

# Utilisation des splines de lissage pour la construction de surface de réponse Application: simulateur de réservoir

par  
Samir Touzani



M. Anestis Antoniadis (Directeur de thèse)

M. Daniel Busby (Promoteur de thèse)




# Introduction

---


- **Contexte**
  - Analyse des incertitudes en ingénierie des réservoirs
  
- **Objectifs principaux**
  - Propagation des incertitudes des entrées sur les sorties du simulateur
  - Analyse de sensibilité: quantifier l'influence des paramètres d'entrée sur les sorties
  
- **Problèmes**
  - Simulateur coûteux en temps de calcul à haute dimension

# Workflow: Modélisation et simulation des réservoirs




# Problématique

## Illustration sur simulation réservoir



**Ces incertitudes sont-elles influentes sur les prévisions de production?**




**Comment quantifier cet impact?**

# Ingénierie de réservoir : Objectifs et enjeux

- **Modèle de simulation impliquant un grand nombre de paramètres incertains :**

- **Paramètres liés au gisement**

- **Géométrie du réservoir** : épaisseur, limites, force d'aquifère, présence de faille, etc.
- **Remplissage du réservoir** : plusieurs milliers de mailles à renseigner en propriétés pétrophysiques (porosité, perméabilité)
- **Propriétés des fluides eau/huile/gaz** : niveau des contacts entre les fluides, viscosité, saturations, PVT
- **Interactions roches/fluides** : perméabilités relatives
  - Capacité d'un fluide à se déplacer gênée par la présence d'un autre fluide
- **Puits & production** : Indice de productivité (IP), effet pariétal (skin)
  - Modification de la perméabilité aux abords du puits - lié au forage





# Surface de réponse


---

## Introduction

- Considérons le modèle :

$$Y_i = f(X_i) + \varepsilon_i \quad i = 1, \dots, n$$

- Le problème de la régression statistique consiste à analyser l'influence des paramètres d'entrés  $X \in \mathcal{R}^d$  sur la sortie  $Y$





# Surface de réponse

---

## Régression et régularisation

- $f(x)$  est approchée selon le principe des moindres carrés régularisé

$$J(f) = \sum_{i=1}^n (y_i - f(x_i))^2 + \lambda p(f)$$




# Surface de réponse

## Régression et régularisation

- $f(x)$  est approchée selon le principe des moindres carrés régularisé

$$J(f) = \sum_{i=1}^n (y_i - f(x_i))^2 + \lambda p(f)$$

fonction de coût quadratique



adéquation du modèle aux données



# Surface de réponse

## Régression et régularisation

- $f(x)$  est approchée selon le principe des moindres carrés régularisé

$$J(f) = \sum_{i=1}^n (y_i - f(x_i))^2 + \lambda p(f)$$

fonction de coût quadratique

terme de régularisation

adéquation du modèle aux données

restreint l'espace des fonctions



# ANOVA

---

## Definition :

- La décomposition ANOVA exprime la sortie  $f(x) \in F$  comme un développement exact, ou tronqué, de fonctions de variables d'entrée  $X$  :

$$f(x) = f_0 + \sum_{i=1}^d f_i(x_i) + \sum_{1 \leq i < j \leq d} f_{ij}(x_i, x_j) + \sum_{1 \leq i < j < k \leq d} f_{ijk}(x_i, x_j, x_k) + \dots + f_{12\dots d}(x_1, x_2, \dots, x_d)$$

Où  $f_0$  est une constante

- L'unicité de cette décomposition est assurée par les conditions :

$$\int_0^1 f_{i_1, \dots, i_s}(x_{i_1}, \dots, x_{i_s}) dx_{i_k} = 0 \quad \forall k = 1, \dots, s \quad \forall \{i_1, \dots, i_s\} \subseteq \{1, \dots, d\}$$



## SS-ANOVA (Wahba 1990)

- Dans le cadre de l'utilisation d'un modèle à splines de lissage ANOVA (SS-ANOVA), on suppose que  $f_j(x_j) \in H^{(j)}$  où  $H^{(j)}$  est un espace Hilbertien à noyau reproduisant (RKHS) et admettant la décomposition orthogonal:  $H^{(j)} = \{1\} \oplus \bar{H}^{(j)}$

- Ainsi l'espace RKHS  $F$  s'écrit comme le produit tensoriel :

$$F = \bigotimes_{j=1}^d H^{(j)} = \{1\} \oplus \left[ \bigoplus_{j=1}^d \bar{H}^{(j)} \right] \oplus \left[ \bigoplus_{j < k} \left( \bar{H}^{(j)} \otimes \bar{H}^{(k)} \right) \right] \oplus \dots$$

- Généralement le développement de  $F$  est tronqué
- Selon l'ordre d'interaction considéré, on réécrit l'espace  $F$  sous la forme :

$$F = \{1\} \oplus \left\{ \bigoplus_{\gamma=1}^q F_{\gamma} \right\}$$

Ci-dessus  $q$  dépend de la dimension du modèle et des interactions considérées



# SS-ANOVA (Wahba 1990)

## Exemple

- Pour un modèle à 2 paramètres d'entrés, la décomposition ANOVA du modèle  $f(x) \in F$  est :

$$f(x) = f_0 + f_1(x_1) + f_2(x_2) + f_{12}(x_1, x_2)$$

- Avec

$$\begin{aligned} F &= \bigotimes_{j=1}^2 H^{(j)} = \{1\} \oplus \bar{H}^{(1)} \oplus \bar{H}^{(2)} \oplus \left[ \left( \bar{H}^{(1)} \otimes \bar{H}^{(2)} \right) \right] \\ &= \{1\} \oplus F_1 \oplus F_2 \oplus F_3 \end{aligned}$$



# COSSO (Lin 2006)

## Définition

- Pour  $f(x) \in F$  la procédure COSSO minimise :

$$\frac{1}{n} \sum_{i=1}^n (y_i - f(x_i))^2 + \lambda^2 \sum_{\gamma=1}^q \|P_{\gamma} f\|_{F_{\gamma}}$$

- Avec  $P_{\gamma} f$  la projection orthogonale de  $f$  sur  $F_{\gamma}$
- Une formulation équivalente qui est plus facile à résoudre numériquement et qui revient à trouver  $\theta$  et  $f(x) \in F$  minimisant :

$$\frac{1}{n} \sum_{i=1}^n \{y_i - f(\mathbf{x}_i)\}^2 + \lambda_0 \sum_{\gamma} (\theta_{\gamma})^{-1} \|P_{\gamma} f\|_{F_{\gamma}}^2 + \nu \sum_{\gamma} \theta_{\gamma}$$

Sous la contrainte  $\theta_{\gamma} \geq 0$

- $f$  est sous la forme:

$$f(x) = b + \sum_{i=1}^n c_i \sum_{\gamma} \theta_{\gamma} K^{\gamma}(t_i, x)$$



# COSMO (Lin 2006)

## Définition

- Pour  $f(x) \in F$  la procédure COSMO minimise :

$$\frac{1}{n} \sum_{i=1}^n (y_i - f(x_i))^2 + \lambda^2 \sum_{\gamma=1}^q \|P_{\gamma} f\|_{F_{\gamma}}$$

- Avec  $P_{\gamma} f$  la projection orthogonale de  $f$  sur  $F_{\gamma}$
- Une formulation équivalente qui est plus facile à résoudre numériquement et qui revient à trouver  $\theta$  et  $f(x) \in F$  minimisant :

$$\frac{1}{n} \sum_{i=1}^n \{y_i - f(\mathbf{x}_i)\}^2 + \lambda_0 \sum_{\gamma} (\theta_{\gamma})^{-1} \|P_{\gamma} f\|_{F_{\gamma}}^2 + \nu \sum_{\gamma} \theta_{\gamma}$$

Sous la contrainte  $\theta_{\gamma} \geq 0$

Constante positive

Paramètre de régularisation

- $f$  est sous la forme:

$$f(x) = b + \sum_{i=1}^n c_i \sum_{\gamma} \theta_{\gamma} K^{\gamma}(t_i, x)$$



# Algorithme du COSSO

- Paramètres à estimer  $(b, \theta_\gamma, c_i)$  de  $f(x) = b + \sum_{i=1}^n c_i \sum_{\gamma} \theta_\gamma K^\gamma(t_i, x)$

Par la minimisation de :  $\frac{1}{n} \sum_{i=1}^n \{y_i - f(\mathbf{x}_i)\}^2 + \lambda_0 \sum_{\gamma} (\theta_\gamma)^{-1} \|P_\gamma f\|_{F_\gamma}^2 + \nu \sum_{\gamma} \theta_\gamma$



# Algorithme du COSSO

- Paramètres à estimer  $(b, \theta_\gamma, c_i)$  de  $f(x) = b + \sum_{i=1}^n c_i \sum_{\gamma} \theta_\gamma K^\gamma(t_i, x)$

Par la minimisation de :  $\frac{1}{n} \sum_{i=1}^n \{y_i - f(\mathbf{x}_i)\}^2 + \lambda_0 \sum_{\gamma} (\theta_\gamma)^{-1} \|P_\gamma f\|_{F_\gamma}^2 + \nu \sum_{\gamma} \theta_\gamma$

- Algorithme:

Pour  $\theta_\gamma$  fixé

$$\min_{c, b} \|\mathbf{y} - \mathbf{f}\|_n^2 + n\lambda_0 \mathbf{c}^T K_\theta \mathbf{c}$$

étape 1




# Algorithme du COSSO

- Paramètres à estimer  $(b, \theta_\gamma, c_i)$  de  $f(x) = b + \sum_{i=1}^n c_i \sum_{\gamma} \theta_\gamma K^\gamma(t_i, x)$

Par la minimisation de :  $\frac{1}{n} \sum_{i=1}^n \{y_i - f(\mathbf{x}_i)\}^2 + \lambda_0 \sum_{\gamma} (\theta_\gamma)^{-1} \|P_\gamma f\|_{F_\gamma}^2 + \nu \sum_{\gamma} \theta_\gamma$

- Algorithme:






# Algorithme du COSSO

- Paramètres à estimer  $(b, \theta_\gamma, c_i)$  de  $f(x) = b + \sum_{i=1}^n c_i \sum_{\gamma} \theta_\gamma K^\gamma(t_i, x)$

Par la minimisation de :  $\frac{1}{n} \sum_{i=1}^n \{y_i - f(\mathbf{x}_i)\}^2 + \lambda_0 \sum_{\gamma} (\theta_\gamma)^{-1} \|P_\gamma f\|_{F_\gamma}^2 + \nu \sum_{\gamma} \theta_\gamma$

- Algorithme:






# Algorithme du COSSO

- Paramètres à estimer  $(b, \theta_\gamma, c_i)$  de  $f(x) = b + \sum_{i=1}^n c_i \sum_{\gamma} \theta_\gamma K^\gamma(t_i, x)$

Par la minimisation de :  $\frac{1}{n} \sum_{i=1}^n \{y_i - f(\mathbf{x}_i)\}^2 + \lambda_0 \sum_{\gamma} (\theta_\gamma)^{-1} \|P_\gamma f\|_{F_\gamma}^2 + \nu \sum_{\gamma} \theta_\gamma$

- Algorithme:






# Algorithme du COSSO

- Paramètres à estimer  $(b, \theta_\gamma, c_i)$  de  $f(x) = b + \sum_{i=1}^n c_i \sum_{\gamma} \theta_\gamma K^\gamma(t_i, x)$

Par la minimisation de :  $\frac{1}{n} \sum_{i=1}^n \{y_i - f(\mathbf{x}_i)\}^2 + \lambda_0 \sum_{\gamma} (\theta_\gamma)^{-1} \|P_\gamma f\|_{F_\gamma}^2 + \nu \sum_{\gamma} \theta_\gamma$

- Algorithme:






# Algorithme du COSSO

- Paramètres à estimer  $(b, \theta_\gamma, c_i)$  de  $f(x) = b + \sum_{i=1}^n c_i \sum_{\gamma} \theta_\gamma K^\gamma(t_i, x)$

Par la minimisation de :  $\frac{1}{n} \sum_{i=1}^n \{y_i - f(\mathbf{x}_i)\}^2 + \lambda_0 \sum_{\gamma} (\theta_\gamma)^{-1} \|P_\gamma f\|_{F_\gamma}^2 + \nu \sum_{\gamma} \theta_\gamma$

- Algorithme:





# Algorithme COSSO

---

- L'étape 1:

$$\min_{\mathbf{c}, b} \|\mathbf{y} - \mathbf{f}\|_n^2 + n\lambda_0 \mathbf{c}^T K_\theta \mathbf{c}$$

est un problème d'optimisation quadratique pouvant être résolu par des méthodes linéaires

- L'étape 2

$$\min_{\theta} \|\mathbf{z} - D\theta\|_n^2 \quad \text{s.c. } \theta_\gamma \geq 0, \sum_\gamma \theta_\gamma \leq M$$

correspond à un problème d'optimisation quadratique sous contrainte linéaire pour lequel il existe plusieurs techniques de résolution



# Algorithme de COSSO

---

- Dans le cas d'un modèle à haute dimension  $q > n$  les algorithmes testés se sont avérés coûteux en temps de calcul et moins fiables
- On introduit un algorithme itératif qui aboutit à une solution parcimonieuse car elle permet d'obtenir des estimations nulles pour certains  $\theta_\gamma$



# Algorithme itératif

- Soit  $a > 0$  tel que  $\lambda_{\max}(D^T D) \leq a$
- Pour  $a = 1$

## ■ Résoudre

$$\min_{\theta} \|z - D\theta\|_n^2 \quad \text{S.C.} \quad \sum_{\gamma} |\theta_{\gamma}| \leq M$$

Équivaut à (Daubechies 2004)

$$\theta^{[k+1]} = S_{\nu} \left( \theta^{[k]} + D^T (z - D\theta^{[k]}) \right)$$

Où  $S_{\nu}(x) = \text{sgn}(x) (|x| - \nu)_+$  (fonction de seuillage doux)

## ■ Résoudre

$$\min_{\theta} \|z - D\theta\|_n^2 \quad \text{S.C.} \quad \theta_{\gamma} \geq 0$$

Équivaut à (Bertero 1998)

$$\theta^{[k+1]} = P_+ \left( \theta^{[k]} + D^T (z - D\theta^{[k]}) \right)$$

Où  $P_+$  le projecteur sur le cône réels positifs (ensemble convexe)



# Algorithme itératif

Définition :

- Résoudre  $\min_{\theta} \|z - D\theta\|_n^2$  sous  $\theta_{\gamma} \geq 0$  et  $\sum_{\gamma} \theta_{\gamma} \leq M$

Conduit à (pour  $a = 1$ )

$$\theta^{[k+1]} = S_{\nu} \left( P_{+} \left( \theta^{[k]} + D^T (Y - D\theta^{[k]}) \right) \right)$$

Où  $S_{\nu}(x) = \text{sgn}(x)(|x| - \nu)_{+}$  (fonction de seuillage doux)

Et  $P_{+}$  le projecteur sur le cône réels positifs (ensemble convexe)



# Estimation des hyper-paramètres

## Validation croisée stratifiée K-fold-CV :

- Partition de l'ensemble  $E$  des données en  $K$  sous ensembles  $E_1, \dots, E_K$

- Estimation de  $\lambda_0$  :

- Minimisation de l'erreur de prédiction :

$$V(\lambda_0) = \frac{1}{n} \sum_{w=1}^K \sum_{(x_i, y_i) \in E_w} (y_i - \hat{f}_{\lambda_0}^{(w)}(x_i))^2$$

Où  $\hat{f}_{\lambda_0}^{(w)}$  minimise :

$$\frac{1}{n} \sum_{(x_i, y_i) \notin E_w} \{y_i - f(\mathbf{x}_i)\}^2 + \lambda_0 \sum_{\gamma} \|P_{\gamma} f\|_{F_{\gamma}}^2$$

- Estimation de  $\nu$  :

- Minimisation de l'erreur de prédiction :

$$V(\nu) = \frac{1}{n} \sum_{w=1}^K \sum_{(x_i, y_i) \in E_w} (y_i - \hat{f}_{\nu}^{(w)}(x_i))^2$$

Où  $\hat{f}_{\nu}^{(w)}$  minimise :

$$\frac{1}{n} \sum_{(x_i, y_i) \notin E_w} \{y_i - f(\mathbf{x}_i)\}^2 + \lambda_0 \sum_{\gamma} (\theta_{\gamma})^{-1} \|P_{\gamma} f\|_{F_{\gamma}}^2 + \nu \sum_{\gamma} \theta_{\gamma}$$



# Application

---

- Application de la méthode sur des cas analytiques et un cas réservoir
- Définition du critère de la qualité de prédiction :

$$Q2 = 1 - \frac{1/N \sum_{i=1}^N (f(t_i) - \hat{f}(t_i))^2}{\text{var}(f(t_i))}$$



## Application : Cas Analytique

---

- **Modèle de Sobol à 8 paramètres (Saltelli 2000)**


$$f(x) = \prod_{j=1}^8 \frac{|4x_j - 2| + a_j}{1 + a_j}$$

Tel que :

$$a_j = \{0, 1, 2, 4.5, 99, 99, 99, 99\}$$


Q2	n=600
COSMO	0.99

Sur 1000 points de confirmation



# Application : Cas Analytique

- **Modèle de Sobol à 8 paramètres (Saltelli 2000)**





## Application : Cas Analytique

- **Modèle de Morris à 20 paramètres (Saltelli 2000)**

$$Y = \beta_0 + \sum_{i=1}^{20} \beta_i \omega_i + \sum_{i < j}^{20} \beta_{i,j} \omega_i \omega_j + \sum_{i < j < l}^{20} \beta_{i,j,l} \omega_i \omega_j \omega_l + \sum_{i < j < l < s}^{20} \beta_{i,j,l,s} \omega_i \omega_j \omega_l \omega_s$$

Tel que

$$\omega_j = \begin{cases} 2 \times (1.1X_j / (X_j + 0.1) - 0.5) & \text{pour } j = 3,5,7 \\ 2 \times (X_j - 0.5) & \text{sinon} \end{cases}$$

$$\begin{cases} \beta_i = 20 & \text{pour } i = 1, \dots, 10 \\ \beta_{i,j} = -15 & \text{pour } i, j = 1, \dots, 6 \\ \beta_{i,j,l} = -10 & \text{pour } i, j, l = 1, \dots, 5 \\ \beta_{i,j,l,s} = 5 & \text{pour } i, j, l, s = 1, \dots, 4 \end{cases}$$



# Application : cas analytique

---

- Les dix premiers paramètres sont influents :
  - Les six premiers ont une influence significative principalement dû à leurs interaction
  - Les quatre autres sont influents grâce à leurs effets principaux

Q2	n=150	n=300
COSMO	0.82	0.93
Krigeage	0.83	0.89

Sur 1000 points de confirmation



## Application : Cas Analytique

- **Modèle de Sobol à 25 paramètres (Saltelli 2000)**

$$f(x) = \prod_{j=1}^{25} \frac{|4x_j - 2| + a_j}{1 + a_j} + \varepsilon$$

Tel que :  $a_j = \{0,1,2,3,4,5,6,7,8,9,99,\dots,99\}$

$$\varepsilon \sim N(0, \sigma^2)$$

$$SNR \equiv 5 : 1$$

	n=150	n=300	n=450
COSSO	0.38	0.69	0.76
Krigeage	0.26	0.60	0.67

Sur 1000 points de confirmation



## Application : Cas Analytique

- Modèle de Sobol à 25 paramètres (Saltelli 2000)

$$f(x) = \prod_{j=1}^{25} \frac{|4x_j - 2| + a_j}{1 + a_j} + \varepsilon$$

Tel que :  $a_j = \{0,1,2,3,4,5,6,7,8,9,99,\dots,99\}$

$$\varepsilon \sim N(0, \sigma^2)$$

$$SNR \equiv 5:1$$

$$SNR = \frac{\text{var}(f)}{\sigma^2}$$


	n=150	n=300	n=450
COSSO	0.38	0.69	0.76
Krigeage	0.26	0.60	0.67

Sur 1000 points de confirmation



# Application : Réservoir synthétique

- Basé sur un champ réel
- 6 puits de production
- La présence d'un aquifère ne nécessite pas le forage d'injecteurs
  
- Modèle d'une des sorties du simulateur à 27 paramètres



Q2	100
COSSO	0.82
Krigeage	0.72

Sur 1000 points de confirmation



# Perspectives

---

- Amélioration de l'estimation des hyper-paramètres
- Accélération de la convergence de l'algorithme itératif
- Utilisation du COSSO pour effectuer l'analyse de sensibilité: calcul des indices de sensibilité à partir des coefficients de noyaux
- Extension de la méthode aux réponses fonctionnelles (*i.e.* cumulé d'huile en fonction du temps)