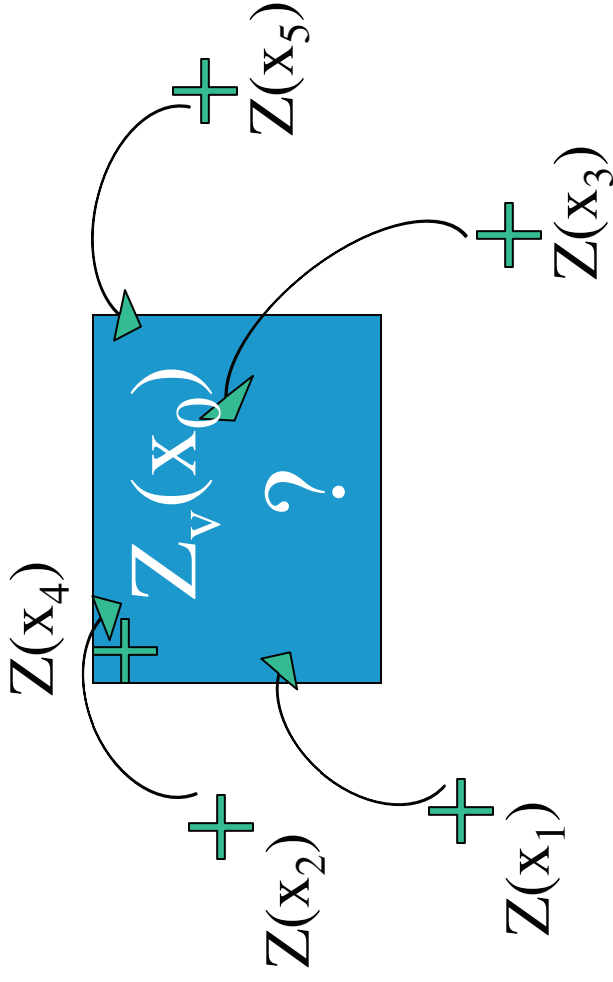


Variance d'estimation et Krigage

Hiver 2006

Variance d'estimation



$$Z_v^* = \sum_{i=1}^n \lambda_i Z_i$$

$$e = Z_v - Z_v^*$$

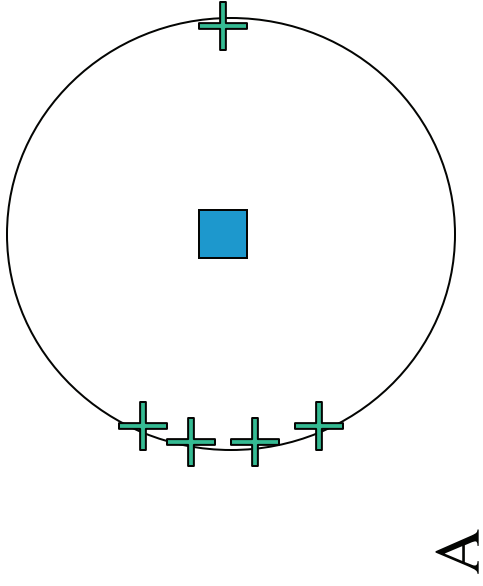
$$\text{Var. d'estimation} = \text{Var}(e)$$

$$\text{Var}(e) = \text{Var}(Z_v) + \text{Var}(Z_v^*) - 2\text{Cov}(Z_v, Z_v^*)$$


$$\sigma_e^2 = \underbrace{\text{Var}(Z_v)}_a + \underbrace{\sum_i \sum_j \lambda_i \lambda_j \text{Cov}(Z_i, Z_j)}_b - 2 \underbrace{\sum_i \lambda_i \text{Cov}(Z_i, Z_v)}_c$$

- a) Ce que l'on cherche à estimer est-il foncièrement variable ou non ?
- b) Quel est le degré de redondance entre les observations ?
- c) Les observations sont-elles bien placées par rapport à ce que l'on veut estimer ?

Exemple



vs




a) Le bloc à estimer est le même

b) **La redondance est beaucoup plus forte en A**

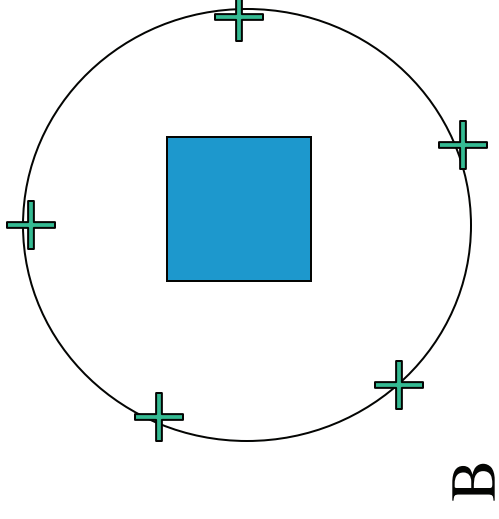
c) La position par rapport au bloc est la même

$\text{Var}(e) + \text{grande en A}$

Exemple



vs



a) **Le bloc à estimer en B est moins variable**


b) La redondance est la même

c) La position par rapport au bloc est


légèrement + favorable en B

Var(e) + grande en A

Exemple



vs



a) Le bloc à estimer est le même

b) La redondance est un peu plus forte en B

c) La position par rapport au bloc est plus favorable en B


Var(e) + grande en A

En terme du variogramme


$$\sigma_e^2 = \text{Var}(Z_v) + \sum_i \sum_j \lambda_i \lambda_j \text{Cov}(Z_i, Z_j) - 2 \sum_i \lambda_i \text{Cov}(Z_i, Z_v)$$

Si $\sum \lambda_i = 1$ (comme c'est le cas pour la plupart des estimateurs)

$$\sigma_e^2 = -\bar{\gamma}(v, v) - \sum_i \sum_j \lambda_i \lambda_j \gamma(x_i, x_j) + 2 \sum_i \lambda_i \bar{\gamma}(x_i, v)$$




On peut calculer $\text{Var}(e)$ dès que l'on connaît le variogramme
Il n'est pas nécessaire que le variogramme montre un palier





$\text{Var}(e)$ ne dépend pas des valeurs observées, il ne dépend que de la géométrie du problème et du variogramme

Interprétation de $\text{Var}(e)$


- Ne dépend pas des valeurs => mesure non-conditionnelle
- Représente la variance des erreurs que l'on obtiendrait si l'on faisait glisser le bloc et la configuration de données sur un domaine très grand




Exemple




Je me sens tout chose




Sphérique isotrope, $C_0=0$, $C=2568$ $a=25.95$




Variogramme sphérique, C0=10, C=40, ax=100 ay=25; zone 300 x 300




100 observations, 3 patrons, lequel procure la plus grande précision pour l'estimation globale ?



$$\sigma^2 = 0.24$$



$$\sigma^2 = 0.36$$



$$\sigma^2 = 0.19$$

Krigeage ordinaire

Dans le krigeage ordinaire l'estimateur prend alors la forme :

$$Z_v^* = \sum_{i=1}^n \lambda_i Z_i$$

Pour que l'estimateur soit sans biais, il faut imposer la contrainte :

$$\sum_{i=1}^n \lambda_i = 1$$

On a un problème de minimisation sous contrainte => méthode de Lagrange, i.e. on forme le lagrangien.

$$\begin{aligned}
 L(\lambda, \mu) &= \sigma_e^2 + 2\mu \left(\sum_{i=1}^n \lambda_i - 1 \right) \\
 &= \text{Var}[Z_v] + \sum_{i=1}^n \sum_{j=1}^n \lambda_i \lambda_j \text{Cov}[Z_i, Z_j] - 2 \sum_{i=1}^n \lambda_i \text{Cov}[Z_v, Z_i] + 2\mu \left(\sum_{i=1}^n \lambda_i - 1 \right)
 \end{aligned}$$

Poser les dérivées partielles par rapport à λ et μ égales à zéro => système linéaire de $n+1$ équations à $n+1$ inconnues

$$\sum_{j=1}^n \lambda_j \text{Cov}[Z_i, Z_j] + \mu = \text{Cov}[Z_v, Z_i] \quad \forall i = 1 \dots n$$

$$\sum_{j=1}^n \lambda_j = 1$$

À l'optimum, la variance d'estimation est :

$$\sigma_{k_0}^2 = \text{Var}[Z_v] - \sum_{i=1}^n \lambda_i \text{Cov}[Z_v, Z_i] - \mu$$

Sous forme matricielle :


$$K_0 \lambda_0 = k_0$$

$$\sigma_{k_0}^2 = \sigma_v^2 - \lambda_0' k_0$$

$$\begin{bmatrix} \sigma^2 & \text{Cov}(Z_1, Z_2) & \bullet & \text{Cov}(Z_1, Z_n) & 1 \\ \text{Cov}(Z_2, Z_1) & \sigma^2 & \bullet & \text{Cov}(Z_2, Z_n) & 1 \\ \bullet & \bullet & \bullet & \bullet & \bullet \\ \text{Cov}(Z_n, Z_1) & \text{Cov}(Z_n, Z_2) & \bullet & \sigma^2 & 1 \\ 1 & 1 & \bullet & 1 & 0 \end{bmatrix} = \underbrace{\begin{bmatrix} \lambda_1 \\ \lambda_2 \\ \bullet \\ \lambda_n \\ \mu \end{bmatrix}}_{\lambda_0} \underbrace{\begin{bmatrix} \text{Cov}(Z_1, Z_v) \\ \text{Cov}(Z_2, Z_v) \\ \bullet \\ \text{Cov}(Z_n, Z_v) \\ 1 \end{bmatrix}}_{\mathbf{k}_0}$$


Le krigeage permet d'estimer directement un bloc (Z_v) ou un point (Z_0)
 Tout ce qui change c'est le membre de droite \mathbf{k}_0 .

Le krigeage d'un bloc est égal à la moyenne des krigeages ponctuels dans le bloc.

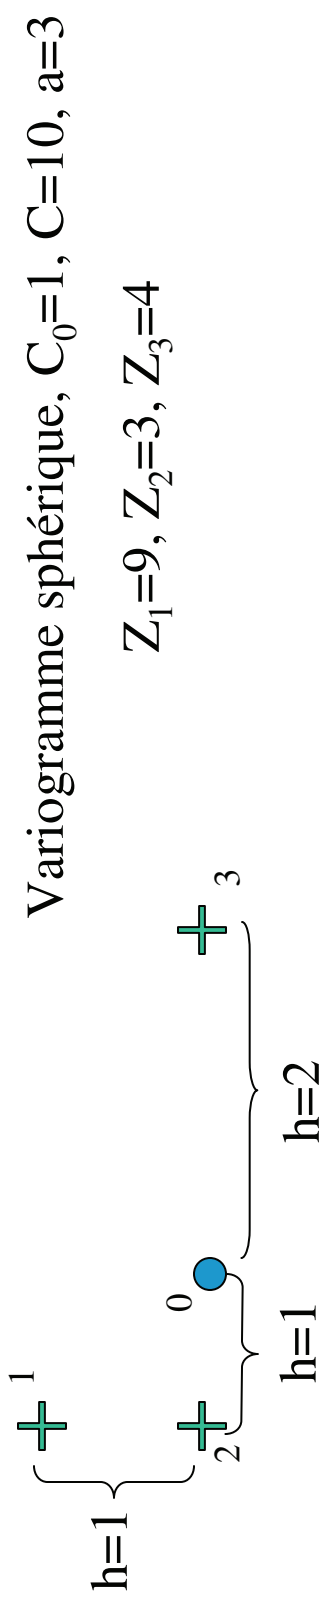


On a toujours :

$$\sigma_{k_0}^2 \geq \sigma_{k_s}^2$$



Exemple numérique détaillé



| | X0 | X1 | X2 | X3 |
|----|-----|-----|----|-----|
| x0 | 0 | 1.4 | 1 | 2 |
| x1 | 1.4 | 0 | 1 | 3.2 |
| x2 | 1 | 1 | 0 | 3 |
| x3 | 2 | 3.2 | 3 | 0 |

| | X0 | X1 | X2 | X3 |
|----|------|------|------|------|
| x0 | 0 | 7.55 | 5.81 | 9.52 |
| x1 | 7.55 | 0 | 5.81 | 11 |
| x2 | 5.81 | 5.81 | 0 | 11 |
| x3 | 9.52 | 11 | 11 | 0 |

h



$\gamma(h)$

| | X0 | X1 | X2 | X3 |
|----|------|------|------|------|
| X0 | 11 | 3.45 | 5.19 | 1.48 |
| X1 | 3.45 | 11 | 5.19 | 0 |
| X2 | 5.19 | 5.19 | 11 | 0 |
| x3 | 1.48 | 0 | 0 | 11 |

C(h)

$$\begin{bmatrix} 11 & 5.19 & 0 & 1 \\ 5.19 & 11 & 0 & 1 \\ 0 & 0 & 11 & 1 \\ 1 & 1 & 1 & 0 \end{bmatrix} = \begin{bmatrix} \lambda_1 \\ \lambda_2 \\ \lambda_3 \\ \mu \end{bmatrix} \begin{bmatrix} 3.45 \\ 5.19 \\ 1.48 \\ 1 \end{bmatrix}$$

$$\begin{bmatrix} \lambda_1 \\ \lambda_2 \\ \lambda_3 \\ \mu \end{bmatrix} = \begin{bmatrix} .21 \\ .51 \\ .28 \\ -1.55 \end{bmatrix}$$



$$Z_0^* = \sum \lambda_i Z_i = (.21)*9 + (.51)*3 + (.28)*4 = 4.54$$

$$\begin{aligned} \sigma_{k_0}^2 &= \sigma^2 - \lambda' k_0 \\ &= 11 - 0.21*3.45 - 0.51*5.19 - 0.28*1.48 - (-1.55)*1 \\ &= 8.76 \end{aligned}$$



Propriétés du krigage

- i. Linéaire, sans biais, à variance minimale, par construction.
- ii. Interpolateur exact
- iii. Effet d'écran
- iv. Tient compte de la taille du champ à estimer et de la position des points entre eux.
- v. Tient compte de la continuité spatiale du phénomène étudié
- vi. Effet de lissage
- vii. Presque sans biais conditionnel.
- viii. Transitif (cohérence des estimés)

Interpolateur exact





En présence d'effet de pépité, les valeurs interpolées sont discontinues => éviter d'estimer un point observé



Pépité + Sphérique(.75, a=10)

Pépité pur


Exemple







En décalant d'un epsilon la grille d'interpolation, on évite les discontinuités sur la carte interpolée



Effet d'écran

Variogramme sphérique; $C=100$, $a=100$, $C_0=0$






Tient compte de la redondance des données




Tient compte de la continuité spatiale



Effet de
pépite



Portée





Influence d'anisotropies



Var. anisotrope

Influence du modèle









| | λ_1 | λ_2 | λ_3 | σ_k^2 |
|-----------------------------------|-------------|-------------|-------------|--------------|
| Sphérique, C=100, a=100 | -.02 | -.01 | .29 | 28.0 |
| Sphérique, C=150, a=150 | -.01 | -.01 | .29 | 27.8 |
| Exp. C=150, a _{eff} =290 | -.01 | -.01 | .28 | 28.2 |
| Linéaire, pente=1 | -.01 | -.01 | .28 | 27.6 |

4 ajustements équivalents
h < 30



=> mêmes poids λ

=> même σ_k^2

Exemples



Le krigage est transitif



À droite, à $x=10$, on observe une donnée égale à la valeur krigée à gauche. Toutes les valeurs krigées demeurent inchangées. Seules les variances de krigage sont réduites.