurs propres d'une matrice réelle symétrique (suite)

- Puisque $\mathbf{v}_1, \mathbf{v}_2, \dots, \mathbf{v}_n$ sont des vecteurs propres orthonormaux alors

$$\begin{aligned} \mathbf{A}(\mathbf{v}_1 \ \mathbf{v}_2 \ \dots \ \mathbf{v}_n) &= \mathbf{A}\mathbf{V} = (\mathbf{A}\mathbf{v}_1 \ \mathbf{A}\mathbf{v}_2 \ \dots \ \mathbf{A}\mathbf{v}_n) \\ &= (\lambda_1\mathbf{v}_1 \ \lambda_2\mathbf{v}_2 \ \dots \ \lambda_n\mathbf{v}_n) \\ &= \mathbf{V} \begin{pmatrix} \lambda_1 & 0 & \dots & 0 \\ 0 & \lambda_2 & \ddots & \vdots \\ \vdots & \ddots & \ddots & 0 \\ 0 & \dots & 0 & \lambda_n \end{pmatrix} = \mathbf{V}\mathbf{\Lambda} \end{aligned}$$

- Donc:

$$\mathbf{A} = \mathbf{V}\mathbf{\Lambda}\mathbf{V}^T \Rightarrow \mathbf{A}^{-1} = \mathbf{V}\mathbf{\Lambda}^{-1}\mathbf{V}^T$$

Transformation orthogonale

- Transformation associée à un changement de coordonnées défini par une base orthonormale

$$(\mathbf{e}_1 \ \mathbf{e}_2 \ \dots \ \mathbf{e}_n) \rightarrow (\mathbf{e}'_1 \ \mathbf{e}'_2 \ \dots \ \mathbf{e}'_n)$$

- Donc et inversement

$$\begin{aligned} \mathbf{e}'_1 &= \alpha_{11}\mathbf{e}_1 + \dots + \alpha_{1n}\mathbf{e}_n & \mathbf{e}_1 &= \alpha'_{11}\mathbf{e}'_1 + \dots + \alpha'_{1n}\mathbf{e}'_n \\ \vdots & & \vdots & \\ \mathbf{e}'_n &= \alpha_{n1}\mathbf{e}_1 + \dots + \alpha_{nn}\mathbf{e}_n & \mathbf{e}_n &= \alpha'_{n1}\mathbf{e}'_1 + \dots + \alpha'_{nn}\mathbf{e}'_n \end{aligned}$$

- Comme $\alpha_{ij} = \mathbf{e}'_i{}^T \mathbf{e}_j$ alors $\alpha'_{ij} = \mathbf{e}_i{}^T \mathbf{e}'_j = \alpha_{ji}$

- Définissant

$$\mathbf{M} = (\mathbf{m}_1 \ \mathbf{m}_2 \ \dots \ \mathbf{m}_n) \quad \text{où} \quad \mathbf{m}_j{}^T = (\alpha_{1j} \ \alpha_{2j} \ \dots \ \alpha_{nj})^T$$

Transformation orthogonale (suite)

- Les vecteurs \mathbf{m}_j représentent les vecteurs unitaires \mathbf{e}_j dans le système primé

→ Donc: $\mathbf{m}_i{}^T \mathbf{m}_j = \delta_{ij}$

→ Il s'ensuit que

$$\mathbf{M}^T \mathbf{M} = \begin{pmatrix} \mathbf{m}_1^T \\ \mathbf{m}_2^T \\ \vdots \\ \mathbf{m}_n^T \end{pmatrix} (\mathbf{m}_1 \ \mathbf{m}_2 \ \dots \ \mathbf{m}_n) = \mathbf{I}$$

→ Et donc $\mathbf{M}^{-1} = \mathbf{M}^T$

- Considérons l'expression $\mathbf{A}\mathbf{v} = \mathbf{w}$ où les vecteurs \mathbf{v} et \mathbf{w} sont exprimés en termes de composantes selon $\mathbf{e}_1, \dots, \mathbf{e}_n$

Transformations orthogonales (suite)

- Donc

$$\mathbf{v}' = \mathbf{M}\mathbf{v} \Leftrightarrow \mathbf{v} = \mathbf{M}^T \mathbf{v}'$$

$$\mathbf{A}\mathbf{v} = \mathbf{w} \Rightarrow \mathbf{A}\mathbf{M}^T \mathbf{v}' = \mathbf{M}^T \mathbf{w}'$$

$$\mathbf{M}\mathbf{A}\mathbf{M}^T \mathbf{v}' = \mathbf{w}' \Rightarrow \mathbf{A}' \mathbf{v}' = \mathbf{w}'$$

SCA-7216 Introduction à l'assimilation de données

Variables statistiquement indépendantes associées à \mathbf{B}

- **Changement de variable orthogonal:** $\xi = \mathbf{V} \phi$


- **Distribution gaussienne: cas général**

$$\begin{aligned} p_{\xi}(\xi_1, \dots, \xi_n) &= \frac{1}{\lambda_1 \sqrt{2\pi}} \exp\left\{-\frac{\xi_1^2}{2\lambda_1^2}\right\} \cdots \frac{1}{\lambda_n \sqrt{2\pi}} \exp\left\{-\frac{\xi_n^2}{2\lambda_n^2}\right\} \\ &= \frac{1}{(\det \mathbf{D})^{1/2} (2\pi)^{n/2}} \exp\left\{-\frac{1}{2} (\mathbf{V}\phi)^T \mathbf{D}^{-1} (\mathbf{V}\phi)\right\} \\ &= \frac{1}{(\det \mathbf{B})^{1/2} (2\pi)^{n/2}} \exp\left\{-\frac{1}{2} \phi^T \mathbf{B}^{-1} \phi\right\} = p(\phi_1, \dots, \phi_n) \end{aligned}$$

- **Normalisation peut être obtenue en utilisant**

$$\chi = \mathbf{D}^{-1/2} \mathbf{V} \phi \quad \Rightarrow \quad p(\chi_1, \dots, \chi_n) = \frac{1}{(2\pi)^{n/2}} \exp\left\{-\frac{1}{2} \chi^T \chi\right\}$$

Exemple illustrant $\phi^T \mathbf{B}^{-1} \phi$ pour $\phi = (\phi_1, \phi_2)^T$



Covariance d'erreur d'un champ de température

- Variable aléatoire: $T = (T_1, \dots, T_n)$ où $T_i = T(x_i, y_i)$
- Modèle de covariance d'erreur:

$$B_{ij} = \sigma_i \sigma_j f(|p_i - p_j|)$$

où $p_i \equiv (x_i, y_i)$.

- Corrélations sont dites homogènes et isotopes car elles ne dépendent que de la distance entre les points p_i et p_j .
- Remarque: la fonction de corrélation peut avoir un profil gaussien ou non. Il n'en demeure pas moins que la distribution de probabilité demeure gaussienne.

Référence: von Storch et Zwiers, 1999: *Statistical analysis in Climate Research*
Section V: Eigen techniques. Ch-13 à 16

FONCTIONS EMPIRIQUES ORTHOGONALES

SCA-7216 Introduction à l'assimilation de données

SCA-7216 Introduction à l'assimilation de données

Fonctions empiriques orthogonales

- **Evaluation des modes associés à la variabilité atmosphérique moyennée sur une période de temps**
- **Exemple: variabilité de la température de la surface de la mer (Sea Surface Temperature, SST)**

→ Considérons que nous avons une suite de champs de température de surface la mer $T_s(\lambda, \varphi, t_k) = T_k$.

→ Sur une période de temps t_1 à t_K , on calcule la moyenne temporelle $\bar{T}_s(\lambda, \varphi)$ de T_s comme étant

$$\bar{T}_s \equiv \bar{T}_s(\lambda, \varphi) = \frac{1}{K} \sum_{k=1}^K T_s(\lambda, \varphi, t_k)$$

→ La variabilité par rapport à cette moyenne est ensuite définie, à chaque instant, comme étant

$$T_k'(\lambda, \varphi) = (T_s(\lambda, \varphi, t_k) - \bar{T}_s)$$

Définition de la covariance de la variabilité

- La covariance spatiale est estimée par

$$B(\lambda, \varphi; \lambda', \varphi') = \frac{1}{(K-1)} \sum_{k=1}^K T_k'(\lambda, \varphi) T_k'(\lambda', \varphi')$$

- Ceci représente la covariance d'erreur entre deux points de longitude et latitude (λ, φ) et (λ', φ') respectivement moyennée à partir d'un échantillon de taille **K**

- Sur une grille comportant N_x points en λ et N_y points en φ , chaque champ comprend donc **N = N_x × N_y** degrés de liberté

→ Les points de grille sont de coordonnées

$$(\lambda_1, \varphi_1) \quad (\lambda_2, \varphi_2) \quad \dots \quad (\lambda_N, \varphi_N)$$

→ Le vecteur de variabilité est alors défini par $\mathbf{E}_k = \frac{1}{\sqrt{K-1}}$

$$\begin{pmatrix} T_k'(\lambda_1, \varphi_1) \\ T_k'(\lambda_2, \varphi_2) \\ \vdots \\ T_k'(\lambda_N, \varphi_N) \end{pmatrix}$$

Équivalence entre les formes matricielle et scalaire

On définit $p_\nu = (\lambda_{j(\nu)}, \varphi_{j(\nu)})$ avec $\nu = 1, \dots, N_x \times N_y = N$

$$\mathbf{B} = \sum_{k=1}^K \begin{pmatrix} E_k'(p_1) \\ \vdots \\ E_k'(p_n) \end{pmatrix} (E_k'(p_1) \quad \dots \quad E_k'(p_n))$$

$$= \sum_{k=1}^K \begin{pmatrix} E_k'(p_1) E_k'(p_1) & \dots & E_k'(p_1) E_k'(p_n) \\ \vdots & \ddots & \vdots \\ E_k'(p_n) E_k'(p_1) & \dots & E_k'(p_n) E_k'(p_n) \end{pmatrix} = \sum_{k=1}^K \mathbf{E}_k \mathbf{E}_k^T$$

$$= \begin{pmatrix} E_1'(p_1) & E_2'(p_1) & \dots & E_n'(p_1) \\ E_1'(p_2) & E_2'(p_2) & \dots & E_n'(p_2) \\ \vdots & \vdots & \ddots & \vdots \\ E_1'(p_n) & E_2'(p_n) & \dots & E_n'(p_n) \end{pmatrix} \begin{pmatrix} E_1'(p_1) & E_1'(p_2) & \dots & E_1'(p_n) \\ E_2'(p_1) & E_2'(p_2) & \dots & E_2'(p_n) \\ \vdots & \vdots & \ddots & \vdots \\ E_n'(p_1) & E_n'(p_2) & \dots & E_n'(p_n) \end{pmatrix}$$

$$= \mathbf{E} \mathbf{E}^T$$

SCA-7216 Introduction à l'assimilation de données

Définition de la covariance de la variabilité

- Avec cette notation, la covariance d'erreur devient

$$\mathbf{B} = \sum_{k=1}^K \mathbf{E}_k \mathbf{E}_k^T$$

- On forme une matrice **E** dont les colonnes correspondent aux vecteurs E_1, E_2, \dots, E_K , c'est-à-dire que

$$\mathbf{E} = (\mathbf{E}_1 \quad \mathbf{E}_2 \quad \dots \quad \mathbf{E}_K)$$

- Conséquemment **B = EE^T**

- Cette matrice est d'ordre NxN

- Remarque Comme E est une matrice *rectangulaire* d'ordre NxK, il s'ensuit que E^T est d'ordre (KxN)

SCA-7216 Introduction à l'assimilation de données

Fonction empirique orthogonale

- **Définition.** Les vecteurs propres de la matrice \mathbf{B} sont appelés *fonctions empiriques orthogonales* (ou EOF de l'anglais *Empirical Orthogonal functions*)
- Calcul nécessite de *définir* les $N(N+1)/2$ coefficients de la matrice et ensuite d'en trouver les vecteurs propres
→ Les vecteurs propres de \mathbf{B} définis comme

$$\mathbf{B}\mathbf{v} = (\mathbf{E}\mathbf{E}^T)\mathbf{v} = \lambda\mathbf{v}$$
- Structure de la matrice symétrique permet de réduire considérablement le calcul.

Fonctions empiriques orthogonales et composantes principales

- La forme de $\mathbf{B} = \mathbf{E}\mathbf{E}^T$ permet d'établir une relation entre les vecteurs propres de \mathbf{B} et ceux de la matrice $\mathbf{E}^T\mathbf{E}$ qui est d'ordre $(K \times K)$ ce qui est beaucoup moins élevé que l'ordre de \mathbf{B} ($N \times N$).
→ Typiquement, K est d'ordre 10^2 alors que N peut facilement être d'ordre égal ou plus grand à 10^6

Considérant que

$$\mathbf{B}\mathbf{v} = \mathbf{E}\mathbf{E}^T\mathbf{v} = \lambda\mathbf{v}$$

On multiplie à gauche par \mathbf{E}^T pour obtenir

$$(\mathbf{E}^T\mathbf{E})\mathbf{E}^T\mathbf{v} = \lambda\mathbf{E}^T\mathbf{v}$$

ce qui se réécrit

$$(\mathbf{E}^T\mathbf{E})\mathbf{w} = \lambda\mathbf{w} \quad (1)$$

où

$$\mathbf{w} = \mathbf{E}^T\mathbf{v} \Rightarrow \mathbf{v} = \mathbf{E}\mathbf{w}$$

Composantes principales et EOF

- **Echantillon basé sur une série temporelle de K instants**
→ champ fourni à toutes les 6 heures durant 60 jours donne un échantillon de taille $K=360$
- **Les vecteurs propres \mathbf{w} de $\mathbf{E}^T\mathbf{E}$ sont de dimension K de telle sorte que les K composantes sont**

$$\mathbf{w} = \begin{pmatrix} w(t_1) \\ w(t_2) \\ \vdots \\ w(t_K) \end{pmatrix}$$

- **Les EOFs sont déduites de (1) et sont telles que**

$$\mathbf{v} = \mathbf{E}\mathbf{w} = \sum_{k=1}^K w(t_k)\mathbf{E}_k$$



Interprétation

- **Composantes principales** définissent les poids $w(t_k)$ d'une combinaison linéaire qui définit les vecteurs propres de la matrice \mathbf{B}
→ $w(t)$ est une série temporelle
- Vecteurs propres de \mathbf{B} sont des structures purement spatiales
- Les définitions précédentes permettent d'écrire que

$$\mathbf{v}(\lambda, \varphi) = \frac{1}{(K-1)} \sum_{k=1}^K w(t_k)T_k'(\lambda, \varphi)$$

- Exemple: analyse des moyennes mensuelles de la température de la surface de la mer (SST) sur la période de 1970 à 1990 ($K=252$)

SCA-7216 Introduction à l'assimilation de données



Remarques

- **Chapitres 13 à 16 de von Storch et Zwiers**
 - Canonical Correlation Analysis (CCA) (Analyse canonique des corrélations)
 - Même approche que pour les EOFs mais pour traiter les corrélations
 - Permet de considérer des corrélations entre différentes variables (e.g., vents et température)
- **Covariances permettent d'établir des liens pour des mécanismes existant au même moment.**

SCA-7216 Introduction à l'assimilation de données

Estimation statistique: cas univarié (1 point)

$\mathbf{X}_b =$ prévision (ou champ d'essai)	$\epsilon_b = (\mathbf{X}_b - \mathbf{X}_t):$	erreur de prévision
$\mathbf{X}_o =$ observation	$\epsilon_o = (\mathbf{X}_o - \mathbf{X}_t):$	erreur d'observation
$\mathbf{X}_a =$ analyse	$\epsilon_a = (\mathbf{X}_a - \mathbf{X}_t):$	erreur d'analyse
et $\mathbf{X}_t =$ état réel		

Hypothèses sous-jacentes à l'interpolation statistique

- Erreur d'observation et de prévision sont non biaisées
 $\langle \epsilon_b \rangle = \langle \epsilon_o \rangle = 0$
- variances d'erreur σ_b^2 et σ_o^2 sont connues

SCA-7216 Introduction à l'assimilation de données

Meilleur estimé linéaire non-biaisé (Best Linear Unbiased Estimate) (BLUE)

• Analyse $\mathbf{X}_a = \mathbf{X}_b + \lambda(\mathbf{X}_o - \mathbf{X}_b)$

- Variance d'erreur d'analyse


$$\begin{aligned} J(\lambda) &= \sigma_a^2 = \langle (\mathbf{X}_a - \mathbf{X}_t)^2 \rangle \\ &= \langle (\mathbf{X}_b - \mathbf{X}_t + \lambda(\mathbf{X}_o - \mathbf{X}_t) - (\mathbf{X}_b - \mathbf{X}_t))^2 \rangle \\ &= \langle ((1-\lambda)\varepsilon_b + \lambda\varepsilon_o)^2 \rangle = (1-\lambda)^2 \langle \varepsilon_b^2 \rangle + 2\lambda(1-\lambda) \langle \varepsilon_b \varepsilon_o \rangle + \lambda^2 \langle \varepsilon_o^2 \rangle \\ &= \sigma_b^2 (1-\lambda)^2 + \lambda^2 \sigma_o^2 \end{aligned}$$

- Estimé de λ minimisant la variance d'erreur d'analyse:

$$\begin{aligned} \frac{dJ}{d\lambda} = 0 \quad \Rightarrow \quad \lambda^* &= \frac{\sigma_b^2}{\sigma_b^2 + \sigma_o^2} \Rightarrow \frac{1}{\sigma_a^2} = \frac{1}{\sigma_b^2} + \frac{1}{\sigma_o^2} \\ &\Rightarrow \sigma_a^2 < \min \{ \sigma_b^2, \sigma_o^2 \} \end{aligned}$$

Opérateur d'observation

- Analyse de température en un point sur le dernier niveau du modèle utilisant une mesure de la température à 10m



Opérateur d'observation: $HT = \alpha T$

Valeur analysée: $T_a = T_b + \lambda(T_{obs.} - \alpha T_b)$

Estimé minimisant la variance d'erreur d'analyse:

$$\lambda = \frac{\alpha \sigma_b^2}{(\sigma_b^2 + \alpha^2 \sigma_o^2)}$$

Interpolation statistique (ou méthode de Gauss-Markov)

(Gandin, 1963; Rutherford, 1973; Schlatter, 1977; Daley, 1991)

Définitions

- $\mathbf{y} \in \mathbb{R}^m$: vecteur d'observation ($m \sim 10^6$)
- $\mathbf{X} \in \mathbb{R}^n$: vecteur d'état du modèle ($n \sim 10^8$)
- $\mathbf{H}: \mathbb{R}^n \rightarrow \mathbb{R}^m$: Opérateur d'observation
- $\mathbf{B} = \langle \varepsilon_b \varepsilon_b^T \rangle$: covariances d'erreur de prévision
- $\mathbf{R} = \langle \varepsilon_o \varepsilon_o^T \rangle$: covariances d'erreur d'observation

Hypothèses

Erreurs d'observation et de prévision sont supposées être non-corrélées

$$\langle \varepsilon_b \varepsilon_o^T \rangle = 0.$$

Erreurs de prévision et d'observation ne sont pas biaisés:

$$\langle \varepsilon_b \rangle = \langle \varepsilon_o \rangle = 0$$

Estimateur de variance minimale: cas univarié

- Analyse univariée: analyse d'un seul champ météorologique en chaque point de la grille du modèle
- Dimension de la variable aléatoire:
→ (# niveaux) × (# points de grille) = $80 \times (1024 \times 800) \sim 10^8$
- Autocovariances d'erreur: $B_y = \langle T T^T \rangle$
→ \mathbf{B} est de dimension $(10^8 \times 10^8) = 10^{16}$.
- Estimateur linéaire: $\mathbf{X}_a = \mathbf{X}_b + \mathbf{K}(\mathbf{y} - \mathbf{H}\mathbf{X}_b)$
→ \mathbf{K} est maintenant une matrice ($N \times M$)

SCA-7216 Introduction à l'assimilation de données

Dérivation de la matrice de gain K minimisant la variance d'erreur d'analyse

- Variance totale d'erreur d'analyse:

$$\begin{aligned} J(\mathbf{K}) &= \varepsilon_a^T \varepsilon_a = (\mathbf{x}_a - \mathbf{x}_i)^T (\mathbf{x}_a - \mathbf{x}_i) \\ &= (\varepsilon_b + \mathbf{K}(\varepsilon_o - \mathbf{H}\varepsilon_b))^T (\varepsilon_b + \mathbf{K}(\varepsilon_o - \mathbf{H}\varepsilon_b)) \\ &= \varepsilon_b^T \varepsilon_b + (\varepsilon_o - \mathbf{H}\varepsilon_b)^T \mathbf{K}^T \mathbf{K} (\varepsilon_o - \mathbf{H}\varepsilon_b) + \varepsilon_b^T \mathbf{K} (\varepsilon_o - \mathbf{H}\varepsilon_b) + (\varepsilon_o - \mathbf{H}\varepsilon_b)^T \mathbf{K}^T \varepsilon_b \end{aligned}$$

- Calcul de $\partial J / \partial \mathbf{K} = \mathbf{M}$: $M_{ij} = \partial J / \partial K_{ij}$

- Quelques identités: $\frac{\partial}{\partial \mathbf{K}} \mathbf{X}^T \mathbf{K}^T \mathbf{K} \mathbf{X} = 2\mathbf{K} \mathbf{X} \mathbf{X}^T$
 $\frac{\partial}{\partial \mathbf{K}} \mathbf{Y}^T \mathbf{K} \mathbf{X} = \mathbf{Y} \mathbf{X}^T$
 $\frac{\partial}{\partial \mathbf{K}} \mathbf{Y}^T \mathbf{K}^T \mathbf{X} = \mathbf{X} \mathbf{Y}^T$

Démonstration

1. $\frac{\partial}{\partial \mathbf{K}} \mathbf{Y}^T \mathbf{K} \mathbf{X} = \mathbf{Y} \mathbf{X}^T$ $(\mathbf{Y}^T \mathbf{K} \mathbf{X}) = \sum_i \sum_m Y_i K_{im} X_m$
 $\left[\frac{\partial}{\partial K_{ij}} \mathbf{Y}^T \mathbf{K} \mathbf{X} \right]_{ij} = Y_j X_i$

2. $\frac{\partial}{\partial \mathbf{K}} \mathbf{Y}^T \mathbf{K}^T \mathbf{X} = \mathbf{X} \mathbf{Y}^T$ $(\mathbf{Y}^T \mathbf{K}^T \mathbf{X}) = \sum_i \sum_m Y_i K_{im}^T X_m$
 $\left[\frac{\partial}{\partial K_{ij}} \mathbf{Y}^T \mathbf{K}^T \mathbf{X} \right]_{ij} = Y_j X_i$

3. $\frac{\partial}{\partial \mathbf{K}} \mathbf{X}^T \mathbf{K}^T \mathbf{K} \mathbf{X} = 2\mathbf{K} \mathbf{X} \mathbf{X}^T$ $(\mathbf{X}^T \mathbf{K}^T \mathbf{K} \mathbf{X}) = \sum_l \sum_m \sum_n X_n K_{ln} K_{lm} X_m$
 $\left[\frac{\partial}{\partial K_{ij}} \mathbf{X}^T \mathbf{K}^T \mathbf{K} \mathbf{X} \right]_{ij} = X_j K_{im} X_m + X_n K_{in} X_j$
 $= 2(\mathbf{K} \mathbf{X})_i X_j$

Matrice de gain

$$\begin{aligned} \frac{\partial}{\partial \mathbf{K}} J(\mathbf{K}) &= \frac{\partial}{\partial \mathbf{K}} (\varepsilon_b^T \varepsilon_b + (\varepsilon_o - \mathbf{H}\varepsilon_b)^T \mathbf{K}^T \mathbf{K} (\varepsilon_o - \mathbf{H}\varepsilon_b) + \varepsilon_b^T \mathbf{K} (\varepsilon_o - \mathbf{H}\varepsilon_b) + (\varepsilon_o - \mathbf{H}\varepsilon_b)^T \mathbf{K}^T \varepsilon_b) \\ &= 2\mathbf{K}(\varepsilon_o - \mathbf{H}\varepsilon_b)(\varepsilon_o - \mathbf{H}\varepsilon_b)^T + \varepsilon_b(\varepsilon_o - \mathbf{H}\varepsilon_b)^T + \varepsilon_b(\varepsilon_o - \mathbf{H}\varepsilon_b)^T \\ &= \mathbf{0} \end{aligned}$$

En prenant l'espérance mathématique de ce résultat et en utilisant les propriétés et définitions introduites plus haut:

$$\langle \varepsilon_b \varepsilon_o^T \rangle = \mathbf{0}; \quad \mathbf{B} = \langle \varepsilon_b \varepsilon_b^T \rangle; \quad \mathbf{R} = \langle \varepsilon_o \varepsilon_o^T \rangle$$

on obtient

$$\begin{aligned} \frac{\partial}{\partial \mathbf{K}} J(\mathbf{K}) &= 2\mathbf{K} [\langle \varepsilon_o \varepsilon_o^T \rangle - \mathbf{H} \langle \varepsilon_b \varepsilon_o^T \rangle - \langle \varepsilon_o \varepsilon_b^T \rangle \mathbf{H}^T + \mathbf{H} \langle \varepsilon_b \varepsilon_b^T \rangle \mathbf{H}^T] + 2 \langle \varepsilon_b \varepsilon_o^T \rangle - 2 \langle \varepsilon_b \varepsilon_b^T \rangle \mathbf{H}^T \\ &= 2\mathbf{K} [\mathbf{R} + \mathbf{H} \mathbf{B} \mathbf{H}^T] - 2\mathbf{B} \mathbf{H}^T = \mathbf{0} \end{aligned}$$

Donc

$$\mathbf{K} = \mathbf{B} \mathbf{H}^T (\mathbf{R} + \mathbf{H} \mathbf{B} \mathbf{H}^T)^{-1}$$

Covariances d'erreur d'analyse

- Erreur d'analyse $\varepsilon_a = \varepsilon_b + \mathbf{K}(\varepsilon_o - \mathbf{H}\varepsilon_b) = (\mathbf{I} - \mathbf{K} \mathbf{H}) \varepsilon_b + \mathbf{K} \varepsilon_o$
- Covariances d'erreur d'analyse

$$\begin{aligned} \mathbf{P}_a &= \langle \varepsilon_a \varepsilon_a^T \rangle \\ &= \langle ((\mathbf{I} - \mathbf{K} \mathbf{H}) \varepsilon_b + \mathbf{K} \varepsilon_o) ((\mathbf{I} - \mathbf{K} \mathbf{H}) \varepsilon_b + \mathbf{K} \varepsilon_o)^T \rangle \\ &= \langle ((\mathbf{I} - \mathbf{K} \mathbf{H}) \varepsilon_b + \mathbf{K} \varepsilon_o) (\varepsilon_b^T (\mathbf{I} - \mathbf{K} \mathbf{H})^T + \varepsilon_o^T \mathbf{K}^T) \rangle \\ &= (\mathbf{I} - \mathbf{K} \mathbf{H}) \langle \varepsilon_b \varepsilon_b^T \rangle (\mathbf{I} - \mathbf{K} \mathbf{H})^T + \mathbf{K} \langle \varepsilon_o \varepsilon_o^T \rangle \mathbf{K}^T + \underbrace{(\mathbf{I} - \mathbf{K} \mathbf{H}) \langle \varepsilon_b \varepsilon_o^T \rangle \mathbf{K}^T}_{=0} + \underbrace{\mathbf{K} \langle \varepsilon_o \varepsilon_b^T \rangle (\mathbf{I} - \mathbf{K} \mathbf{H})^T}_{=0} \\ &= (\mathbf{I} - \mathbf{K} \mathbf{H}) \mathbf{B} (\mathbf{I} - \mathbf{K} \mathbf{H})^T + \mathbf{K} \mathbf{R} \mathbf{K}^T \end{aligned}$$

A l'optimalité, on a $\mathbf{K} = \mathbf{B} \mathbf{H}^T (\mathbf{R} + \mathbf{H} \mathbf{B} \mathbf{H}^T)^{-1}$

Conséquentement,

$$\begin{aligned} \mathbf{P}_a &= (\mathbf{I} - \mathbf{K} \mathbf{H}) \mathbf{B} - (\mathbf{I} - \mathbf{K} \mathbf{H}) \mathbf{B} \mathbf{H}^T \mathbf{K}^T + \mathbf{K} \mathbf{R} \mathbf{K}^T \\ &= (\mathbf{I} - \mathbf{K} \mathbf{H}) \mathbf{B} - \mathbf{B} \mathbf{H}^T \mathbf{K}^T + \mathbf{K} (\mathbf{H} \mathbf{B} \mathbf{H}^T + \mathbf{R}) \mathbf{K}^T \\ &= (\mathbf{I} - \mathbf{K} \mathbf{H}) \mathbf{B} - \mathbf{B} \mathbf{H}^T \mathbf{K}^T + \mathbf{B} \mathbf{H}^T (\mathbf{H} \mathbf{B} \mathbf{H}^T + \mathbf{R})^{-1} (\mathbf{H} \mathbf{B} \mathbf{H}^T + \mathbf{R}) \mathbf{K}^T \\ &= (\mathbf{I} - \mathbf{K} \mathbf{H}) \mathbf{B} - \mathbf{B} \mathbf{H}^T \mathbf{K}^T + \mathbf{B} \mathbf{H}^T \mathbf{K}^T \\ &= (\mathbf{I} - \mathbf{K} \mathbf{H}) \mathbf{B} \end{aligned}$$

SCA-7216 Introduction à l'assimilation de données

Equations de l'interpolation statistique

$$\mathbf{X}_a = \mathbf{X}_b + \mathbf{K}(\mathbf{y} - \mathbf{H}\mathbf{X}_b)$$


$$\mathbf{K} = \mathbf{B}\mathbf{H}^T(\mathbf{R} + \mathbf{H}\mathbf{B}\mathbf{H}^T)^{-1}$$

$$\mathbf{P}_a = (\mathbf{I} - \mathbf{K}\mathbf{H})\mathbf{B}$$

Matrice de gain (ou poids statistiques): \mathbf{K}
 Innovations (ou écarts aux observation): $\mathbf{y} - \mathbf{H}\mathbf{X}_b$

Dimensionnalité du problème

- Nombre d'observations: \mathbf{M}
- Etat-modèle: \mathbf{N}
- Vecteur d'état \mathbf{x}_a et \mathbf{x}_b : $\mathbf{x} = (\mathbf{N} \times 1)$
- Vecteur d'observation: $\mathbf{y} = (\mathbf{M} \times 1)$
- Equivalent modèle de l'observation: $\mathbf{H}\mathbf{x}_b = (\mathbf{N} \times 1)$
- Opérateur d'observation $\mathbf{H} = (\mathbf{M} \times \mathbf{N})$
- Matrice de gain $\mathbf{K} = (\mathbf{N} \times \mathbf{M})$
- Covariance d'erreur de prévision $\mathbf{B} = ((\mathbf{N} \times \mathbf{N}))$
- Covariance d'erreur d'observation $\mathbf{R} = (\mathbf{M} \times \mathbf{M})$
- Erreur de prévision dans l'espace des observations $\mathbf{H}\mathbf{B}\mathbf{H}^T = (\mathbf{M} \times \mathbf{M})$



© ECMWF 2000


Exemple: cas unidimensionnel T(x)

- Covariance d'erreur de prévision
$$B(x_1, x_2) = \sigma_b(x_1)\sigma_b(x_2) \exp\left\{-\frac{(x_1 - x_2)^2}{2L^2}\right\}$$

 L est la longueur caractéristique de la fonction de corrélation
- Assimilation d'une seule observation
$$H(x) = \delta(x - x_{obs})$$

$$(\mathbf{R} + \mathbf{H}\mathbf{B}\mathbf{H}^T) = (\sigma_o^2 + \sigma_b^2(x_{obs}))$$
- Forme matricielle de H
$$\mathbf{H} = \left(0 \quad \dots \quad 0 \quad \underset{x=x_{obs}}{1} \quad 0 \quad \dots \quad 0 \right)$$
- Incrément d'analyse

$$T_a(x) - T_b(x) = \frac{\sigma_b(x_{obs})\sigma_b(x)}{(\sigma_b^2(x_{obs}) + \sigma_o^2)} \exp\left\{-\frac{(x - x_{obs})^2}{2L^2}\right\} (T_{obs} - T_b(x_{obs}))$$




Covariance d'erreur d'analyse

$$(\mathbf{I} - \mathbf{K}\mathbf{H})\mathbf{B} = \left(1 - \frac{1}{\sigma_o^2 + \sigma_b^2} \mathbf{B}\mathbf{H}^T\mathbf{H} \right) \mathbf{B} \quad \mathbf{B}\mathbf{H}^T(x) = \sigma_b(x_{obs})\sigma_b(x) e^{-(x-x_{obs})^2/2L^2}$$

- Expression pour la variance d'erreur d'analyse

$$\mathbf{B}\mathbf{H}^T(\mathbf{B}\mathbf{H}^T)^T(x, x) = \sigma_b^2(x_{obs})\sigma_b^2(x) e^{-2(x-x_{obs})^2/L^2}$$

$$\sigma_a^2(x) = \sigma_b^2(x) \left[1 - \frac{\sigma_b^2(x_{obs})}{\sigma_b^2(x_{obs}) + \sigma_o^2} e^{-2(x-x_{obs})^2/L^2} \right]$$



SCA-7216 Introduction à l'assimilation de données

Exemple: assimilation de radiances

- Dans ce cas, pour chaque longueur d'onde λ , la radiance $R(\lambda)$ mesurée au sommet de l'atmosphère est telle que

$$R(\lambda) = \int_0^{\infty} \tau(\lambda; z) T(z) dz$$


- La forme discrétisée de ceci est

$$R(\lambda) = (\tau(z_1)w_1 \quad \tau(z_2)w_2 \quad \dots \quad \tau(z_N)w_N) \begin{pmatrix} T(z_1) \\ T(z_2) \\ \vdots \\ T(z_N) \end{pmatrix} \equiv \mathbf{HT}$$

- Programme SCA7216_radiances.sce illustre l'assimilation de quatre radiances à différentes longueur d'ondes prises individuellement ou ensemble

SCA-7216 Introduction à l'assimilation de données

Assimilation de quatre radiances pour quatre longueurs d'onde différentes



SCA-7216 Introduction à l'assimilation de données

Hypothèses utilisées dans la dérivation

- Linéarisation des opérateurs H** intervient
- Hypothèses sur les statistiques d'erreur**
 $\langle \varepsilon_b \varepsilon_o^T \rangle = 0$; $\langle \varepsilon_b \rangle = \langle \varepsilon_o \rangle = 0$
- Généralisation aux estimateurs donnant l'état le plus probable.**
- Implications et exemples:**
 → Daley (1991) ch.4, sections 4.5 et 4.6
- Historique de l'assimilation de données**
 → Daley (1991): chapitre 1