

# Incertitudes en cinétique

François WAHL ([Francois.wahl@ifp.fr](mailto:Francois.wahl@ifp.fr))  
IFP BP3 69390 VERNAISON



Procédés habituellement représentés par un modèle non-linéaire

Modèle

$$\mathbf{y} = f(\mathbf{c}; \boldsymbol{\theta}_0)$$

Procédés habituellement représentés par un modèle non-linéaire

Modèle

$$\mathbf{y} = f(\mathbf{c}; \boldsymbol{\theta}_0)$$

$\mathbf{c}$  = entrées = compositions des réactifs + conditions opératoires

Procédés habituellement représentés par un modèle non-linéaire

Modèle

$$\mathbf{y} = f(\mathbf{c}; \boldsymbol{\theta}_0)$$

$\mathbf{c}$  = entrées = compositions des réactifs + conditions opératoires

$\mathbf{y}$  = sorties = compositions de l'effluent  $\boldsymbol{\theta}_0$

Procédés habituellement représentés par un modèle non-linéaire

Modèle

$$\mathbf{y} = f(\mathbf{c}; \boldsymbol{\theta}_0)$$

$\mathbf{c}$  = entrées = compositions des réactifs + conditions opératoires

$\mathbf{y}$  = sorties = compositions de l'effluent  $\boldsymbol{\theta}_0$

$\boldsymbol{\theta}_0$  = vrais paramètres du modèle (inconnus) =  $k, \alpha$

Procédés habituellement représentés par un modèle non-linéaire

Modèle

$$\mathbf{y} = f(\mathbf{c}; \boldsymbol{\theta}_0)$$

$\mathbf{c}$  = entrées = compositions des réactifs + conditions opératoires

$\mathbf{y}$  = sorties = compositions de l'effluent  $\boldsymbol{\theta}_0$

$\boldsymbol{\theta}_0$  = vrais paramètres du modèle (inconnus) =  $k, \alpha$

$f$  = fonction liant  $\mathbf{c}$ ,  $\boldsymbol{\theta}_0$  et  $\mathbf{y}$  (solution d'un système d'EDO, résolu numériquement)




Schéma réactionnel



Modèle

$$y = f(\mathbf{c}, \boldsymbol{\theta})$$

$$\frac{dS}{dt} = -kS^\alpha$$

$$\mathbf{c} = [S_0, t]$$


$$\boldsymbol{\theta} = (k, \alpha)$$

$$y = S_{\text{Effluent}}$$

$$f = \text{fonction liant } \mathbf{c}, \boldsymbol{\theta} \text{ et } y$$

$$S_{\text{Effluent}} = (S_0^{1-\alpha} - (1-\alpha)kt)^{1/(1-\alpha)}$$

# Isomérisation des C4



Conditions opératoires  
(P, T, ...)

Modèle  $\mathbf{y} = f(\mathbf{c}, \boldsymbol{\theta})$


$\mathbf{c} = [(nC4, iC4)_{CHARGE} (P, T, \dots)]$

$\boldsymbol{\theta} = (k_1, k_2, k_3, E_1, E_2, E_3, b_{iC4}, b_{C3+C5})$

$\mathbf{y} = (nC4, iC4, C3+C5)_{RECETTE}$

$f =$  fonction liant  $\mathbf{x}$ ,  $\boldsymbol{\theta}$  et  $\mathbf{y}$

Schéma réactionnel



variables contrôlées

paramètres à déterminer(catalyseur)

réponses

programme informatique



Procédés habituellement représentés par un modèle non-linéaire

Modèle

$$\mathbf{y} = f(\mathbf{c}, \boldsymbol{\theta}_0)$$

$\mathbf{c}$  = entrées = compositions des réactifs + conditions opératoires

$\mathbf{y}$  = sorties = compositions de l'effluent  $\boldsymbol{\theta}_0$

$\boldsymbol{\theta}_0$  = vrais paramètres du modèle (**inconnus**) =  $k, \alpha$

$f$  = fonction liant  $\mathbf{c}, \boldsymbol{\theta}_0$  et  $\mathbf{y}$  (solution d'un système d'EDO, résolu numériquement)

Mesures expérimentales  $(\mathbf{c}_i, y_{obs,i})_{i=1,n}$

Présence de bruit  $y_{obs,i} \neq y_{vrai,i}$  et  $\mathbf{y}_{obs}$  réalisation de  $Y$  aléatoire

Modèle statistique

$$Y = f(\mathbf{c}, \boldsymbol{\theta}_0) + \varepsilon$$

Mesures expérimentales  $(\mathbf{c}_i, y_{obs,i})_{i=1,n}$

Présence de bruit  $y_{obs,i} \neq y_{vrai,i}$  et  $\mathbf{y}_{obs}$  réalisation de  $Y$  aléatoire

Modèle statistique

$$Y = f(\mathbf{c}, \boldsymbol{\theta}_0) + \varepsilon$$

$\boldsymbol{\theta}_0$  estimé par

$$\boldsymbol{\theta}_{obs} = \underset{\boldsymbol{\theta} \in \Theta}{\operatorname{argmin}} \sum_{i=1}^n w_i (y_{obs,i} - f(\mathbf{c}_i, \boldsymbol{\theta}))^2$$

$\Rightarrow \boldsymbol{\theta}_{obs}$  réalisation de  $\hat{\boldsymbol{\theta}}$  aléatoire

Mesures expérimentales  $(\mathbf{c}_i, y_{obs,i})_{i=1,n}$

Présence de bruit  $y_{obs,i} \neq y_{vrai,i}$  et  $\mathbf{y}_{obs}$  réalisation de  $Y$  aléatoire

Modèle statistique

$$Y = f(\mathbf{c}, \boldsymbol{\theta}_0) + \varepsilon$$

$\boldsymbol{\theta}_0$  estimé par

$$\boldsymbol{\theta}_{obs} = \underset{\boldsymbol{\theta} \in \Theta}{\operatorname{argmin}} \sum_{i=1}^n w_i (y_{obs,i} - f(\mathbf{c}_i, \boldsymbol{\theta}))^2$$

$\Rightarrow \boldsymbol{\theta}_{obs}$  réalisation de  $\hat{\boldsymbol{\theta}}$  aléatoire

En prédiction

$$\hat{y} = f(\mathbf{c}, \hat{\boldsymbol{\theta}})$$


$\hat{\boldsymbol{\theta}}$  aléatoire  $\Rightarrow \hat{y}$  aléatoire

**Objectif :** quantifier l'incertitude sur  $\hat{y}$

**Comment :** identifier la loi suivie par  $\hat{\boldsymbol{\theta}}$

# Propagation des Incertitudes : isomérisation des C4

Distribution de  $\hat{\theta}$   $\longrightarrow$   $\hat{y} = f(\mathbf{c}, \hat{\theta})$



# Analyse de sensibilité

Modèle

$$y = f(\mathbf{x})$$

Quelles sont les entrées (de  $\mathbf{x}$ )

dont les variations influencent le plus, le moins, la variation de  $y$  ?

Modèle  $y = f(\mathbf{x})$

Quelles sont les entrées (de  $\mathbf{x}$ )

dont les variations influencent le plus, le moins, la variation de  $y$  ?

Indices de sensibilité au 1er ordre :

$$S_i = \frac{\text{var}(E(Y / X_i))}{\text{var}(Y)}$$

## Interprétation

- $E(Y / X_i)$  la fonction de  $X_i$  qui approche le mieux  $Y$
- $\text{var}(E(Y / X_i))$  variations de la sortie comme fonction de  $X_i$  seul
- $\text{var}(Y)$  normalisation

Modèle  $y = f(\mathbf{x})$

Quelles sont les entrées (de  $\mathbf{x}$ )

dont les variations influencent le plus, le moins, la variation de  $y$  ?

Indices de sensibilité au 1er ordre :

$$S_i = \frac{\text{var}(E(Y / X_i))}{\text{var}(Y)}$$

## Interprétation

- $E(Y / X_i)$  la fonction de  $X_i$  qui approche le mieux  $Y$
- $\text{var}(E(Y / X_i))$  variations de la sortie comme fonction de  $X_i$  seul
- $\text{var}(Y)$  normalisation

Techniques usuelles : SOBOL, FAST

Limitations : Nombre de runs, **Indépendance des entrées**



# Entrées non indépendantes

Méthode de MacKay : nombre de runs très important

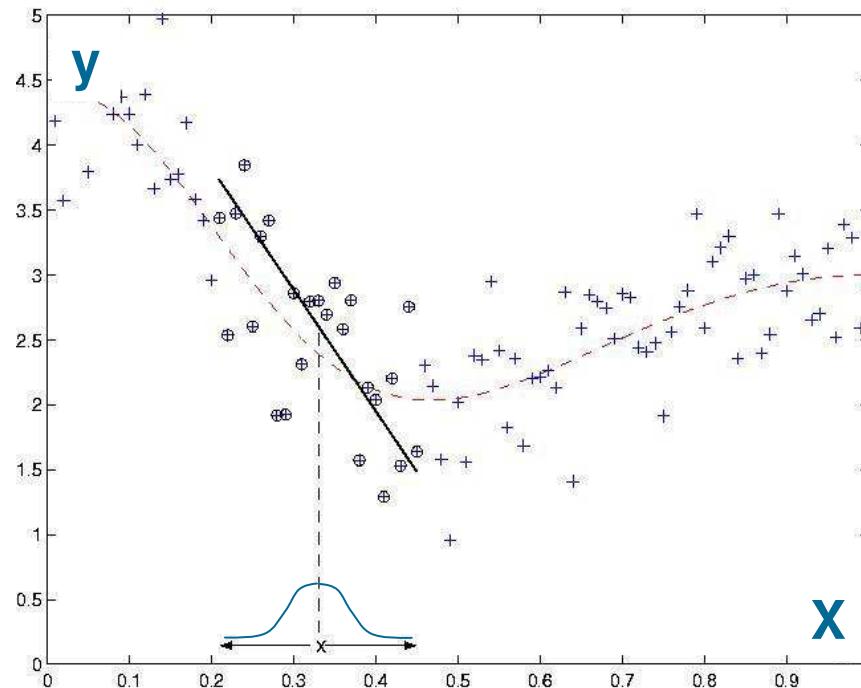
Méthode Oakley et O'Hagan : Développements analytiques +  
Intégrales multiples ( $2d-1$ )

# Entrées non indépendantes

Méthode de MacKay : nombre de runs très important

Méthode Oakley et O'Hagan : Développements analytiques +  
Intégrales multiples  $(2d-1)$

Méthode par polynômes locaux : Sébastien Da Veiga (2007)



## Modèle de régression classique

$$Y_i = m(X_i) + \sigma(X_i)\varepsilon_i$$

$$m(x) = E(Y / X = x) \quad \text{et} \quad \sigma^2(x) = \text{var}(Y / X = x)$$

Les  $\varepsilon_i$  sont centrées réduites indépendantes des  $X_i$

## Modèle de régression classique

$$Y_i = m(X_i) + \sigma(X_i)\varepsilon_i$$

$$m(x) = E(Y / X = x) \quad \text{et} \quad \sigma^2(x) = \text{var}(Y / X = x)$$

Les  $\varepsilon_i$  sont centrées réduites indépendantes des  $X_i$

polynômes d'ordre 1 (ou 2) en pratique

$$\beta_0, \beta_1 = \underset{\beta}{\operatorname{argmin}} \sum_{i=1}^n \left( y_{obs,i} - (\beta_1(x_{obs,i} - x) + \beta_0) \right)^2 K\left(\frac{x_{obs,i} - x}{h}\right)$$

## Modèle de régression classique

$$Y_i = m(X_i) + \sigma(X_i)\varepsilon_i$$

$$m(x) = E(Y / X = x) \quad \text{et} \quad \sigma^2(x) = \text{var}(Y / X = x)$$

Les  $\varepsilon_i$  sont centrées réduites indépendantes des  $X_i$

## polynômes d'ordre 1 (ou 2) en pratique

$$\beta_0, \beta_1 = \underset{\beta}{\operatorname{argmin}} \sum_{i=1}^n \left( y_{\text{obs},i} - (\beta_1(x_{\text{obs},i} - x) + \beta_0) \right)^2 K\left(\frac{x_{\text{obs},i} - x}{h}\right)$$


## Estimation de $\text{Var}(E(Y/X)) = \text{Var}(m(X))$

$$\widehat{T}_1 = \frac{1}{n' - 1} \sum_{j=1}^{n'} (\widehat{m}(X_j) - \widehat{\bar{m}})^2 \quad \text{où} \quad \widehat{\bar{m}} = \frac{1}{n'} \sum_{j=1}^{n'} \widehat{m}(X_j)$$

# Entrées non indépendantes sur le modèle HDS

$$\frac{dS}{dt} = -kS^\alpha$$

$$S_{\text{Effluent}} = (S_0^{1-\alpha} - (1-\alpha)kt)^{1/(1-\alpha)}$$

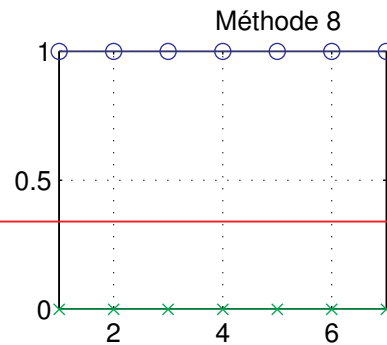

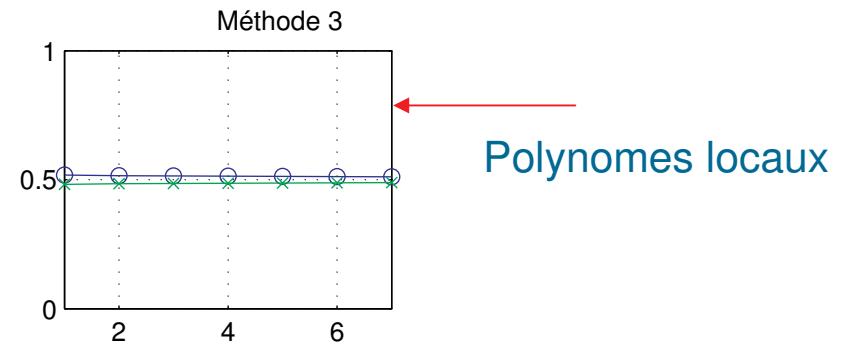


les entrées sont supposées indépendantes

# Entrées non indépendantes sur le modèle HDS

$$\frac{dS}{dt} = -kS^\alpha$$

$$S_{\text{Effluent}} = (S_0^{1-\alpha} - (1-\alpha)kt)^{1/(1-\alpha)}$$




—○— Indice de sensibilité k  
—×— Indice de sensibilité alpha

SOBOL'

FAST

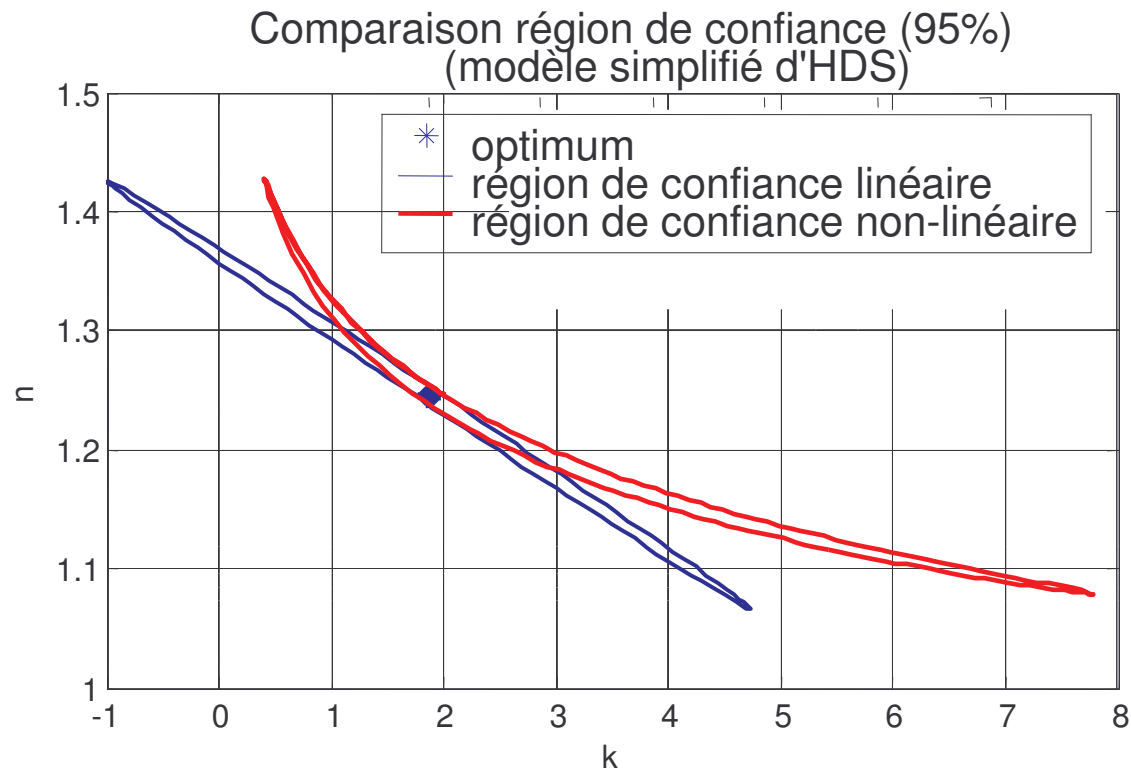
les entrées sont supposées indépendantes

# Entrées non indépendantes sur le modèle HDS






L'approximation linéaire (classique) ne suffit pas



# Modèle simple d'HDS : Résultats

t contact	0	0.1	0.2	0.3	0.4	0.6	0.8	1.0
y mesuré	14000	2892	1109	230	84	23	9	4

**Fonction coût**  $\sum_i (y_i^{mesuré} - y_i^{calculé})^2 \rightarrow \hat{\theta}_{ref} = [k \quad \alpha] = [2.35 \quad 1.23]$

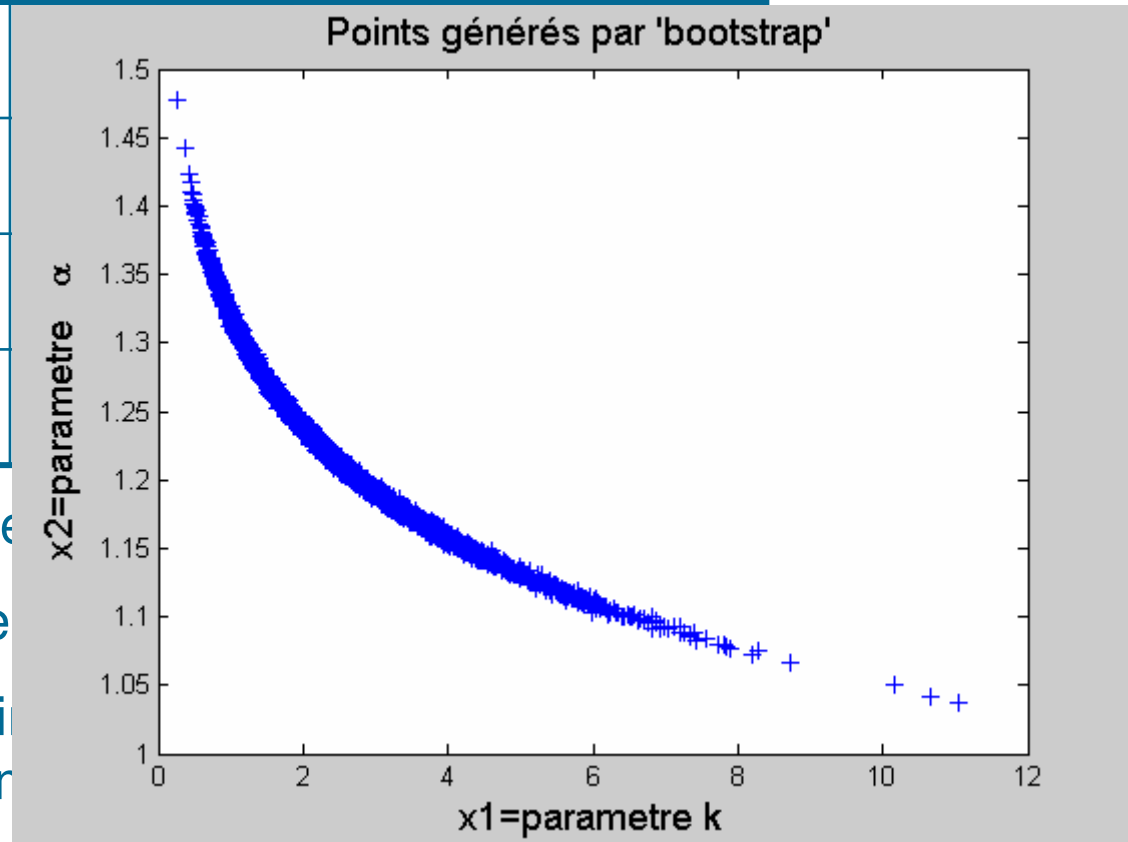


t contact	0	0.1	0.2	0.3	0.4	0.6	0.8	1.0
y mesuré	14000	2892	1109	230	84	23	9	4
$y_{ref}$ calculé	14000	2492	695	265	121	35	13	6
résidus	0	-500	-514	35	37	12	4	2

On considère  $y_{ref}$ , calculé avec les paramètres  $\hat{\theta}_{ref}$ , comme vrai

- Faire un grand nombre de fois (pour  $b=1, B$ )
  1. rajouter une erreur aléatoire sur chacun des  $y_{ref}$  calculés, pour obtenir des nouvelles mesures simulées (en tirant parmi les résidus)
  2. redéterminer les paramètres  $\hat{\theta}_b$  à partir des mesures simulées


t contact	0	0.1
y mesuré	14000	2892
$y_{ref}$ calculé	14000	2492
résidus	0	-500



On considère  $y_{ref}$ , calculé avec

- Faire un grand nombre de simulations
1. rajouter une erreur aléatoire aux nouvelles mesures simulées
  2. redéterminer les paramètres  $\theta_b$  à partir des mesures simulées

t contact	0	0.1
y mesuré	14000	2892
$y_{ref}$ calculé	14000	2492
résidus	0	-500



On considère  $y_{ref}$ , calculé avec

- Faire un grand nombre de simulations
1. rajouter une erreur aléatoire à  $y_{ref}$  pour générer des nouvelles mesures simulées
  2. redéterminer les paramètres  $\theta_b$  à partir des mesures simulées

**Avantage** : Méthode générale, peu d'hypothèses

**Inconvénient** : Coût de calcul (B optimisations)

- **1 point 'bootstrap' = 1 jeu de paramètres = 1 optimisation**
- **fléau de la dimension = nombre de paramètres**
  
- **Isomérisation des C4**
  - 8 paramètres
  - 10000 optimisations = une nuit de calcul
- **Isomérisation des C5**
  - ~20 paramètres
  - 20000 optimisations = un mois de calcul

**Objectif :** quantifier l'incertitude sur  $\hat{y}$

**Comment :** identifier la loi suivie par  $\hat{\theta}$

- Une réalisation  $\theta_b^*$  demande la résolution d'un problème de minimisation

$$\theta_b^* = \operatorname{argmin}_{\theta \in \Theta} \sum_{i=1}^n w_i (y_{b,i}^* - f(\mathbf{c}_i, \theta))^2$$

**Objectif :** quantifier l'incertitude sur  $\hat{y}$

**Comment :** identifier la loi suivie par  $\hat{\theta}$

- Une réalisation  $\theta^*_b$  demande la résolution d'un problème de minimisation

$$\theta^*_b = \operatorname{argmin}_{\theta \in \Theta} \sum_{i=1}^n w_i (y^*_{b,i} - f(\mathbf{c}_i, \theta))^2 \quad \hat{\theta}_b \text{ est une fonction des résidus } (\varepsilon_i)_{i=1,n}$$

$$\begin{aligned} y^*_{b,i} - f(\mathbf{c}_i, \theta) &= y^*_{b,i} - f(\mathbf{c}_i, \theta_{obs}) + f(\mathbf{c}_i, \theta_{obs}) - f(\mathbf{c}_i, \theta) \\ &= \varepsilon_i + f(\mathbf{c}_i, \theta_{obs}) - f(\mathbf{c}_i, \theta) \end{aligned}$$



# Idée : Fonction des résidus

**Objectif :** quantifier l'incertitude sur  $\hat{y}$

**Comment :** identifier la loi suivie par  $\hat{\theta}$

- Une réalisation  $\theta_b^*$  demande la résolution d'un problème de minimisation
- **Idée :** On considère que le bootstrap échantillonne une surface de réponse, qu'on ajuste à partir de quelques points seulement

$$\theta_b^* = \operatorname{argmin}_{\theta \in \Theta} \sum_{i=1}^n w_i (y_{b,i}^* - f(\mathbf{c}_i, \theta))^2 \quad \hat{\theta}_b \text{ est une fonction des résidus } (\varepsilon_i)_{i=1,n}$$

$$\begin{aligned} y_{b,i}^* - f(\mathbf{c}_i, \theta) &= y_{b,i}^* - f(\mathbf{c}_i, \theta_{obs}) + f(\mathbf{c}_i, \theta_{obs}) - f(\mathbf{c}_i, \theta) \\ &= \varepsilon_i + f(\mathbf{c}_i, \theta_{obs}) - f(\mathbf{c}_i, \theta) \end{aligned}$$

# Idée : Fonction des résidus

**Objectif :** quantifier l'incertitude sur  $\hat{y}$

**Comment :** identifier la loi suivie par  $\hat{\theta}$

• Une réalisation  $\theta^*_b$  demande la résolution d'un problème de minimisation

• **Idée :** On considère que le bootstrap échantillonne une surface de réponse, qu'on ajuste à partir de quelques points seulement

❖ soit par **SVR** ('Support Vector Machine for Regression')

❖ soit par **PCE** ('Polynomial Chaos Expansion')

$$\theta^*_b = \operatorname{argmin}_{\theta \in \Theta} \sum_{i=1}^n w_i (y^*_{b,i} - f(\mathbf{c}_i, \theta))^2 \quad \hat{\theta}_b \text{ est une fonction des résidus } (\varepsilon_i)_{i=1,n}$$

$$\begin{aligned} y^*_{b,i} - f(\mathbf{c}_i, \theta) &= y^*_{b,i} - f(\mathbf{c}_i, \theta_{obs}) + f(\mathbf{c}_i, \theta_{obs}) - f(\mathbf{c}_i, \theta) \\ &= \varepsilon_i + f(\mathbf{c}_i, \theta_{obs}) - f(\mathbf{c}_i, \theta) \end{aligned}$$

$\hat{\theta}_b$  est une fonction des résidus  $(\varepsilon_i)_{i=1,n}$

Chaque composante du vecteur de paramètres  $\hat{\theta}_b$  peut s'écrire comme **une somme de polynômes orthogonaux**

$$\hat{\theta}_b = a_0 \Gamma_0 + \sum_i a_i \Gamma_1(\varepsilon_i) + \sum_{i,j} a_{i,j} \Gamma_{1,1}(\varepsilon_i, \varepsilon_j) + \dots$$

Pour chacune des  $q$  composantes de  $\hat{\theta}_b$

on est ramené à un système d'équations linéaires pour trouver

**$(n+1)(n+2)/2$  coefficients  $a_i$**  pour  $n$  résidus à l'ordre 2

à l'aide de  **$b$  équations =  $b$  estimations bootstrap**

# Introduction des dérivées / aux résidus

$$\hat{\theta} = a_0 \Gamma_0 + \sum_i a_i \Gamma_1(\varepsilon_i) + \sum_{i,j} a_{i,j} \Gamma_{1,1}(\varepsilon_i, \varepsilon_j) + \dots$$

$$\frac{\partial \hat{\theta}}{\partial \varepsilon_i} = a_0 \Gamma_0 + a_i \frac{\partial \Gamma_1}{\partial \varepsilon_i} + \sum_j a_{i,j} \frac{\partial \Gamma_{1,1}}{\partial \varepsilon_i} + \dots$$

$$\hat{\theta} = \underset{\theta \in \Theta}{\operatorname{argmin}} \sum_{i=1}^n w_i (y_i - f(\mathbf{c}_i, \theta))^2 \quad \text{avec} \quad C = \sum_{i=1}^n w_i (y_i - f(\mathbf{c}_i, \theta))^2$$

$$\frac{\partial \hat{\theta}}{\partial \varepsilon_i} = - \left( \frac{\partial^2 C}{\partial \varepsilon_i^2} \right)^{-1} \frac{\partial^2 C}{\partial \theta \cdot \partial \varepsilon_i}$$

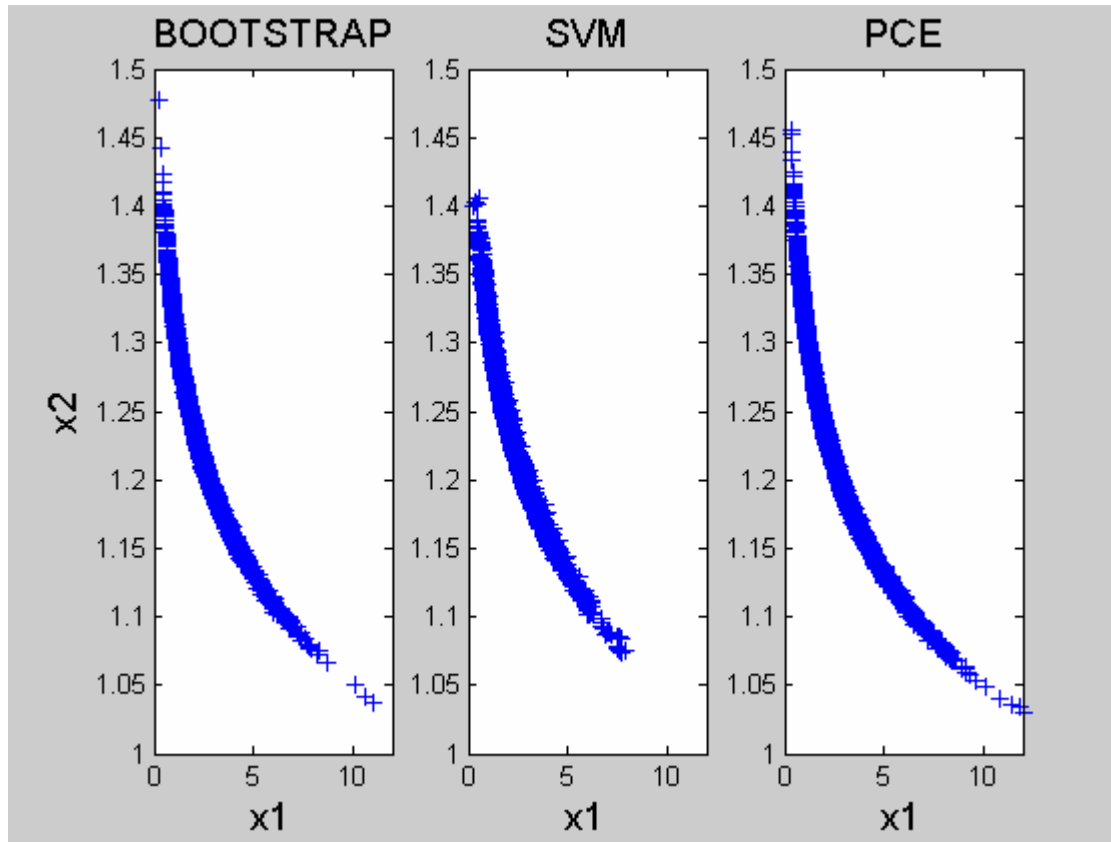
Pour chacune des  $q$  composantes de  $\hat{\theta}_b$

on est ramené à un système d'équations linéaires pour trouver

**$(n+1)(n+2)/2$  coefficients  $a_i$**  pour  $n$  résidus à l'ordre 2

à l'aide de  **$\mathbf{b}(q+1)$  équations**

# Désulfuration : Comparaison des résultats



Bootstrap : **5000** points

SVM : **500** points, 5000 points générés


PCE (avec dérivées) : **50** points, 5000 points générés

# Distribution des paramètres 1 et 7

Rouge = bootstrap 10000,

Bleu = SVM 200

= SVM 50 + Deriv (Vasquez & al 2003), (Lazaro & al 2005)



$$S_i = \frac{\text{var}(E(Y / X_i))}{\text{var}(Y)}$$

- **Indices de sensibilité et Polynômes locaux**

- faciles à appréhender
- résultats théoriques de convergence

$$\theta_b^* = \underset{\theta \in \Theta}{\text{argmin}} \sum_{i=1}^n w_i (y_{b,i}^* - f(\mathbf{c}_i, \theta))^2$$

- **Bootstrap : Pb de temps de calcul**

- **Solutions : Surfaces de réponse**

- SVR
- Polynômes de chaos

- **Surfaces de réponse et dérivées**

- Limitations : Calcul des dérivées
- Pb en grande dimension