

---

# Krigeage d'indicatrice

---

---

# Plan

- Introduction: contexte et problématique
- Cas d'une variable binaire
- Cas d'une distribution seuillée
- Interprétation de la valeur estimée
- Équations du krigeage d'indicatrices
- Corrections d'ordre
- Changements de support
- « Soft kriging »
- Exemples

# Contexte et problématique

Krigeage d'indicatrices : méthode géostatistique non-linéaire =>

cherche à estimer la fonction de distribution conditionnelle en tout point;

par contraste, le krigeage ordinaire n'estime que la moyenne conditionnelle (sauf dans le cas gaussien, *la variance de krigeage n'est pas une variance conditionnelle*).

Exemples :

- Estimation du volume in-situ de sols contaminés; sur un site donné, quel est le volume de sols excédant le critère « C » du MENV ? Quelle quantité totale de contaminants y retrouve-t-on ?
- Dans une mine, quel est le tonnage de minerai (in-situ); quelle est la teneur moyenne ou la quantité de métal contenue dans le minerai?

---

Exemples:

- Dans une mine, la sélection finale des blocs se fait à partir d'estimations qui seront obtenues une fois les données des blocs voisins connues. Peut-on prédire maintenant la proportion des blocs qui seront identifiés plus tard comme du minerai ? Quelle devrait être la teneur de ces blocs sélectionnés sur des estimations futures ?

Note: il y a 3 grandes catégories de méthodes pour répondre à ce genre de questions :

- le krigeage d'indicatrices (et ses variantes multivariées)
- les méthodes gaussiennes (multigaussien)
- le krigeage disjonctif (lois bivariées isofactorielles)  
(note: dans le cours, on ne voit que les 2 premières méthodes)

# Variable binaire

a) Variable binaire (0-1) (ex.  $I(x)=1$  si on a le faciès A au point x et  $I(x)=0$  si l'on a un autre faciès)

Quelle interprétation donner au résultat du krigeage dans ce contexte ?

Soit  $I(x)$  la v.a. binaire au point x.

$$E[I(x)] = P(I(x)=0)*0 + P(I(x)=1)*1 = P(I(x)=1)$$

Si l'on tient compte des observations disponibles:

$$E[I(x)|I(x_1), I(x_2), \dots, I(x_n)] = P(I(x)=1|I(x_1), I(x_2), \dots, I(x_n))$$

---

Pour une variable continue, le krigeage est un bon estimateur de l'espérance conditionnelle, on suppose que ceci demeure vrai pour une indicatrice.

$$I^*(\mathbf{x}) = \sum_{i=1}^n \lambda_i I(\mathbf{x}_i)$$

où les poids sont obtenus par krigeage ordinaire de la variable indicatrice est donc une estimation de  $P(I(\mathbf{x})=1 | I(\mathbf{x}_1), I(\mathbf{x}_2), \dots, I(\mathbf{x}_n))$

$$I^*(\mathbf{x}) \equiv P^*(I(\mathbf{x}) | I(\mathbf{x}_1), I(\mathbf{x}_2), \dots, I(\mathbf{x}_n))$$

# Généralisation: variable continue

Soit  $Z(x)$  une v.a. continue définie au point  $x$  et  $F(x,c)$ , la fonction de répartition de la v.a. au point  $x$  pour la valeur «  $c$  ».

Par définition:  $F(x,c) = P(Z(x) \leq c) = E[I(x,c)]$

où  $I(x,c) = 1$  si  $Z(x) \leq c$

0 si  $Z(x) > c$

Par krigeage ordinaire d'indicatrices, on aura :

$$I^*(x, c) = \sum_{i=1}^n \lambda_i I(x_i, c)$$

---


Cette valeur devrait être un bon (?) estimateur de :

$$\begin{aligned} P(I(x, c) = 1 \mid I(x_1, c), I(x_2, c), \dots, I(x_n, c)) &= \\ P(Z(x) < c \mid I(x_1, c), I(x_2, c), \dots, I(x_n, c)) &= \\ F(x, c \mid I(x_1, c), I(x_2, c), \dots, I(x_n, c)) & \end{aligned}$$

Si l'on choisit une infinité de « c » différents, on aura une estimation de la **fonction de répartition au point « x » conditionnelle** aux indicatrices obtenues aux points échantillons.




# Exemple



Ici, par symétrie, les poids valent tous  $1/4$

c	$F^*(x_0, c,  (n))$
0.5	0
1.5	0.25
2.5	0.25
3.5	0.25
4.5	0.50
5.5	0.75
6.5	0.75
7.5	1.0



---

Que gagne-t-on par rapport à un krigeage ordinaire ?


À quel prix ?

Quels sont les problèmes qui se posent ?


## Que gagne-t-on par rapport à un krigeage ordinaire ?

- **Estimer une probabilité d'excéder un seuil (e.g. en environnement);**
- **estimer un quantile (e.g. valeur ayant 5% de chances d'être dépassée au point  $x_0$ );**
- **calculer une variance conditionnelle, i.e. qui dépend des valeurs locales;**
- **fournir un estimateur qui minimise l'espérance d'une fonction de coût;**
- **+ de flexibilité :**
  - **utiliser des informations du type  $Z(x_i) > t$ ,  $Z(x_i) < t$ ,  $t_2 > Z(x_i) > t_1$ ; des données semi-quantitatives fournies par le géologue (e.g. « dans ce type de roche, la teneur n'excède jamais «  $t$  »)**
  - **les variogrammes peuvent varier d'une indicatrice à l'autre**

## Exemple: les variogrammes peuvent varier d'une indicatrice à l'autre



**Exemple: le krigeage d'indicateurs permet de mieux estimer les quantiles, probabilités, etc. que le krigeage ordinaire**



Réalité

Krigeage ordinaire

Krigeage indicatrice

$$\text{Nb}(Z(x) > 200) = 1453$$

$$\text{Nb}(Z(x)^* > 200) = 561$$

**sous-estimation de 61% !**

$$\sum_x I^*(x,200) = 1655$$

sur-estimation de 12%

## À quel prix ?

- **Fonction de répartition représentée sous forme discrète : combien de seuils ? (en pratique souvent de 5 à 10 seuils)**
- **Chaque seuil => v. indicatrice différente => variogramme => krigeage d'indicatrice => effort ++ important; possibilité d'incohérences dans la modélisation.**
- **Chaque indicatrice doit être stationnaire => fonction de répartition stationnaire, (hypothèse + forte que pour le krigeage).**
- **On a réduit l'ensemble conditionnant à  $\{ I(x_1,c), I(x_2,c)\dots I(x_n,c) \}$  au lieu de  $\{ Z(x_1), Z(x_2)\dots Z(x_n) \}$  => certaine perte d'information ?**

## Quels sont les problèmes qui se posent ?

- **Problème de relation d'ordre:**
  - valeurs de  $I^*(x_0, c_i)$  peuvent être  $>1$  ou  $<0$ ;
  - $I^*(x_0, c_i) > I^*(x_0, c_j)$  quand  $c_i < c_j$
- **Variogrammes d'indicateurs sont souvent + faciles à modéliser (il n'y a pas de données extrêmes, que des 0 ou des 1) mais souvent la structure spatiale est faible => manque de précision dans les estimations de  $I^*$**
- **Comment interpoler entre les valeurs de  $I^*(x_0, c_i)$  ? Comment extrapoler au-delà de  $c_{min}$  et  $c_{max}$  ?**
- **Que faire si l'estimation doit porter sur des blocs ? Ex.:  $P^*(Zv(x) > c | (n))$**

# Problème de relation d'ordre

- **Problème de relation d'ordre:**

-  $I^{**}(x_0, c_i) = \max(0, I^*(x_0, c_i))$

-  $I^{**}(x_0, c_i) = \min(1, I^*(x_0, c_i))$

- **Correction avant,**

$$-I^*_{\text{avant}}(x_0, c_{i+1}) = \max(I^*(x_0, c_i), I^*(x_0, c_{i+1}))$$

-**Correction arrière,**

$$- I^*_{\text{arr}}(x_0, c_i) = \min(I^*(x_0, c_i), I^*(x_0, c_{i+1}))$$

$$-I^*(x_0, c_i) = 0.5 * [I^*_{\text{avant}}(x_0, c_{i+1}) + I^*_{\text{arr}}(x_0, c_i) ]$$



# Exemple

seuil c	$F_{KI}(x_0, c)$	$F_{KI,avant}(x_0, c)$	$F_{KI,arr}(x_0, c)$	$F_{KI,corr}(X_0, c)$
1	-.01 --> 0	0	0	0
2	0.13	0.13	0.13	0.13
3	0.24	0.24	0.234	0.237
4	0.238	0.24	0.234	0.237
5	0.234	0.24	0.234	0.237
6	0.237	0.24	0.237	0.2385
7	0.53	0.53	0.53	0.53
8	0.79	0.79	0.77	0.78
9	0.77	0.79	0.77	0.78
10	1.02 -> 1.0	1	1	1


# Structure spatiale plus faible

**Exemple : cas gaussien**

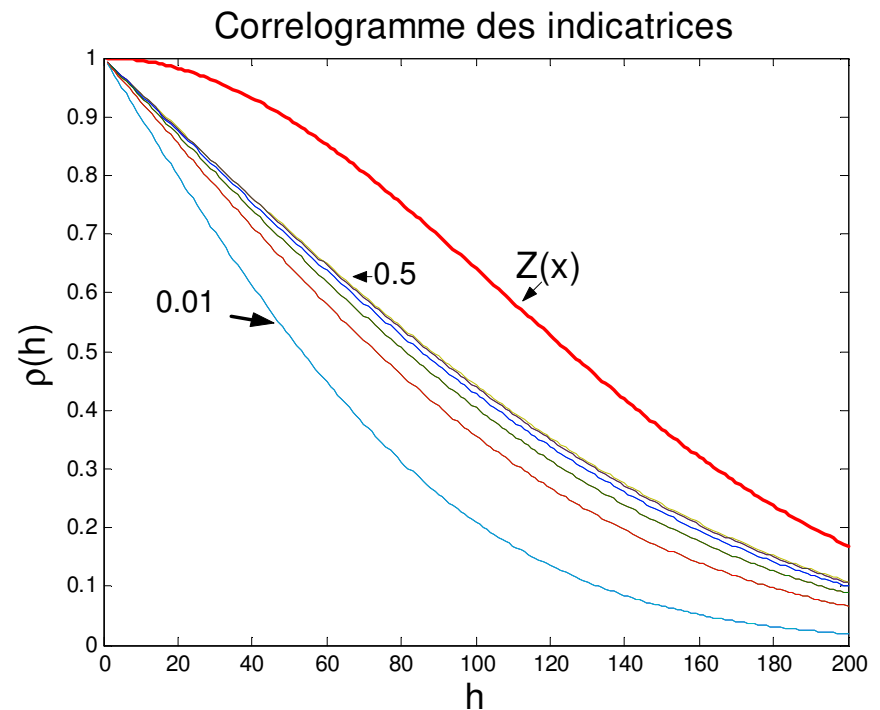
**Si  $Z(x)$  est bigaussien  $(0,1)$ , on connaît la relation entre  $\gamma_Z(h)$  et  $\gamma_I(h, c)$**

$$C_I(h, c) = \frac{1}{2\pi} \int_0^{\rho(h)} \exp\left(-\frac{c^2}{1+u}\right) \frac{1}{\sqrt{1-u^2}} du$$

**ou  $\rho(h)$  est le corrélogramme de  $Z(x)$**

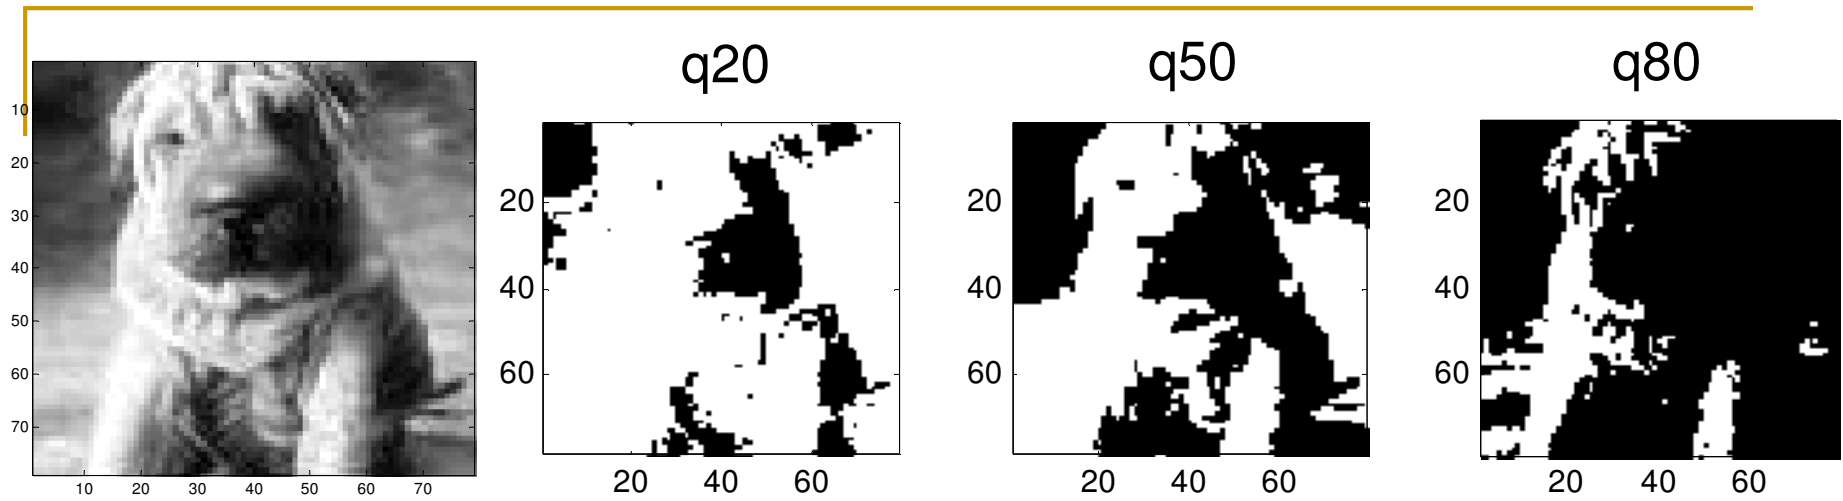


$Z(x)$  : modèle sphérique




$Z(x)$  : modèle gaussien

- Plus le seuil « c » est éloigné de la médiane moins il y a de structure
- Variogrammes des indicatrices est linéaire à l'origine même si  $Z(x)$  est parabolique à l'origine => proscrire le modèle gaussien pour les indicatrices




Corrélogrammes de  $Z(x)$  et  $I(x)$



# Interpolation entre les valeurs de $I^*(x_i, c_j)$ ?

Linéaire, sauf possiblement la dernière classe



# Que faire si l'estimation doit porter sur des blocs ?


Reconnaître que:

$$P(Z_v(x) > c) \neq P(Z(x) > c)$$

$$P(Z_v(x) > c) \neq \frac{1}{v} \int_{v(x)} P(Z(y) > c) dy$$

$$P(Z_v(x) > c) = 1$$

$$\frac{1}{v} \int_{v(x)} P(Z(y) > c) dy \approx 0$$



- $Z(x) = 1e6 \ c$
- $Z(x) = 0.9 \ c$

---

Solutions ?

Plusieurs propositions, dont:

- correction affine
- correction indirecte lognormale

*aucune n'est entièrement convaincante*

Tendance actuelle: recourir à des simulations!

## Exemple: correction affine

$$F_v(Z_v) = F \left( (Z - m) \left\{ \frac{D^2(v | G)}{D^2(\bullet | G)} \right\}^{0.5} + m \right)$$

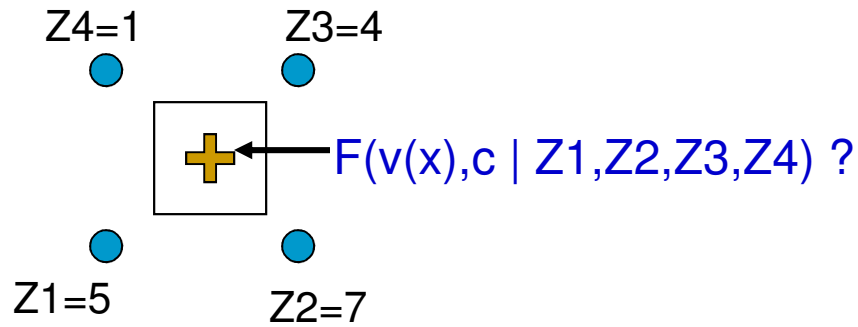
$m$  est la moyenne de la distribution locale estimée par KI

$F$  est la fonction de répartition locale estimée par KI (i.e.  $I^*(x,c)$  après corrections pour relations d'ordre)

$F_v$  est la fonction de répartition « de blocs »

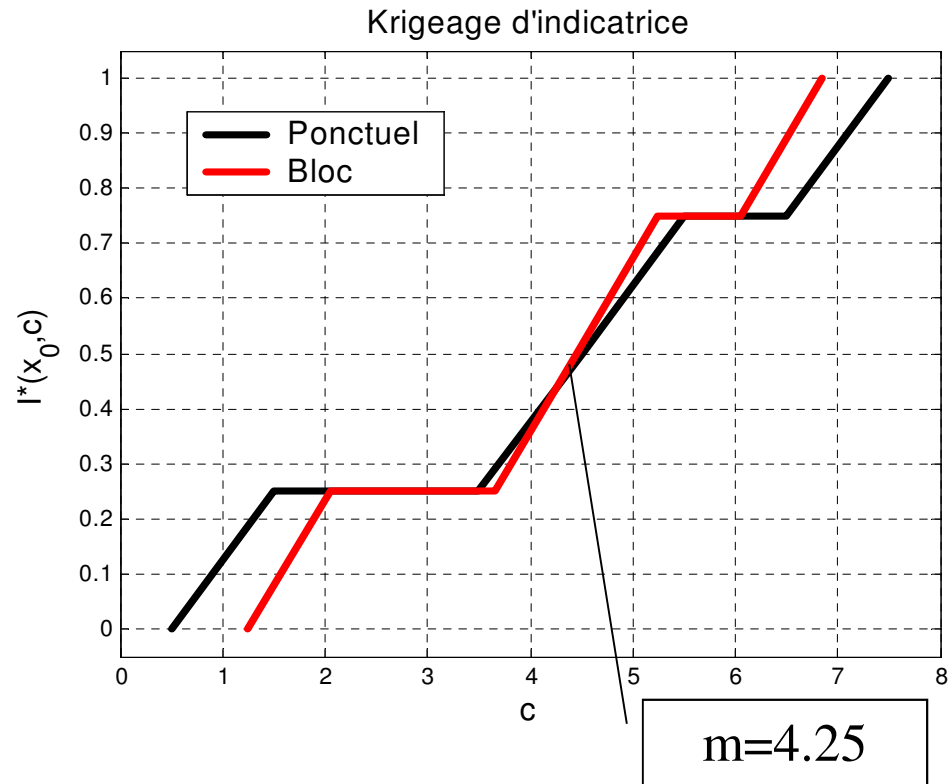
Le facteur de contraction  $\left\{ \frac{D^2(v | G)}{D^2(\bullet | G)} \right\}^{0.5}$  est *global* malgré que la correction soit appliquée à une *distribution locale* !





Variogramme  $\Rightarrow D^2(\cdot|G)$   
 $\Rightarrow D^2(v|G)$

$$\left\{ \frac{D^2(v|G)}{D^2(\bullet|G)} \right\}^{0.5} = 0.8$$



# Variantes


1- Krigage simple d'indicatrice :

$$I^*(x_0, c) = \sum_{i=1}^n \lambda_i I(x_i, c) + (1 - \sum_{i=1}^n \lambda_i) F_Z(c)$$

$F_Z(c)$  : fonction de répartition (globale)

Permet une gradation plus souple de  $I^*(x, c)$

Permet de mieux tenir compte du degré de corrélation locale



S'il n'y a pas de corrélation entre les points, la fonction estimée sera simplement  $F_Z(c)$

Z4=1



Z3=4



←  $F(x_0, c | Z_1, Z_2, Z_3, Z_4)$  ?

Z1=5

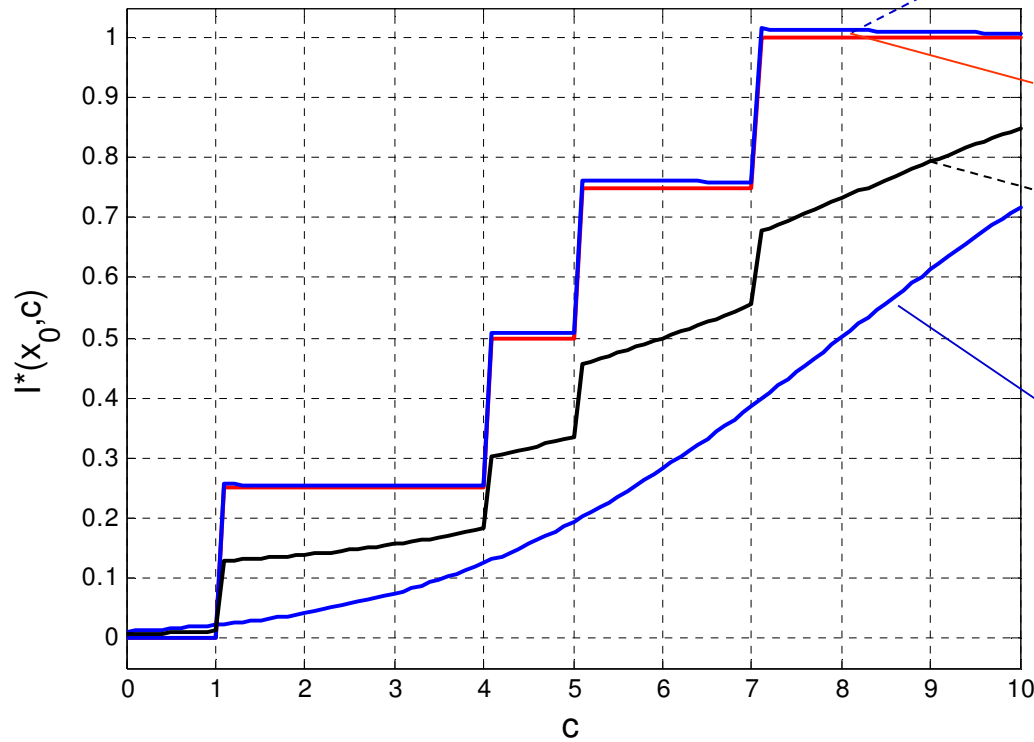


h=1



Z2=7

Krigeage d'indicatrice



I\* par KS, sphérique a=10

I\* par K0

I\* par KS, sphérique a=1

Fct. de répartition N(8,12)  
I\* par KS si  $a < 1/2^{0.5}$

---

## 2- Cokrigeage :

v. principale :  $I(x, c_j)$

v. secondaires :  $I(x, c_k), k \neq j$



Très lourd, presque jamais utilisé

ou

v. principale :  $I(x, c_j)$

v. secondaire :  $Z(x)$  ou mieux  $U(x) = \text{rang}(Z(x)) / (n+1)$

# « Soft kriging »

**-+ de flexibilité :**

- **utiliser des informations du type  $Z(x_i) > t$ ,  $Z(x_i) < t$ ,  $t_2 > Z(x_i) > t_1$ ;**  
**des données semi-quantitatives fournies par le géologue (e.g.**  
**« dans ce type de roche, la teneur n'excède jamais « t »)**

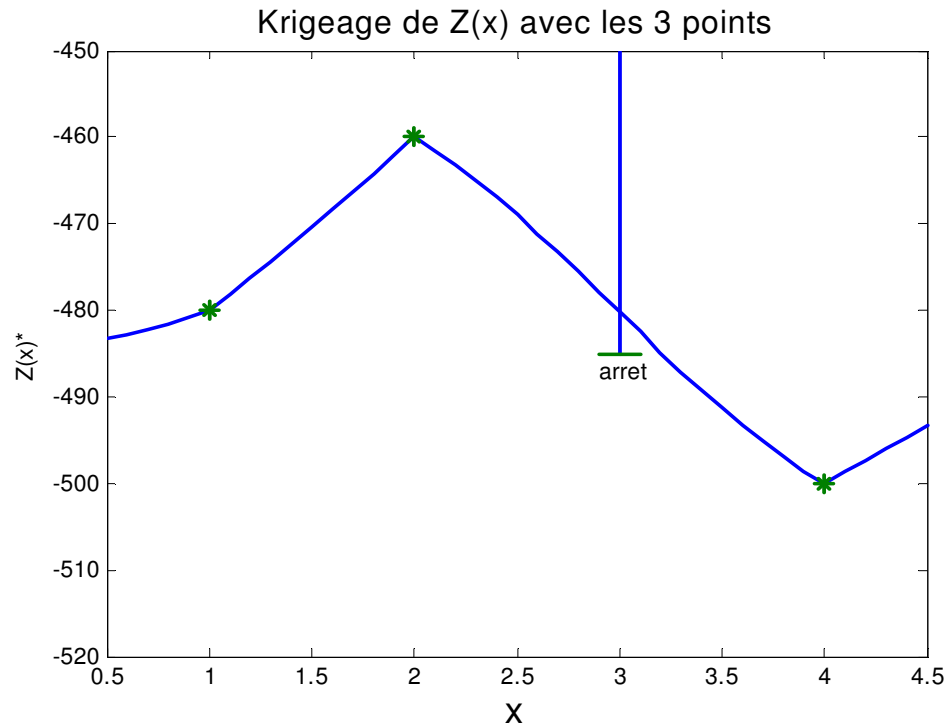
**Exemple :**

**3 forages ont intercepté le sommet d'un réservoir pétrolier**


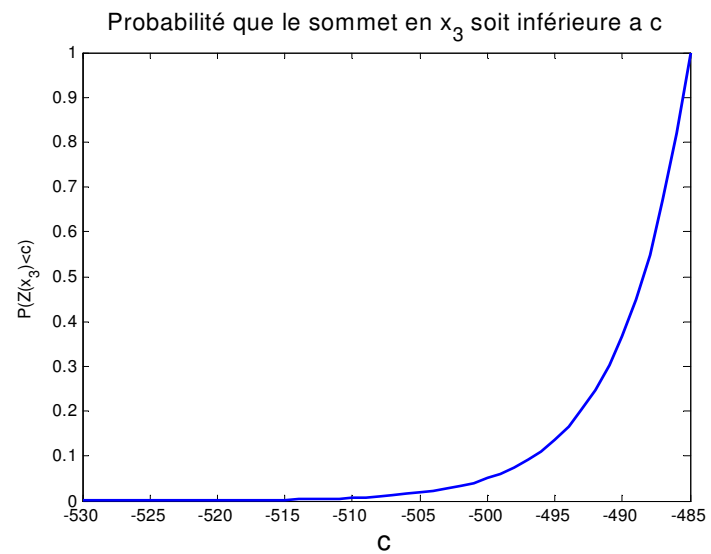


$$Z(1) = -480, Z(2) = -460, Z(4) = -500$$

**un 4e forage situé en  $x=3$ , a dû être arrêté au niveau  $-485$  sans que le sommet n'ait été intercepté !**

## Solution par KO de $Z(x) \approx$ solution par KO de $I(x)$ avec les 3 forages (1,2,4)



**La solution n'est pas acceptable ! Elle contredit l'information en  $x=3$ .**



# Remarques

Soit le seuil « c » correspondant à un quantile « p » de la distribution de  $Z(x)$


$I(x,c)$  a les propriétés suivantes:

$$E[I(x,c)] = p$$

$$\text{Var}(I(x,c)) = p(1-p)$$

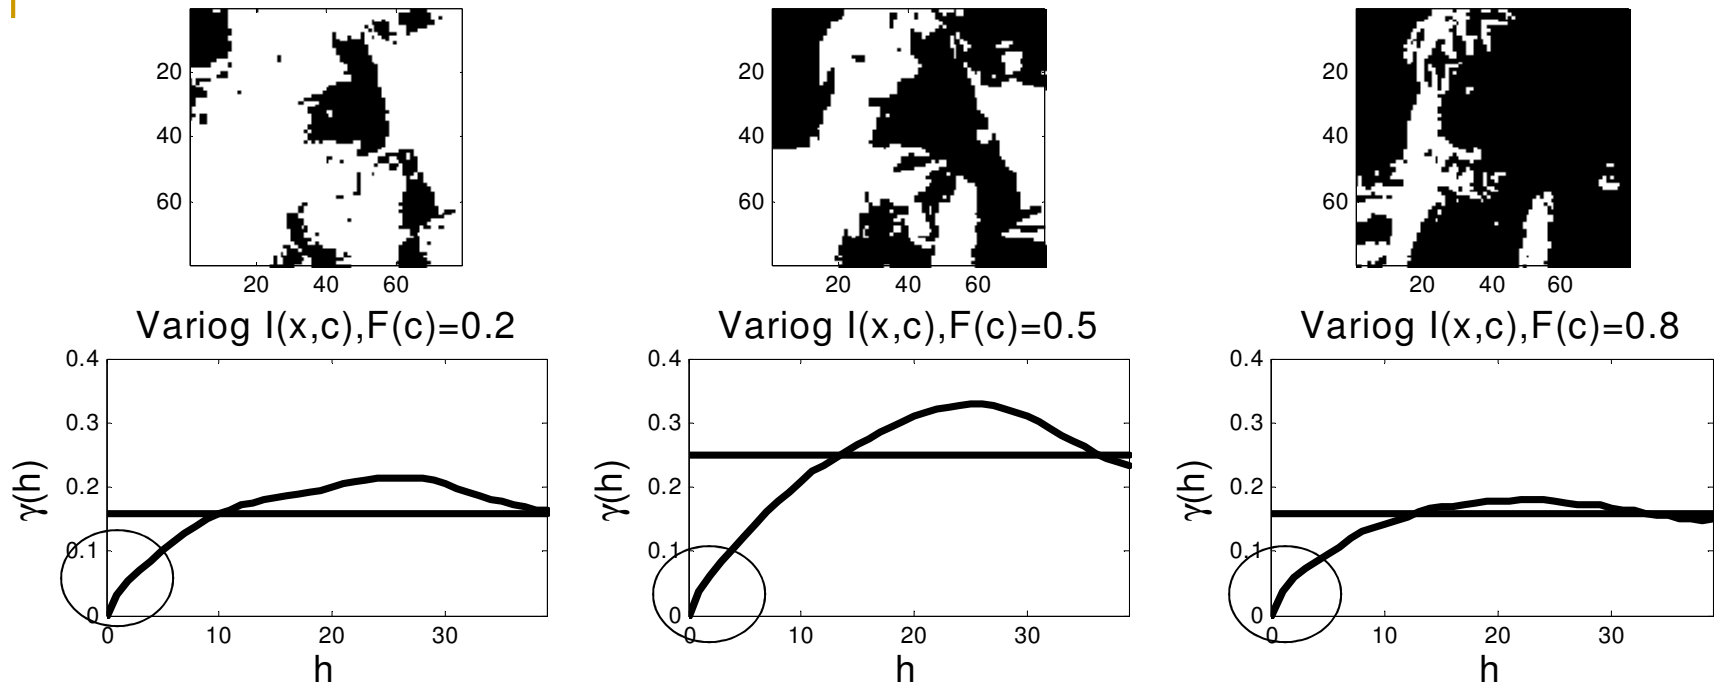
Ex.: si l'on choisit un seuil pour lequel 20% des observations sont inférieures,  $D^2(I(x,c)|G) \approx 0.2 \cdot 0.8 = 0.16$

normalement, **le palier est légèrement supérieur** à  $D^2(I(x,c)|G)$  (dépendant de l'importance de la structure spatiale).



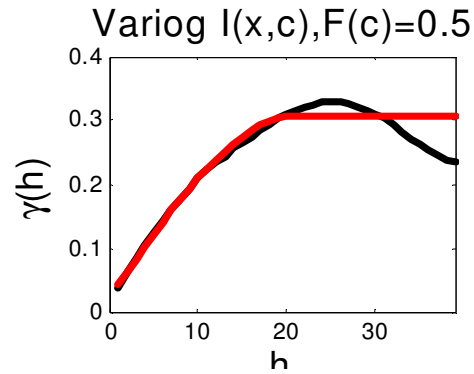

Les paliers sont presque déterminés par le seuil du codage de l'indicatrice









Les variogrammes d'indicatrices ne peuvent montrer un comportement parabolique à l'origine => **proscrire le modèle gaussien !**

# Exemple : déterminer le volume d'un sol contaminé au delà d'une norme

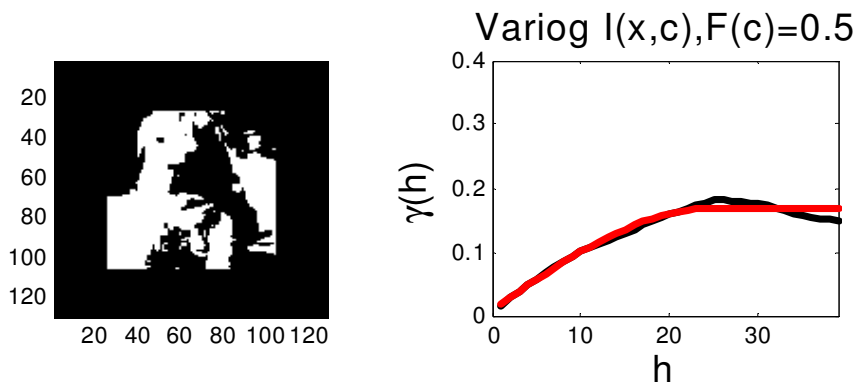


**C=130; V=3120**



Pas	n	V*	$\sigma$	CI (95%)
5	256	3020	93	[2834,3205]
10	64	3023	210	[2603,3443]
15	25	3002	387	[2228,3775]
20	16	3089	527	[2036,4142]

Que se passe-t-il si l'échantillon déborde de la zone d'intérêt ?



Le variogramme des indicatrices change

Pas	Surface > c		Écart-type	
	Sans	Avec	Sans	Avec
5	3020	3096	93	132
10	3023	3110	210	230
15	3002	4115	387	403
20	3089	3267	527	577


Les estimés sont semblables et l'ordre de grandeur des écarts-types est comparable, même si la zone couverte est 2.2 fois + grande en superficie




Bonne robustesse au choix initial de la zone d'étude

---


as=5



pas=10



pas=15



pas=20

