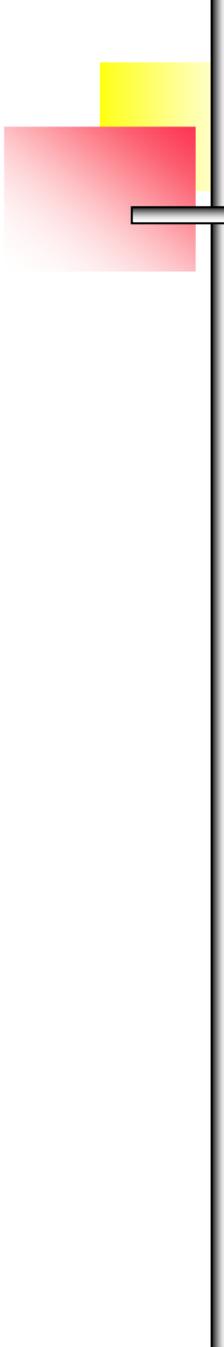


Enlever les valeurs extrêmes de concentration: pour quoi faire?

Jacques.Rivoirard@ensmp.fr

CG Fontainebleau

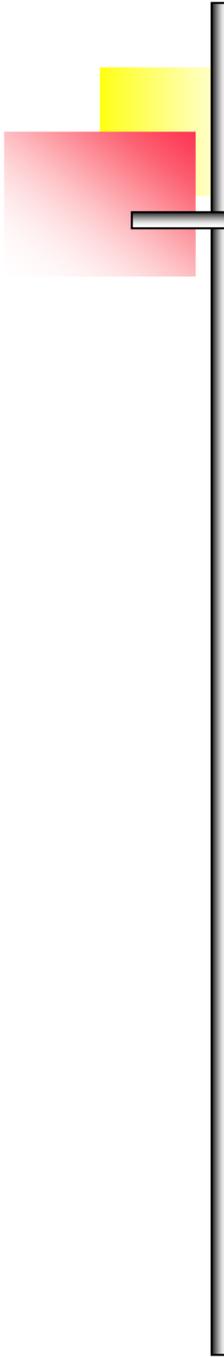
Journées de Géostatistique 18-19 Septembre 2003



Les valeurs extrêmes de concentration (métaux précieux, poisson, pollution...)

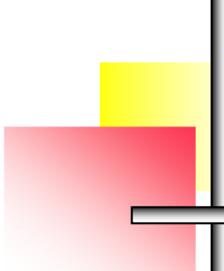
- un problème *extrêmement* sérieux, vue l'importance des valeurs extrêmes en abondance globale ou en dépassement de seuil

... mais forte instabilité des statistiques et des outils
- Besoin de méthodes adéquates, avec hypothèses mesurées (développements en cours pour or et poisson)



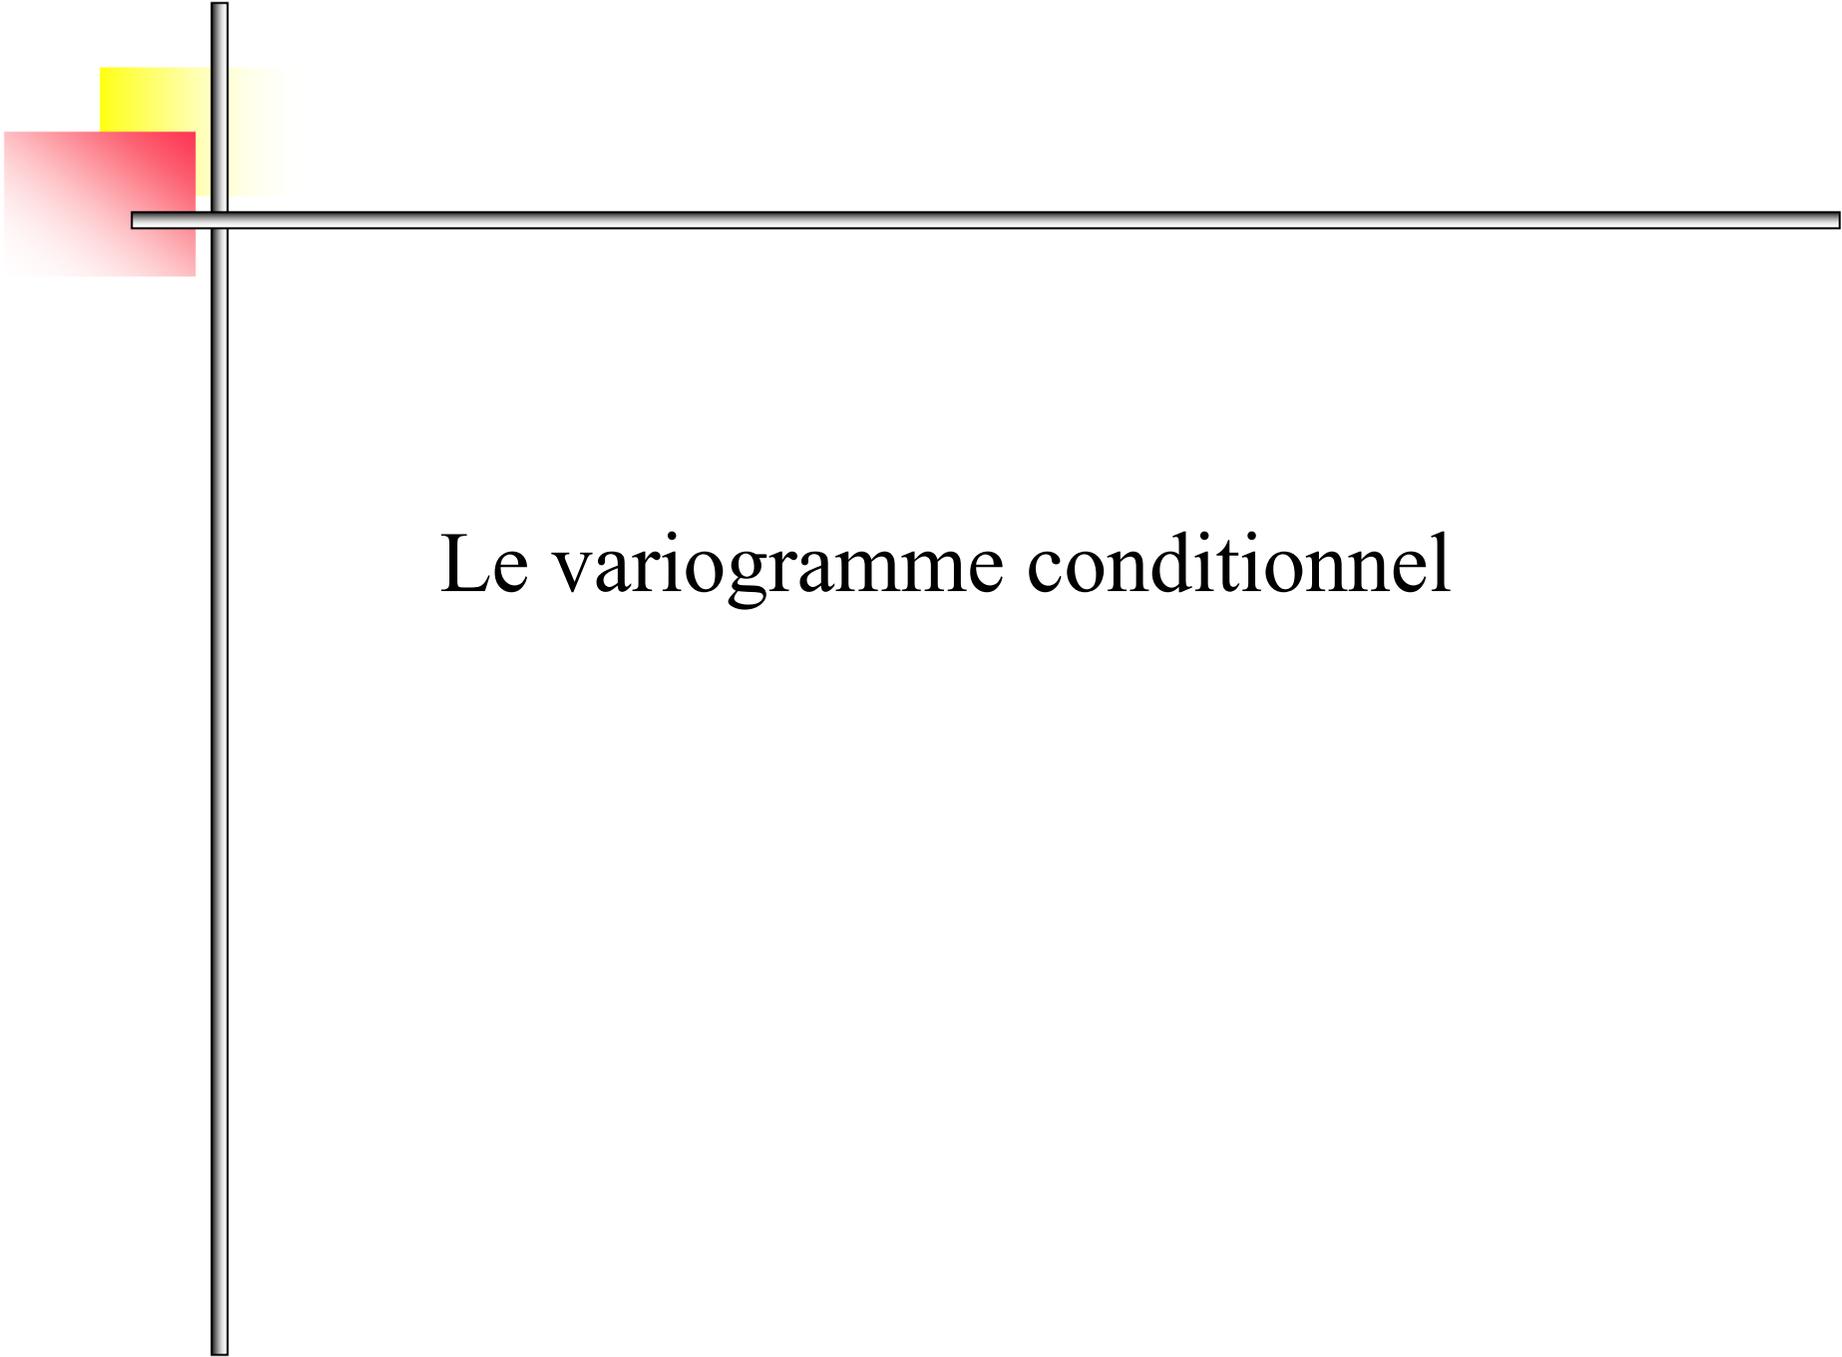
Une « technique » très répandue: la suppression des valeurs extrêmes

- ... notamment du variogramme, pour calculer une « structure »
... laquelle pourra servir à un krigeage... excluant ou non les valeurs extrêmes
- Problème abordé ici: que peut-on dire d'une telle technique de façon « théorique »?
est-il possible de construire des modèles géostatistiques qui la légitiment?
par exemple dans lesquels le variogramme « entier » est identique au variogramme sans extrêmes, ou s'en déduit simplement (ex: addition de pépité)



Hypothèses de base

- seront considérées comme valeurs extrêmes: les valeurs au-dessus d'un seuil z donné, supposées peu fréquentes et beaucoup plus fortes que les autres
- ces valeurs extrêmes ne sont pas des valeurs erronées
- a priori elles peuvent se trouver n'importe où dans le champ étudié
- on ignore les incertitudes sur le variogramme calculé sans les extrêmes: celui-ci est supposé parfaitement connu

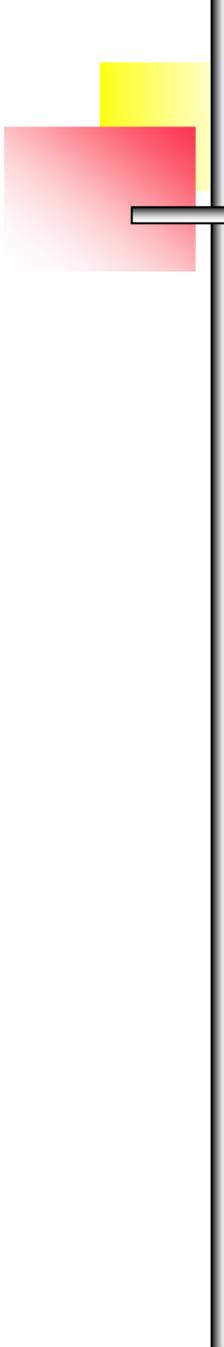


Le variogramme conditionnel

Le variogramme conditionnel, en théorie...

$$\gamma_{-z}(h) = \frac{1}{2} E \left[(Z(x+h) - Z(x))^2 \mid Z(x) < z, Z(x+h) < z \right]$$

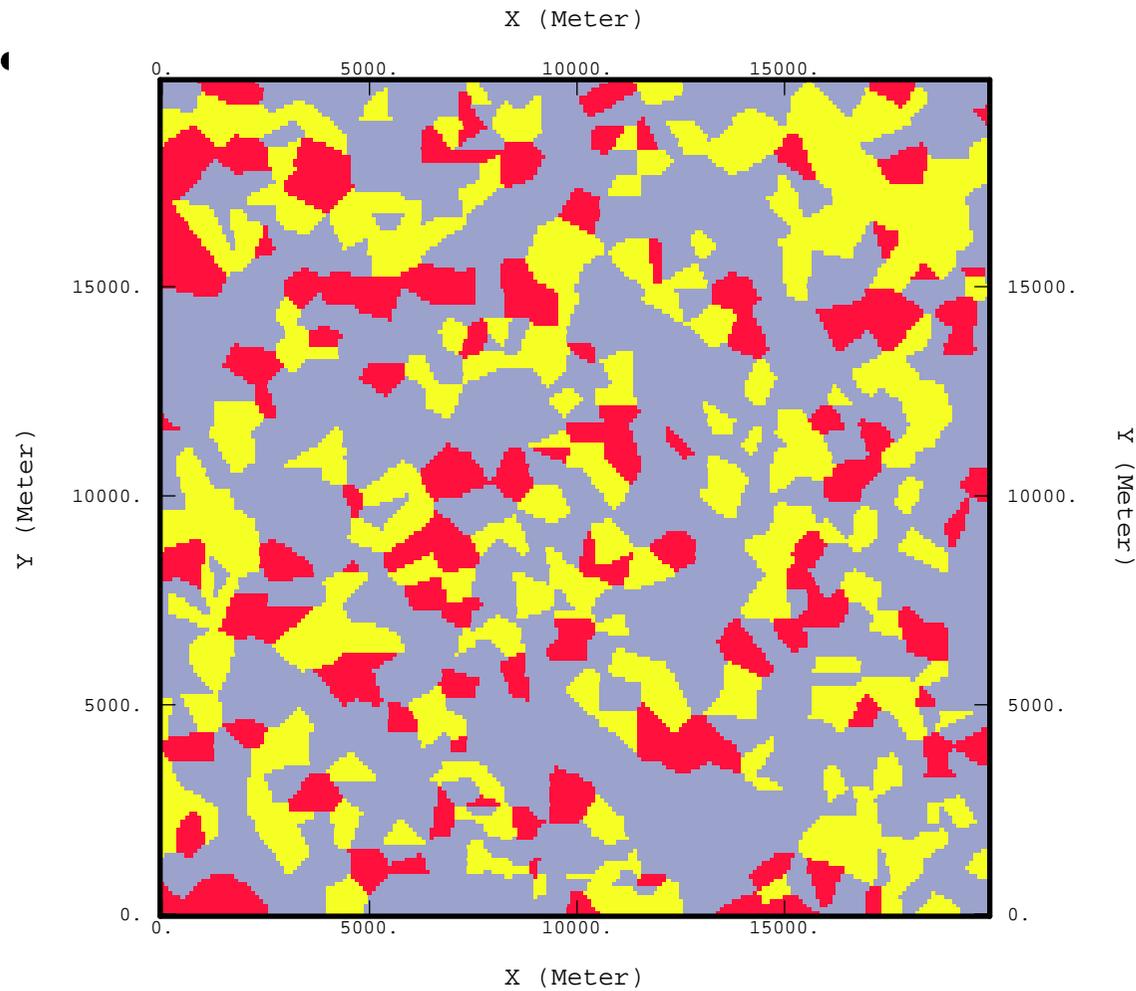
- est-ce nécessairement une fonction de type variogramme (conditionnellement définie négative)?
- Lien avec $\gamma(h) = \frac{1}{2} E \left[(Z(x+h) - Z(x))^2 \right]$
théoriquement possible connaissant les lois bivariées $(Z(x), Z(x+h))$ (géostat non-linéaire, lourde en hypothèses!)



Un cas simple: le modèle mosaïque à valuations indépendantes

- Espace partitionné en compartiments
- On value (tous les points de) chaque compartiment indépendamment des autres, et selon la même loi
- Deux points à distance h :
 - appartiennent à un même compartiment (et ont donc la même valeur) avec proba $r(h)$
 - appartiennent à des compartiments différents (et ont donc des valeurs indépendantes, éventuellement égales) avec proba $\gamma(h) = 1 - r(h)$

Modèle mosaïque à valuations indépendantes

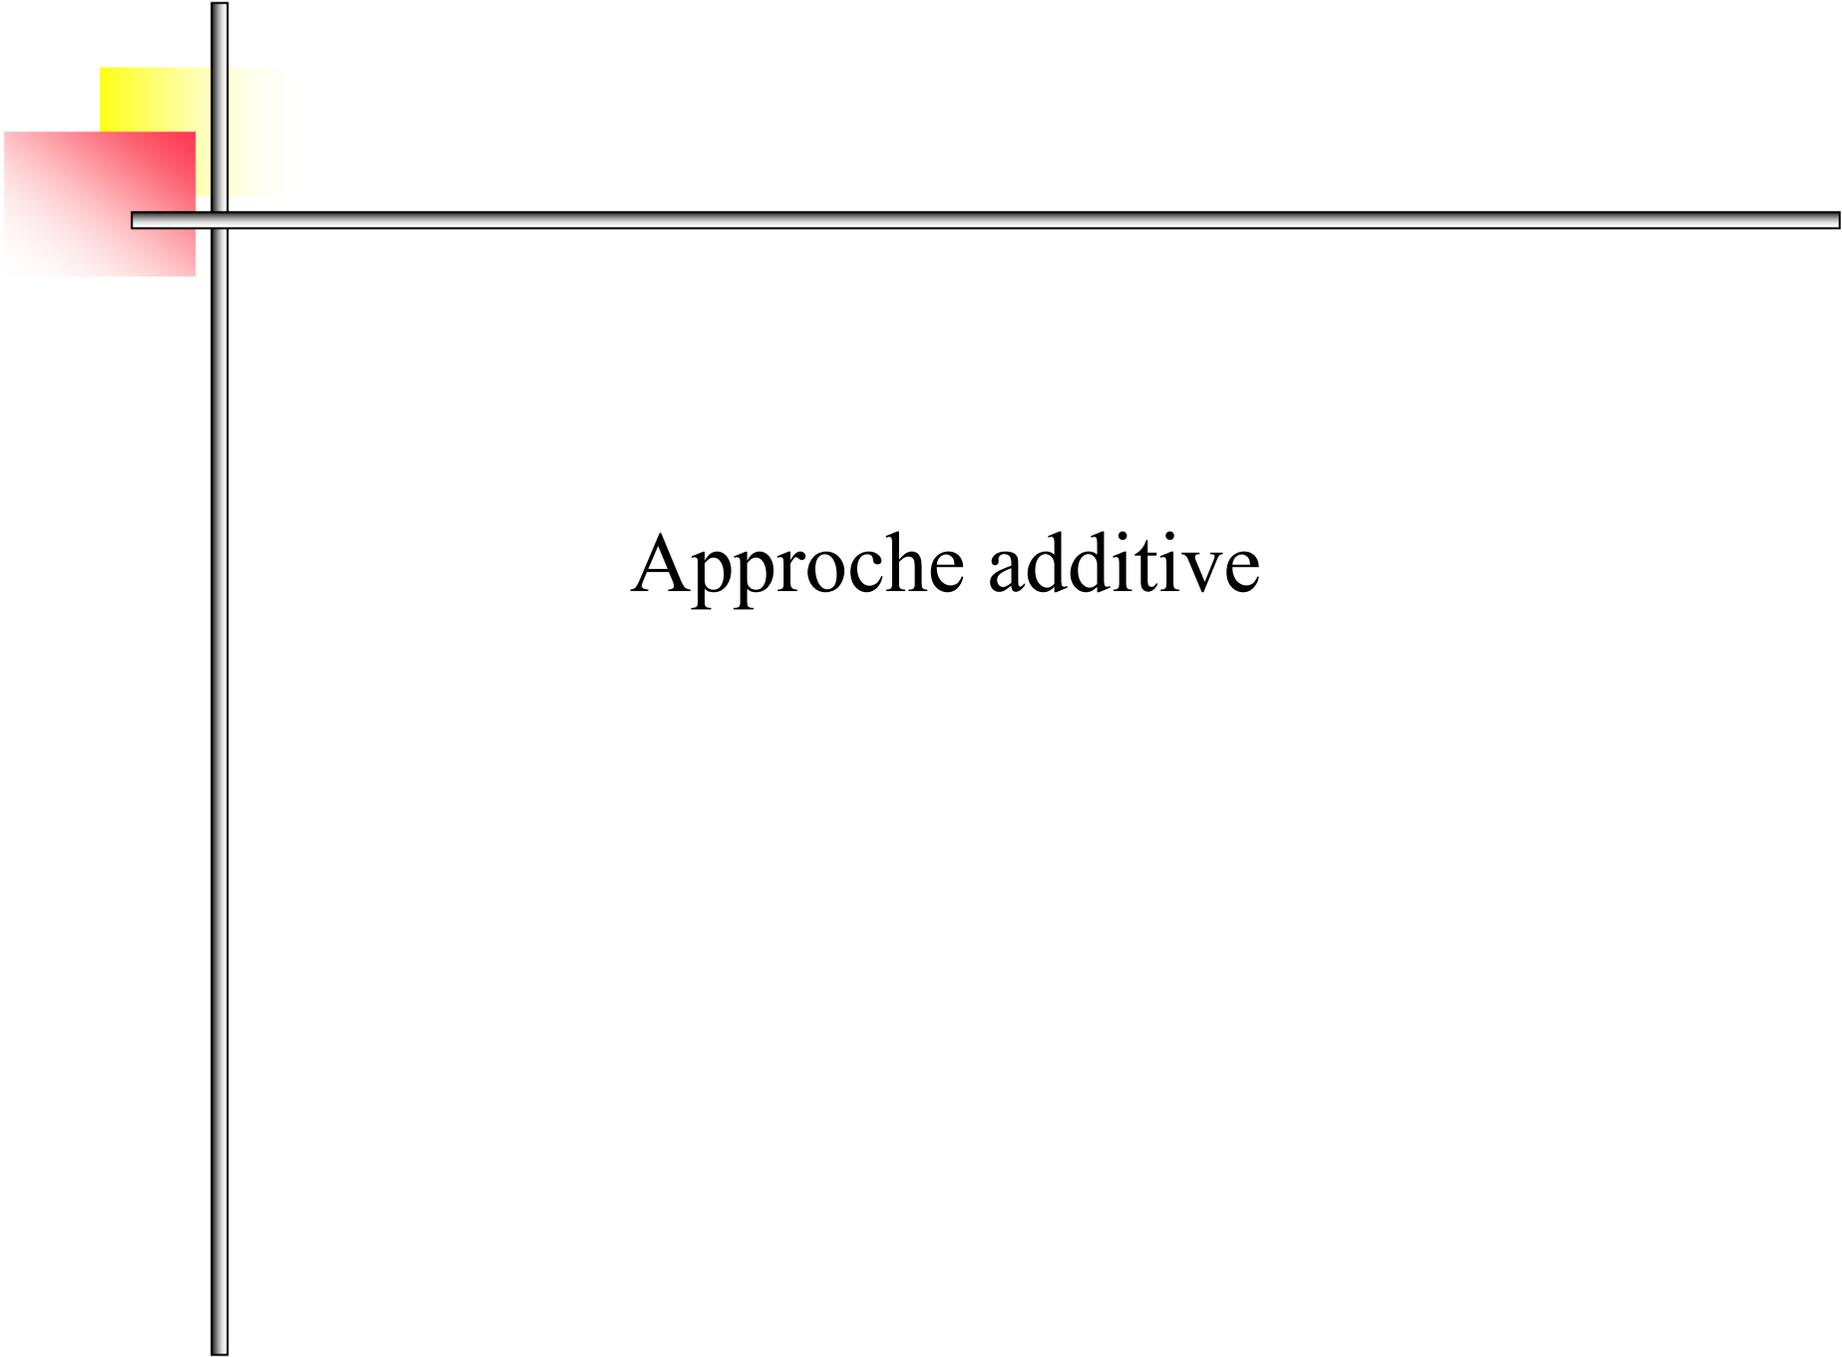


Modèle mosaïque à valuations indépendantes

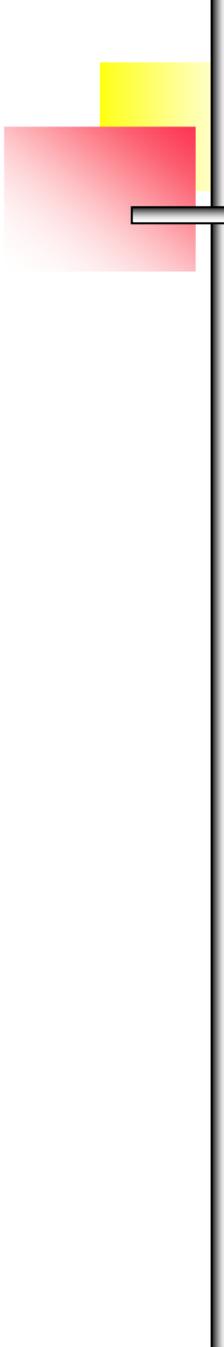
- La variable $Z(x)$, de même que ses transformées, ont toutes une structure identique à $\gamma(h) = 1 - r(h)$
- Cependant le variogramme (?) sans les extrêmes est différent (plus régulier à petites distances, car on chevauche moins souvent les compartiments):

$$\gamma_{-z}(h) = \frac{\text{var}(Z \mid Z < z) P(Z < z) \gamma(h)}{1 - [1 - P(Z < z)] \gamma(h)}$$

$$\gamma(h) = \frac{\gamma_{-z}(h)}{\text{var}(Z \mid Z < z) P(Z < z) + [1 - P(Z < z)] \gamma_{-z}(h)}$$



Approche additive



Approche additive

- L'élimination des fortes valeurs suggère le modèle additif:

$$Z(x) = Z_1(x) + Z_2(x)$$

somme de deux FA ≥ 0 indépendantes:

- fond Z_1 , inférieur au seuil z
- Z_2 responsable du dépassement de seuil
- ce qui permet le calcul de statistiques concernant $Z_1(x)$ à partir des seuls points de S_1 où $Z(x) < z$

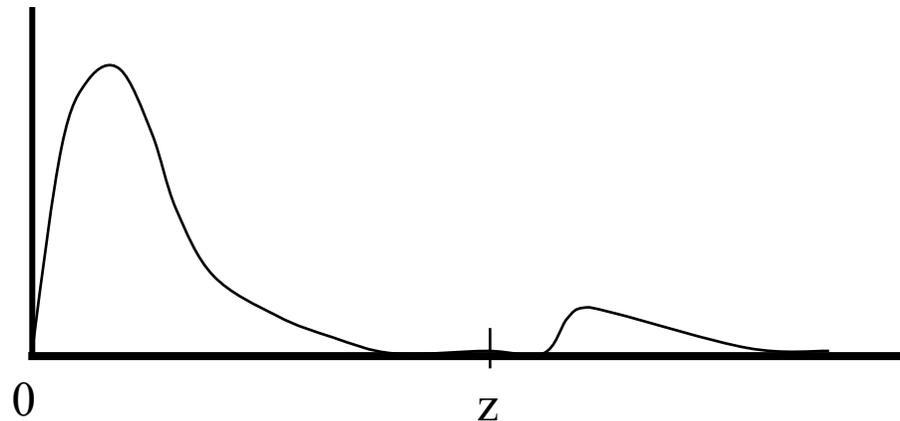
Approche additive: distribution

- $Z_2(x) > 0 \Leftrightarrow Z(x) = Z_1(x) + Z_2(x) \geq z \Leftrightarrow Z_2(x) \geq z - Z_1(x)$

- $Z_1(x)$ et $Z_2(x)$ étant indépendants:

$$Z_2(x) > 0 \Rightarrow Z_2(x) \geq z - \min(Z_1) \geq \max(Z_1) - \min(Z_1)$$

rôle très particulier du seuil dans la distribution de Z (bimodale par ex)



Approche additive: structure

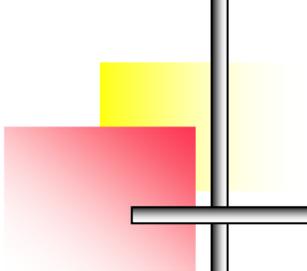
- $Z(x) = Z_1(x) + Z_2(x) \Rightarrow$ Modèle structural simple:

$$\gamma_Z(h) = \gamma_1(h) + \gamma_2(h)$$

$$\gamma_{Z,Z_1}(h) = \gamma_1(h)$$

$$\gamma_{Z,Z_2}(h) = \gamma_2(h)$$

- $\gamma_1(h)$ étant supposé connu: $\gamma_Z(h)$?
 - $\gamma_2(h)$ composante supplémentaire, pépité par ex
 - rescaling si $\gamma_2(h) \equiv \gamma_1(h)$



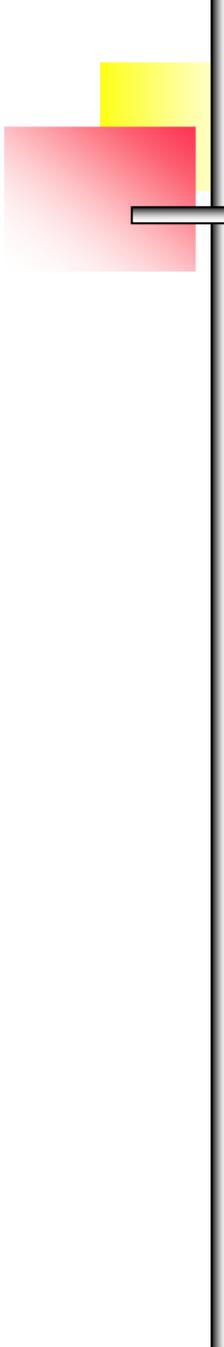
Approche additive: estimation

- $\gamma_Z(h)$

permet calcul de variance et krigeage sur $Z(x)$

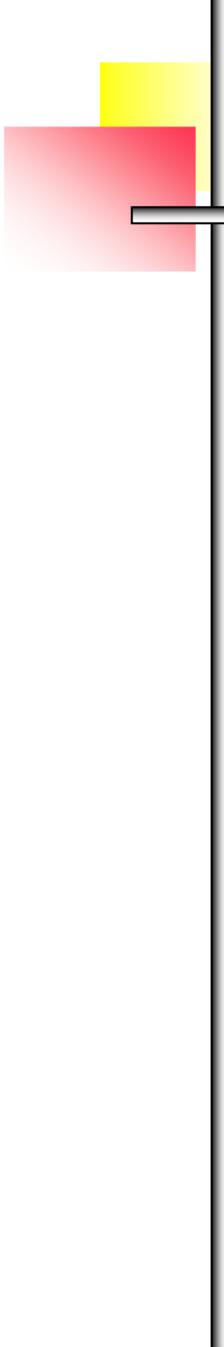
- modèle bivariable permet calcul de variances et cokrigeage à partir des données:
 - $Z_1(x)$ et $Z_2(x)=0$ connus sur S_1
 - $Z(x) = Z_1(x)+Z_2(x)$ connu sur les autres points S_2

(bien que $Z_1(x)$ et $Z_2(x)$ soient indépendantes, leur cokrigeage n'est pas leur krigeage)



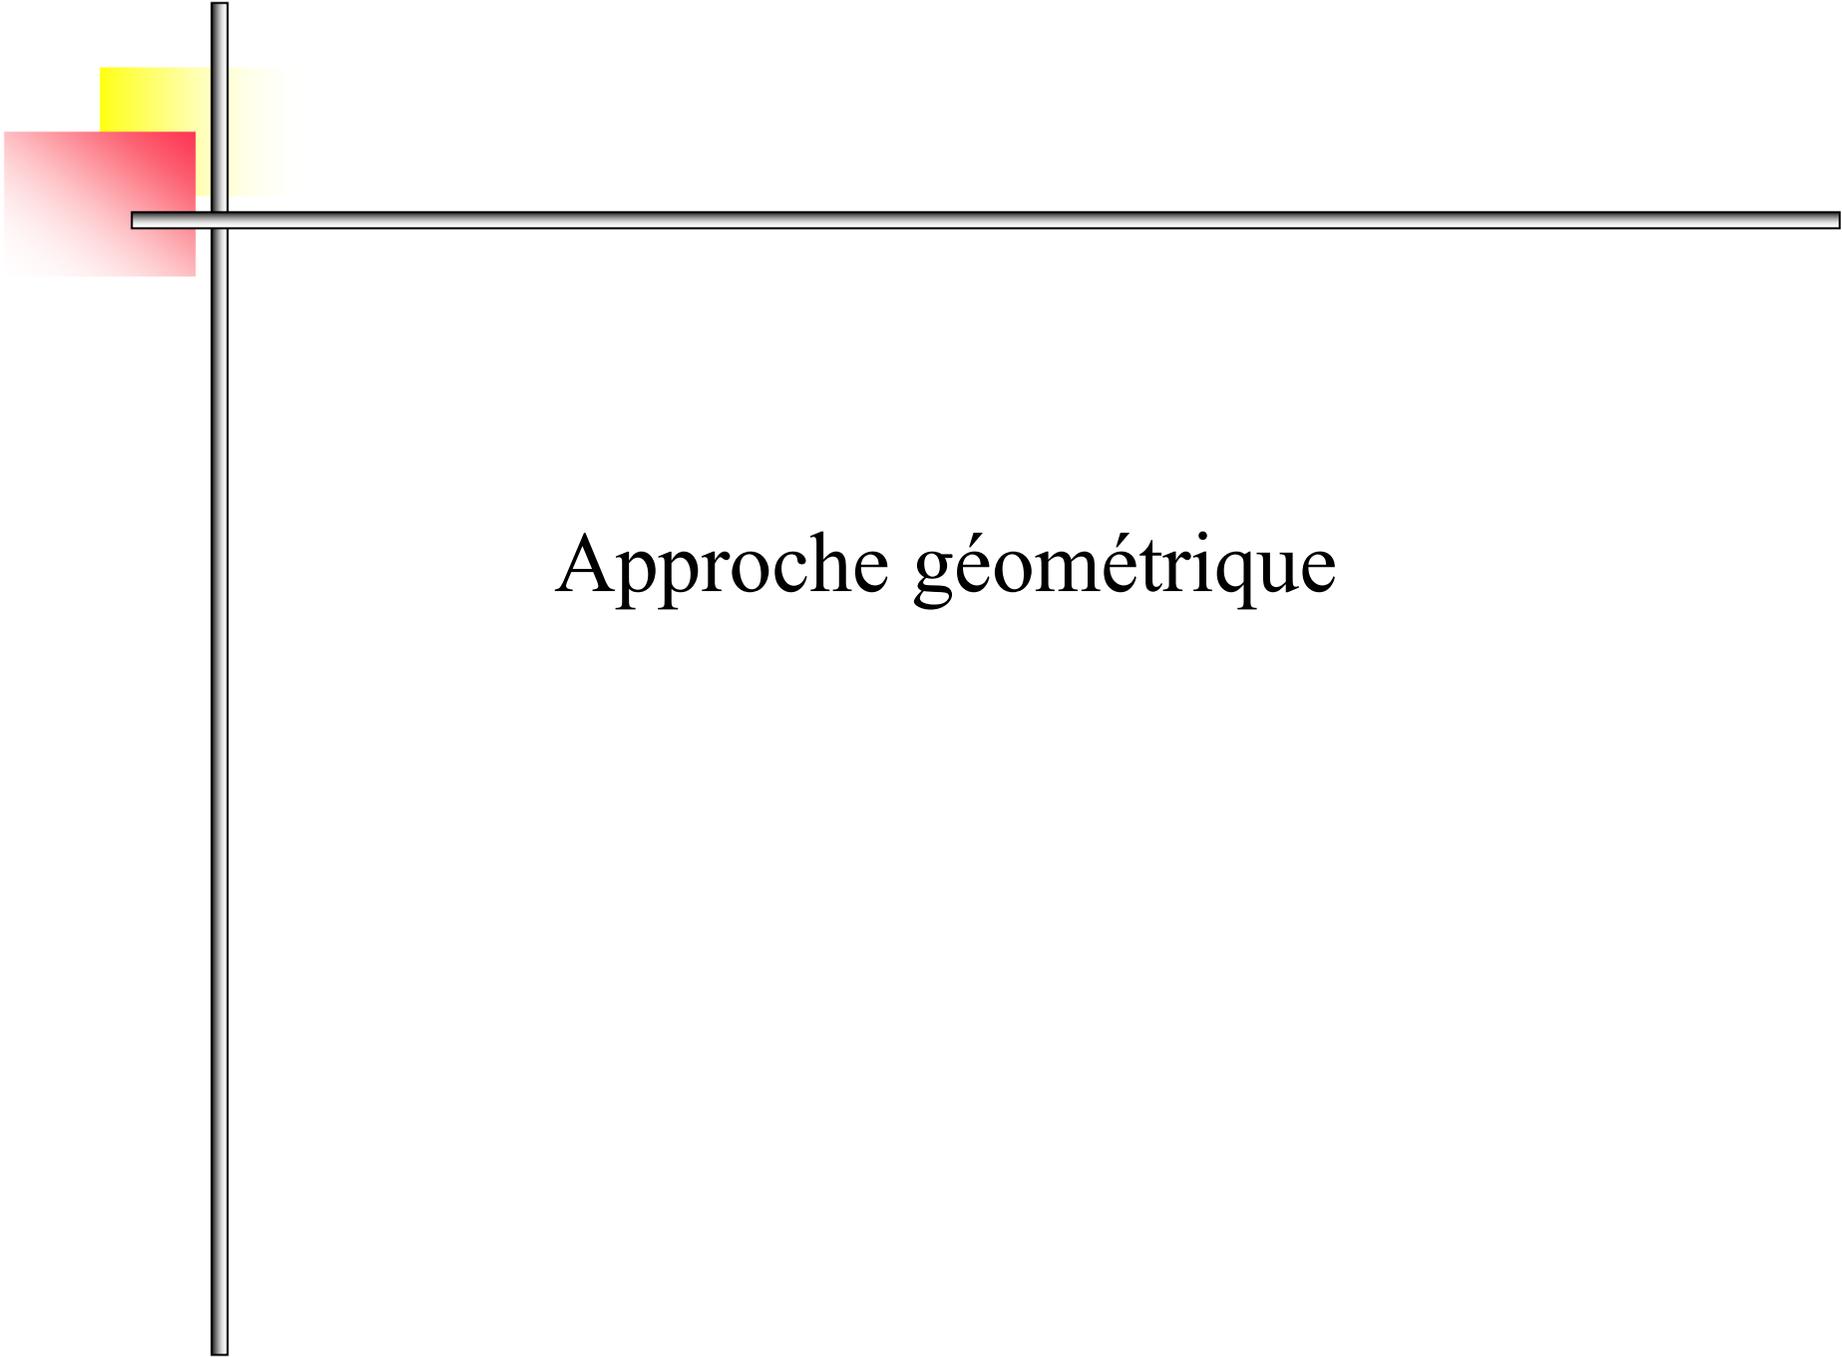
Approche additive: estimation

- Alternative au cokrigage (non optimale, mais privilégiant la structure de Z_1 , la mieux connue):
 - kriger Z_1 , y compris sur S_2 , à partir des seules valeurs non extrêmes $Z=Z_1$ sur S_1
 - en déduire valeurs estimées de $Z_2=Z-Z_1$ sur S_2
 - estimer Z_2 à partir de ces valeurs estimées de Z_2 sur S_2 et des valeurs nulles de Z_2 sur S_1
(saupoudrage uniforme de la moyenne m_2 de Z_2 si celle-ci est pépitique)



Approche additive: conclusions

- intérêt: simplicité du modèle structural et de l'estimation
- inconvénients:
 - hypothèse très particulière sur la distribution de valeurs de Z
 - Z_1 et Z_2 ne sont connus individuellement qu'aux points de données où $Z < z$,
l'estimation ne tient pas explicitement compte du fait que Z_2 est > 0 aux points de données où $Z \geq z$



Approche géométrique

Approche géométrique: base

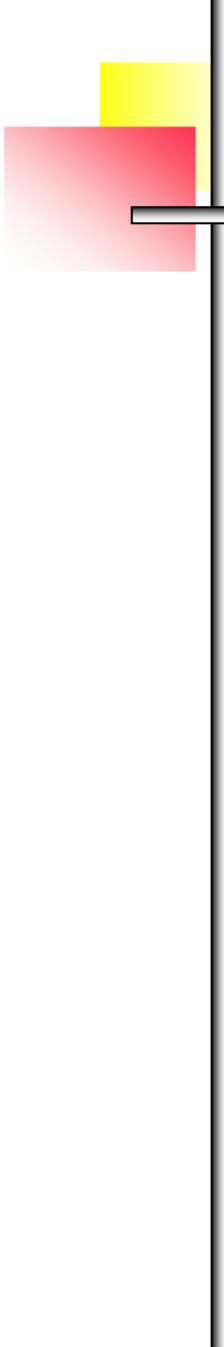
- distinction selon l'appartenance aux ensembles

$$A = A_z = \{x \mid Z(x) \geq z\}$$

$$A^c = A_z^c = \{x \mid Z(x) < z\}$$

par exemple:

$$\begin{aligned} Z(x) &= Z(x)1_{Z(x) < z} + Z(x)1_{Z(x) \geq z} \\ &= Z(x)1_{x \in A^c} + Z(x)1_{x \in A} \end{aligned}$$



Approche géométrique

- Éléments à considérer: structures et relations entre
 - ensemble A des fortes valeurs
 - Z dans A
 - Z dans A^c
 - Z au passage de A^c à A



Approche géométrique: modèle simple

- $$Z(x) = Y_1(x)1_{x \in A^c} + Y_2(x)1_{x \in A}$$

avec $1_{x \in A}$

$Y_1(x)$, *entre 0 et z*

$Y_2(x)$, $\geq z$

indépendants

pouvant faire l'objet d'estimations séparées
(mais hétérotopiques)

- Structure de $Z =$ combinaison des structures des
3 variables

Approche géométrique: modèle simple

si $1_{x \in A}$ et $Y_2(x)$ (supposés) quasi-pépitiques:

- Variogramme $\gamma_Z(h) \equiv \gamma_{-z}(h) [P(Z < z)]^2 + \text{pépité}$

avec $\text{pépité} = \text{var } Z - \text{var}(Z | Z < z) [P(Z < z)]^2$

- Estimation de Y_1 , soit $Z | Z < z$, se complète par saupoudrage de $m_2 = E[Y_2(x)] = E[Z(x) | Z(x) \geq z]$ en proportion $P(Z \geq z)$

Approche géométrique: modèle simple

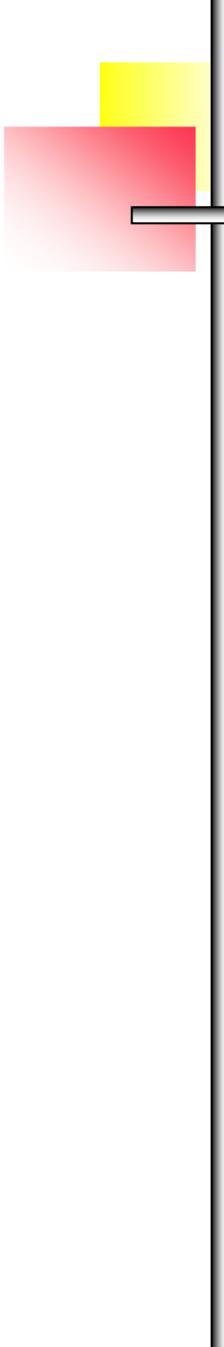
- Un peu plus général (suppose absence d'effets de bord, simples et couplés, de Z dans A et A^c):
factorisation par:

$$1_{Z(x) \geq z} \quad [Z(x) - m_1] 1_{Z(x) < z} \quad [Z(x) - m_2] 1_{Z(x) \geq z}$$

avec $m_1 = E[Z(x) \mid Z(x) < z]$

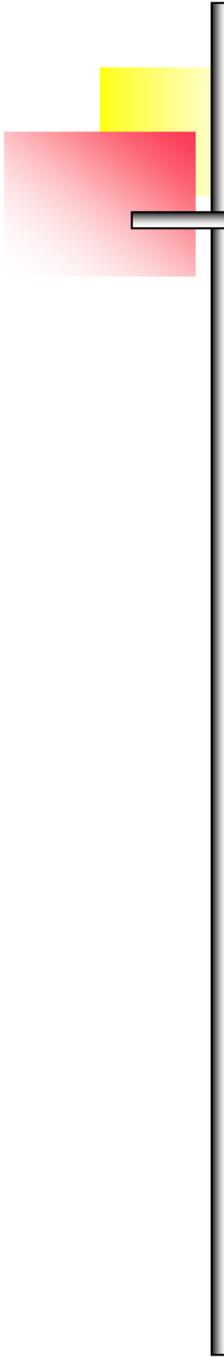
$$m_2 = E[Z(x) \mid Z(x) \geq z]$$

- estimation par krigeage séparé (isotopique) des facteurs



Approche géométrique: modèle simple

- Le modèle simple légitime un krigeage séparé des valeurs de Z inférieures au seuil z
- Il fait jouer un rôle très particulier au seuil: ce qui se passe au-dessus ne dépend pas de ce qui se passe au-dessous. Difficile en particulier d'étendre à un modèle multi-seuil.



Conclusions

- Dans les cas envisagés, la suppression des valeurs extrêmes permet des techniques effectivement simples, mais dans des modèles où le seuil joue un rôle très particulier.
- D'autres approches, plus sophistiquées semblent nécessaires sinon...