

GdR MASCOT-NUM 2009

18-19-20 Mars 2009

Université Paris 13, Institut Galilée

Calcul à coût réduit des indices de Sobol' par apprentissage SVM

C. Mattrand, J.-M. Bourinet, M. Lemaire

cmattrand@ifma.fr

LaMI / IFMA - Clermont-Ferrand, France



- ▲ **Analyses probabilistes : Quantifier l'influence de l'aléa des variables d'entrée**
 - ↳ sur une probabilité fonction des variables d'entrée et grandeurs de sortie: **analyses de fiabilité**
 - ↳ sur une sortie du modèle: **analyses de sensibilité**
- ▲ **Analyses de sensibilité dite globale**
 - ↳ **Méthodes quantitatives** permettant de **mesurer la contribution** de chaque v.a. (ou groupe de v.a.) d'entrée sur la sortie d'un modèle numérique traduisant un comportement physique
 - ↳ **Indices de Sobol'**: basées sur la mesure de la **réduction de la variance** de la sortie d'un modèle lorsqu'une ou plusieurs variables sont fixées
- ▲ **Développer une stratégie de calcul à coût réduit des indices de Sobol'**
 - ↳ Substituer le modèle numérique par une surface de réponse: régression SVR
- ▲ **Analyses de sensibilité globale appliquées à des exemples de mécanique**
 - ↳ Exemple analytique Ellingwood (*Nie & Ellingwood, 2004*)
 - ↳ Tuyau fissuré - Modèle EF - Code_Aster (*Berveiller, 2005*)

Analyses de sensibilité globale

- ▶ Rappels sur les indices de Sobol'
- ▶ Estimation des indices de Sobol'

▲ Notations

$\underline{X} = \langle X_1, X_2, \dots, X_d \rangle^t \in \mathbb{R}^d$ Vecteur aléatoire de **variables indépendantes**

$f : \mathbb{R}^d \rightarrow \mathbb{R}$ Modèle numérique de grandeur de sortie Y

$$\underline{X} \rightarrow Y = f(\underline{X})$$

▲ Décroissance de la variance de Y pour une v.a. X_i fixée à x_i

$E[V(Y|X_i = x_i)]$ sur l'espace des possibles x_i

▲ Théorème de la variance totale

$$V(Y) = V(E[Y|X_i]) + E[V(Y|X_i)]$$

▲ Indice de Sobol' du 1^{er} ordre

$0 \leq S_i = \frac{V(E[Y|X_i])}{V(Y)} \leq 1$ mesurent la sensibilité de la sortie à une v.a.

▲ Décomposition de la fonction f

$$Y = f(\underline{X}) = f_0 + \sum_{i=1}^d f_i(X_i) + \sum_{1 \leq i < j \leq d} f_{ij}(X_i, X_j) + \dots + f_{1, \dots, d}(X_1, \dots, X_d)$$

▲ Indices du 2nd ordre et ordres supérieurs

↳ Mesurent la sensibilité de la sortie à l'interaction entre deux v.a. (et plus) non prise en compte dans les indices du 1^{er} ordre

$$S_{ij} = \frac{V(f_{ij}(X_i, X_j))}{V(Y)} = \frac{V_{ij}}{V(Y)} = \frac{V(E[Y|X_i, X_j]) - V_i - V_j}{V(Y)} \quad S_{ijk} = \frac{V_{ijk}}{V(Y)}$$

▲ Caractéristiques des indices de Sobol'

↳ $2^d - 1$ indices et $\sum_{i=1}^d S_i + \sum_{1 \leq i < j \leq d} S_{ij} + \dots + S_{1, \dots, d} = 1$

▲ Indices totaux

↳ (Homma & Saltelli, 1996)

$$S_{T_i} = \sum_{i \subseteq k} S_k \quad S_{T_i} = \frac{E[V(Y|X_{\sim i})]}{V(Y)}$$

▲ Estimation de l'espérance et de la variance de $f(X_1, X_2, \dots, X_d)$

$$\tilde{E} = \frac{1}{N} \sum_{k=1}^N f(x_{k1}, x_{k2}, \dots, x_{kd}) \quad \tilde{V} = \frac{1}{N} \sum_{k=1}^N f^2(x_{k1}, x_{k2}, \dots, x_{kd}) - \tilde{E}^2$$

Echantillon de N réalisations des d variables aléatoires

▲ Indices du 1^{er} ordre

$$S_i = \frac{V(E[Y|X_i])}{V(Y)}$$

$$V_i = V(E[Y|X_i])$$

$$= E[E^2[Y|X_i]] - E^2[E[Y|X_i]]$$

$$= U_i - E^2[Y]$$

$$\tilde{U}_i = \frac{1}{N} \sum_{k=1}^N f(x_{k1}^{(1)}, x_{k2}^{(1)}, \dots, x_{k(i-1)}^{(1)}, x_{ki}^{(1)}, x_{k(i+1)}^{(1)}, \dots, x_{kd}^{(1)}) \times f(x_{k1}^{(2)}, x_{k2}^{(2)}, \dots, x_{k(i-1)}^{(2)}, x_{ki}^{(1)}, x_{k(i+1)}^{(2)}, \dots, x_{kd}^{(2)})$$

2 échantillons de N réalisations des d variables aléatoires

▲ Estimation de l'espérance et de la variance de $f(X_1, X_2, \dots, X_d)$

Meilleure estimation des indices de Sobol' si
(Saltelli, 2002)

$$\tilde{V} = \frac{1}{N} \sum_{k=1}^N f^2(x_{k1}, x_{k2}, \dots, x_{kd}) - \tilde{E}^2$$

$$\tilde{E}^2 = \frac{1}{N} \sum_{k=1}^N f(x_{k1}^{(1)}, x_{k2}^{(1)}, \dots, x_{k(i-1)}^{(1)}, x_{ki}^{(1)}, x_{k(i+1)}^{(1)}, \dots, x_{kd}^{(1)}) f(x_{k1}^{(2)}, x_{k2}^{(2)}, \dots, x_{k(i-1)}^{(2)}, x_{ki}^{(2)}, x_{k(i+1)}^{(2)}, \dots, x_{kd}^{(2)})$$

▲ Indices du 1^{er} ordre $S_i = \frac{V(E[Y|X_i])}{V(Y)}$

$$V_i = V(E[Y|X_i])$$

$$= E[E^2[Y|X_i]] - E^2[E[Y|X_i]]$$

$$= U_i - E^2[Y]$$

$$\tilde{U}_i = \frac{1}{N} \sum_{k=1}^N f(x_{k1}^{(1)}, x_{k2}^{(1)}, \dots, x_{k(i-1)}^{(1)}, x_{ki}^{(1)}, x_{k(i+1)}^{(1)}, \dots, x_{kd}^{(1)}) \times f(x_{k1}^{(2)}, x_{k2}^{(2)}, \dots, x_{k(i-1)}^{(2)}, x_{ki}^{(1)}, x_{k(i+1)}^{(2)}, \dots, x_{kd}^{(2)})$$

2 échantillons de N réalisations des d variables aléatoires

▲ Nombre d'appels au modèle pour le calcul des indices

- ↳ Indices du 1^{er} ordre : $(d+2)N$
- ↳ Indices de tous les ordres : $(2^d+1)N$
- ↳ Indices totaux : $(d+2)N$

▲ Méthodes de simulation

- ↳ Monte Carlo Classique (CMC)
- ↳ Quasi Monte Carlo (QMC):
Suites de Sobol' randomisées
(*J. Jacques, 2005*)

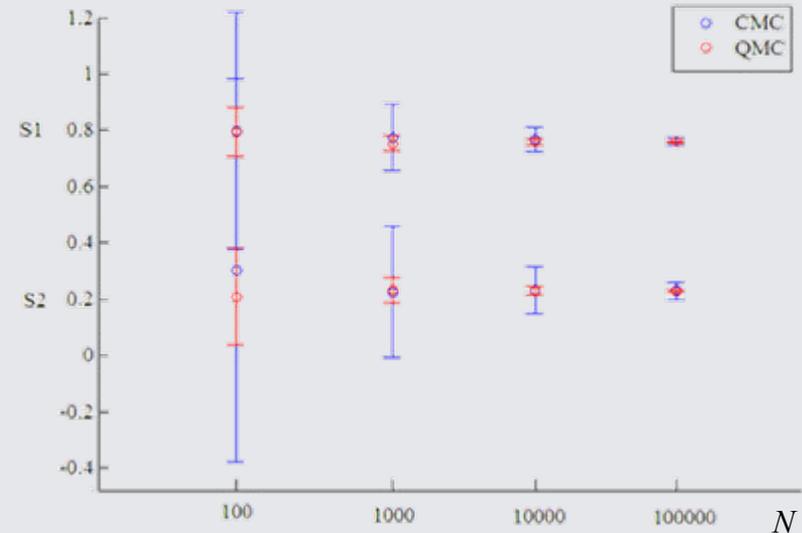
▲ Estimation répétée 30 fois

- ↳ Moyenne & Ecart type pour chaque indice

▲ Exemple 2 v.a.

$$X_1 \sim N(10,2) \quad X_2 \sim N(2,1)$$

$$Y = f(\underline{X}) = X_1 - X_2$$



Intervalle de confiance à 95%

Machines à Vecteurs Supports

- ▶ Régression SVR
- ▶ Influence du choix des paramètres sur la solution SVR
- ▶ Points délicats dans la construction d'une régression SVR

▲ Machines à vecteurs supports (*Support Vector Machines - Vapnik, 1963*)

↳ Concevoir un algorithme qui après avoir observé n couples (données, réponse) parvienne à simuler la réponse à une **nouvelle** entrée \underline{x}

$$\left(\underline{x}_i, y_i = f(\underline{x}_i) \right), i \in \{1, \dots, n\}, \underline{x}_i \in \mathbb{R}^d \quad \text{couples (données, réponse)}$$

↳ Apprendre un modèle en l'approchant par une fonction simple

▲ 2 Catégories de méthodes

↳ **Classification:** Séparer l'espace des données en construisant un séparateur (plutôt adaptée à une analyse de fiabilité)

↳ **Régression:** Construire un substitut du modèle sur son ensemble de définition (plutôt adaptée à l'analyse de sensibilité globale quantitative)

Principe de l' ε -tube

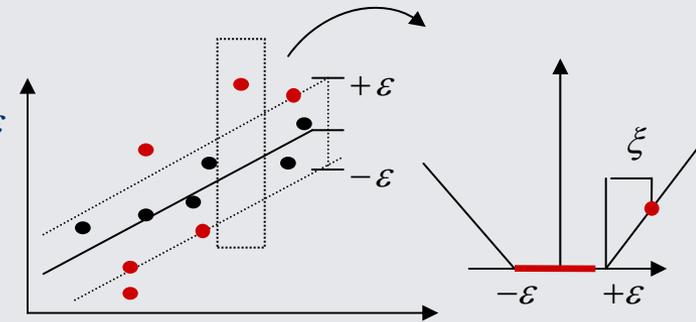
- ↳ Base d'apprentissage $(\underline{x}_i, y_i = f(\underline{x}_i))$, $i \in \{1, \dots, n\}$, $\underline{x}_i \in \mathbb{R}^d$
- ↳ Recherche d'un substitut de $f(\underline{X})$ noté $\hat{f}(\underline{X})$ telle que la distance entre y_i et $\hat{f}(\underline{x}_i)$ soit inférieur à ε
- ↳ Erreur parfois tolérée : introduction de variables de pénalisation ξ et du paramètre de contrôle C

↳ Problème d'optimisation

$$\min_{\underline{\omega}, b} \frac{\|\underline{\omega}\|^2}{2} + C \sum_{i=1}^n (\xi_i + \xi_i^*)$$

$$\text{s.c.} \begin{cases} y_i - \langle \underline{\omega}, \underline{x}_i \rangle - b \leq \varepsilon + \xi_i \\ \langle \underline{\omega}, \underline{x}_i \rangle + b - y_i \leq \varepsilon - \xi_i^* \\ \xi_i, \xi_i^* \geq 0 \end{cases}$$

$$|\xi|_{\varepsilon} = \begin{cases} 0 & \text{pour } |\xi| \leq \varepsilon \\ |\xi| - \varepsilon & \end{cases}$$



Cas linéaire $\hat{f}(\underline{X}) = \langle \underline{\omega}, \underline{X} \rangle + b$

$$\underline{\omega} = \sum_{i=1}^n (\alpha_i - \alpha_i^*) \underline{x}_i$$

$$\hat{f}(\underline{x}) = \sum_{i=1}^n (\alpha_i - \alpha_i^*) \langle \underline{x}_i, \underline{x} \rangle + b$$

$$\alpha_i - \alpha_i^* \neq 0$$

Vecteurs supports

Principe de l' ε -tube

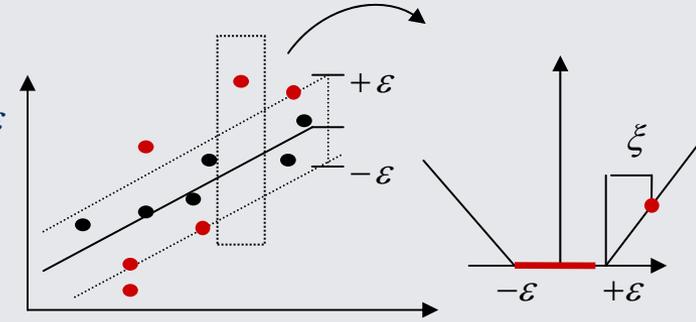
Nombre de points?

Placement dans l'espace?

- ↳ Base d'apprentissage $(\underline{x}_i, y_i = f(\underline{x}_i))$, $i \in \{1, \dots, n\}$, $\underline{x}_i \in \mathbb{R}^d$
- ↳ Recherche d'un substitut de $f(\underline{X})$ noté $\hat{f}(\underline{X})$ telle que la distance entre y_i et $\hat{f}(\underline{x}_i)$ soit inférieure à ε
- ↳ Erreur parfois tolérée : introduction de variables de pénalisation ξ et du paramètre de contrôle C

↳ Problème d'optimisation

$$|\xi|_\varepsilon = \begin{cases} 0 & \text{pour } |\xi| \leq \varepsilon \\ |\xi| - \varepsilon & \text{sinon} \end{cases}$$



$$\min_{\underline{\omega}, b} \frac{\|\underline{\omega}\|^2}{2} + C \sum_{i=1}^n (\xi_i + \xi_i^*)$$

$$\text{s.c.} \begin{cases} y_i - \langle \underline{\omega}, \underline{x}_i \rangle - b \leq \varepsilon + \xi_i \\ \langle \underline{\omega}, \underline{x}_i \rangle + b - y_i \leq \varepsilon - \xi_i^* \\ \xi_i, \xi_i^* \geq 0 \end{cases}$$

Cas linéaire $\hat{f}(\underline{X}) = \langle \underline{\omega}, \underline{X} \rangle + b$

$$\underline{\omega} = \sum_{i=1}^n (\alpha_i - \alpha_i^*) \underline{x}_i$$

$$\hat{f}(\underline{x}) = \sum_{i=1}^n (\alpha_i - \alpha_i^*) \langle \underline{x}_i, \underline{x} \rangle + b$$

$$\alpha_i - \alpha_i^* \neq 0$$

Vecteurs supports

Principe de l' ϵ -tube

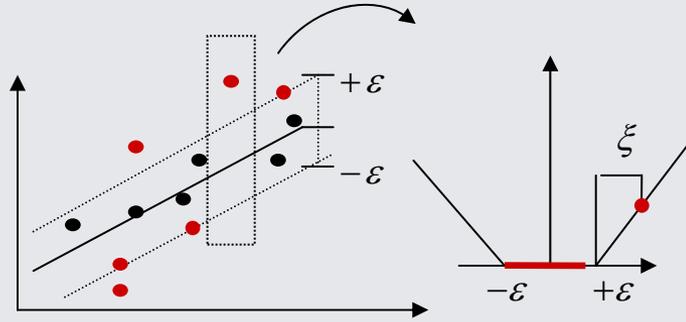
Nombre de points?

Placement dans l'espace?

- ↳ Base d'apprentissage $(\underline{x}_i, y_i = f(\underline{x}_i))$, $i \in \{1, \dots, n\}$, $\underline{x}_i \in \mathbb{R}^d$
- ↳ Recherche d'un substitut de $f(\underline{X})$ noté $\hat{f}(\underline{X})$ telle que la distance entre y_i et $\hat{f}(\underline{x}_i)$ soit inférieure à ϵ
- ↳ Erreur parfois tolérée : introduction de variables de pénalisation ξ et du paramètre de contrôle C

↳ Problème d'optimisation

$$|\xi|_\epsilon = \begin{cases} 0 & \text{pour } |\xi| \leq \epsilon \\ |\xi| - \epsilon & \end{cases}$$



$$\min_{\omega, b} \frac{\|\omega\|^2}{2} + C \sum_{i=1}^n (\xi_i + \xi_i^*)$$

$$\text{s.c.} \begin{cases} y_i - \langle \omega, \underline{x}_i \rangle - b \leq \epsilon + \xi_i \\ \langle \omega, \underline{x}_i \rangle + b - y_i \leq \epsilon - \xi_i^* \\ \xi_i, \xi_i^* \geq 0 \end{cases}$$

Cas linéaire $\hat{f}(\underline{X}) = \langle \omega, \underline{X} \rangle + b$

$$\omega = \sum_{i=1}^n (\alpha_i - \alpha_i^*) \underline{x}_i$$

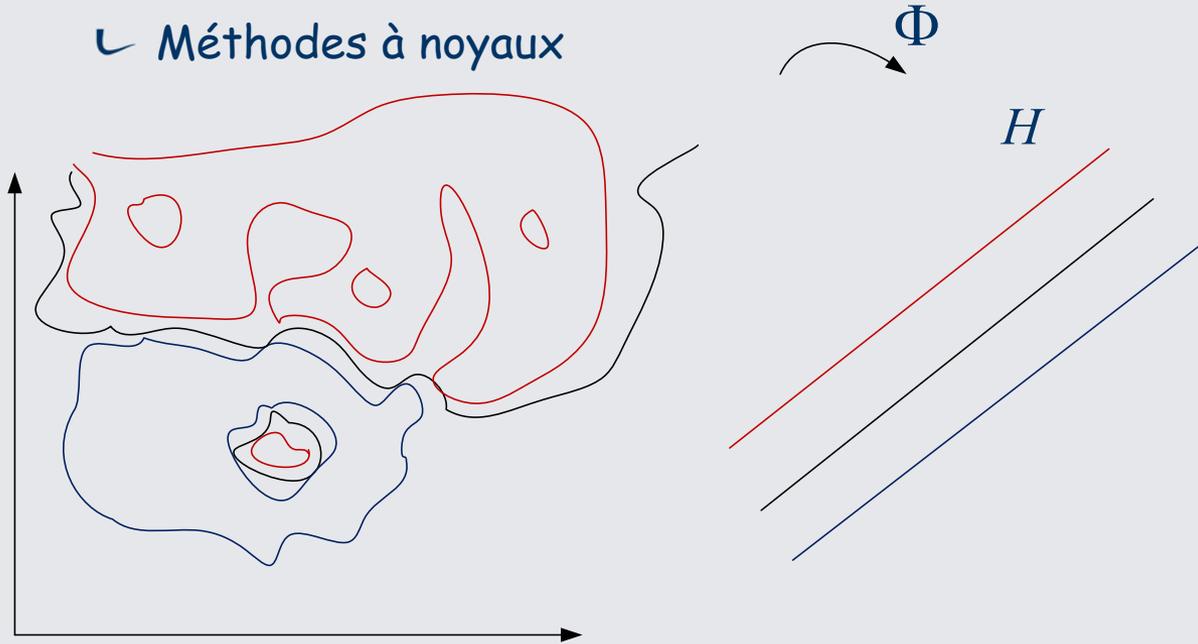
$$\hat{f}(\underline{x}) = \sum_{i=1}^n (\alpha_i - \alpha_i^*) \langle \underline{x}_i, \underline{x} \rangle + b$$

$$\alpha_i - \alpha_i^* \neq 0$$

Vecteurs supports

▲ Régression SVR dans le cas non linéaire

↳ Méthodes à noyaux



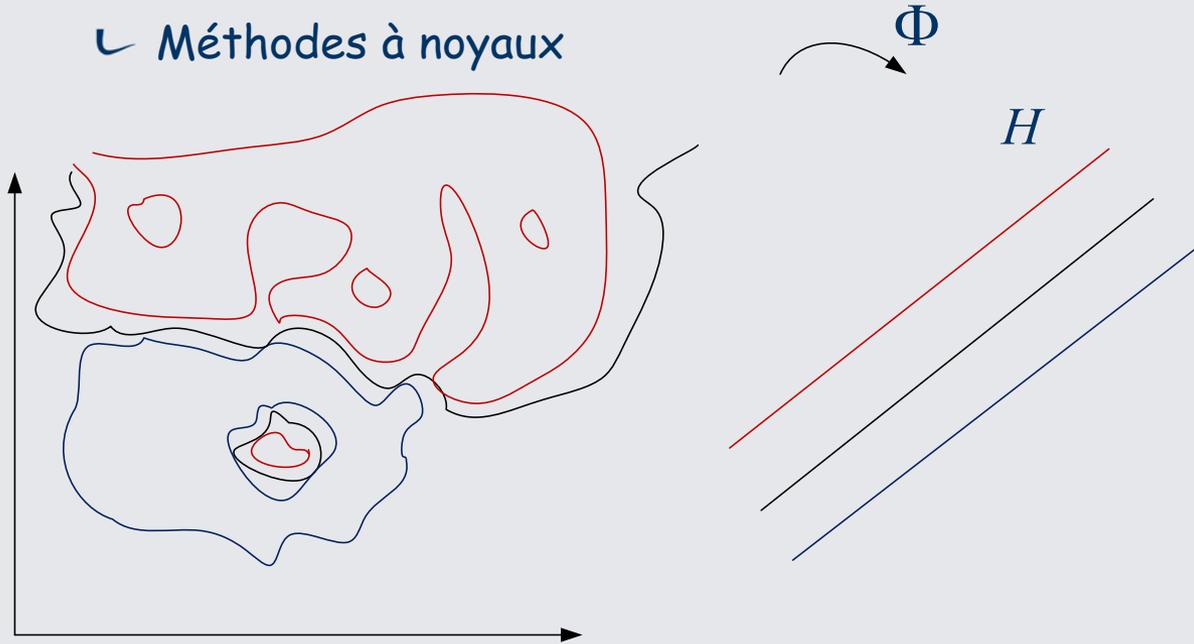
Transformation de l'espace physique en un espace support H par un projecteur non linéaire Φ

Espace vectoriel H : $\left\langle \sum_i \beta_i \Phi(\underline{x}_i), \sum_j \gamma_j \Phi(\underline{x}_j) \right\rangle = \sum_{ij} \beta_i \gamma_j K(\underline{x}_i, \underline{x}_j)$

Noyau gaussien : $K(\underline{x}, \underline{x}') = \exp\left(-\frac{\|\underline{x} - \underline{x}'\|^2}{2\sigma^2}\right) \rightarrow \hat{f}(\underline{x}) = \sum_{i=1}^n (\alpha_i - \alpha_i^*) K(\underline{x}_i, \underline{x}) + b$

▲ Régression SVR dans le cas non linéaire

↳ Méthodes à noyaux



Transformation de l'espace physique en un espace support H par un projecteur non linéaire Φ

Espace vectoriel H : $\left\langle \sum_i \beta_i \Phi(\underline{x}_i), \sum_j \gamma_j \Phi(\underline{x}_j) \right\rangle = \sum_{ij} \beta_i \gamma_j K(\underline{x}_i, \underline{x}_j)$

Noyau gaussien : $K(\underline{x}, \underline{x}') = \exp\left(-\frac{\|\underline{x} - \underline{x}'\|^2}{2\sigma^2}\right) \rightarrow \hat{f}(\underline{x}) = \sum_{i=1}^n (\alpha_i - \alpha_i^*) K(\underline{x}_i, \underline{x}) + b$

← Choix du noyau?

Stratégie de calcul des indices de Sobol' à coût réduit

- ▶ Principe de la stratégie
- ▶ Génération de la base d'apprentissage
- ▶ Grille de recherche des hyper paramètres

Substituer f par
une SVR

1. Base d'apprentissage

- Nombre de couples, n $\left(u_i, y_i = \frac{f(u_i) - f_{\min}}{f_{\max} - f_{\min}} \right)$

- Génération déterministe, espace standard

▶ Hypersphère Multinormale ▶

2. Choix des hyper paramètres

- $C = 1000000$

- Grille de recherche (ε, σ) :

σ : [1 2 5 7 8 10 15 20 50 100]

$\log(\varepsilon/2)$: [-11:1:-1]

3. Critères de choix

Erreur empirique minimale & Validation croisée

Nombre de v.a. d
Taille échantillon (QMC):
 $N = 10\ 000$

Calculs des indices de
Sobol' sur la SVR

Indices de Sobol' 1^{er} ordre
Indices de Sobol' ordre sup.
Indices de Sobol' totaux

➔ Appels au modèle $f = n$

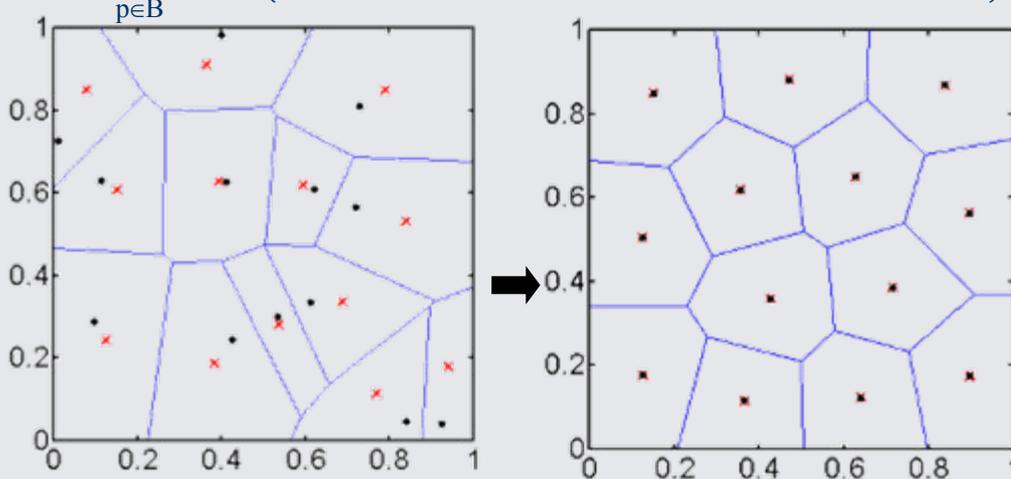
x 30

▲ Espace de construction de la régression SVR

↳ Espace standard = Espace des variables gaussiennes centrées réduites \underline{U}

▲ Placement uniforme des points dans une hypersphère : Cellules de Voronoï Tesselation

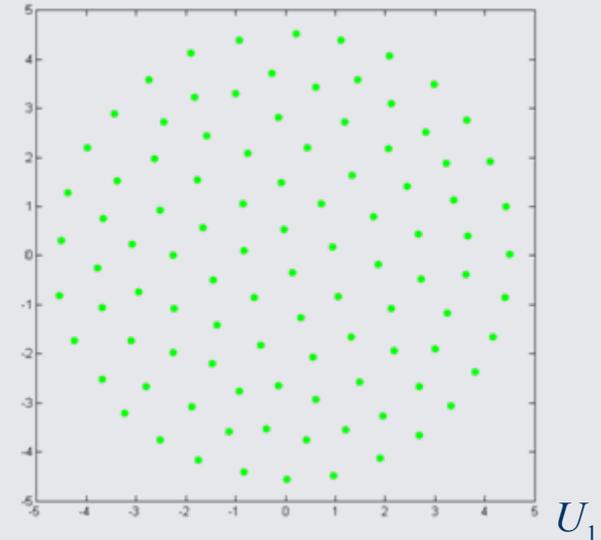
$$CVT(p) = \left\{ x \in [0,1]^d \mid \forall q \in B, d(x,p) \leq d(x,q) \right\}$$



(Hanson, 2005)

• Point aléatoire × Centre CVT

U_2 $n = 100$



▲ Rayon de l'hypersphère

Rayon maximal d'un échantillon $N = 10000$
gaussien standard



Substituer f par une SVR

1. Base d'apprentissage

- Nombre de couples, n $\left(u_i, y_i = \frac{f(u_i) - f_{\min}}{f_{\max} - f_{\min}} \right)$

- Génération déterministe, espace standard

▶ Hypersphère Multinormale ▶

2. Choix des hyper paramètres

- $C = 1000000$

- Grille de recherche (ϵ, σ) :

σ : [1 2 5 7 8 10 15 20 50 100]

$\log(\epsilon/2)$: [-11:1:-1]

3. Critères de choix

Erreur empirique minimale & Validation croisée

Nombre de v.a. d
Taille échantillon (QMC):
 $N = 10\ 000$

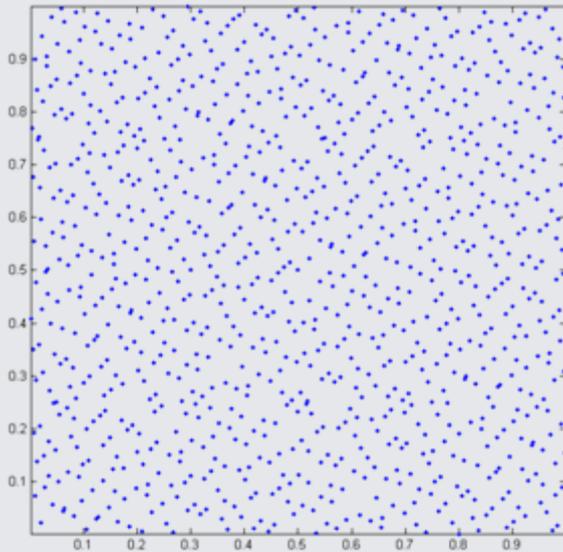


Indices de Sobol' 1^{er} ordre
Indices de Sobol' ordre sup.
Indices de Sobol' totaux

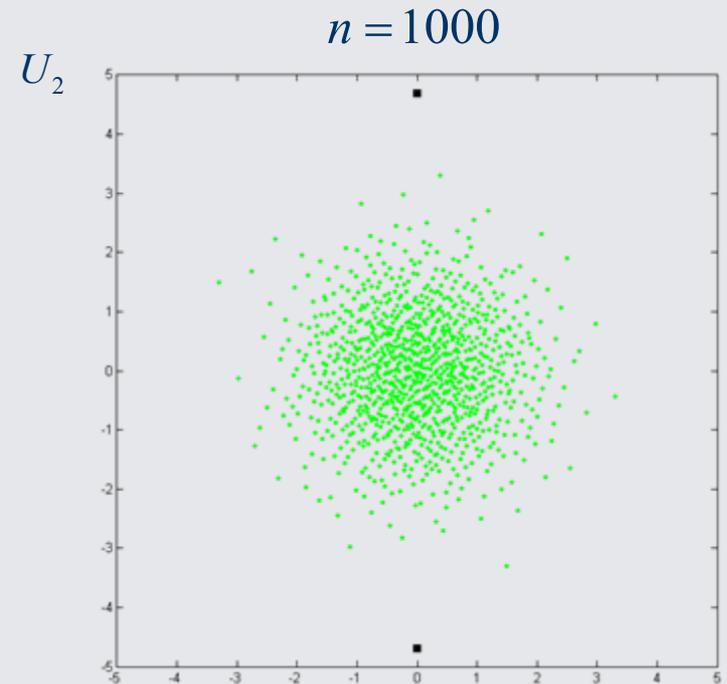
➔ Appels au modèle $f = n$

- ▲ Espace de construction de la régression SVR
 - ↳ Espace standard = Espace des variables gaussiennes centrées réduites
- ▲ Génération des suites de Sobol' déterministes sur l'hypercube $[0,1]^d$ puis transformation isoprobabiliste suivant la multinormale dans l'espace standard

Suites de Sobol'



Transformation isoprobabiliste



U_1

Substituer f par une SVR

1. Base d'apprentissage

- Nombre de couples, n $\left(u_i, y_i = \frac{f(u_i) - f_{\min}}{f_{\max} - f_{\min}} \right)$

- Génération déterministe, espace standard

▶ Hypersphère Multinormale ▶

2. Choix des hyper paramètres

- $C = 1000000$

- Grille de recherche (ε, σ) :

σ : [1 2 5 7 8 10 15 20 50 100]

$\log(\varepsilon/2)$: [-11:1:-1]

3. Critères de choix

Erreur empirique minimale & Validation croisée

Nombre de v.a. d
Taille échantillon (QMC):
 $N = 10\ 000$



Calculs des indices de Sobol' sur la SVR



x 30

Indices de Sobol' 1^{er} ordre
Indices de Sobol' ordre sup.
Indices de Sobol' totaux

➔ Appels au modèle $f = n$

Applications

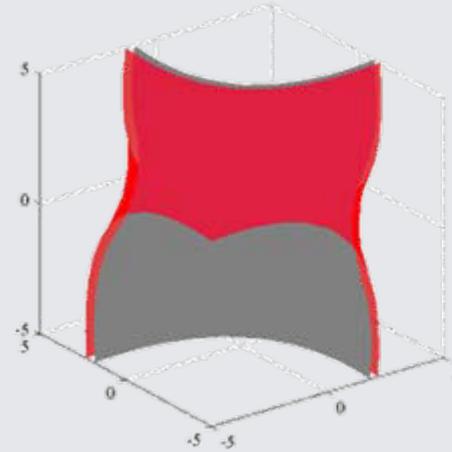
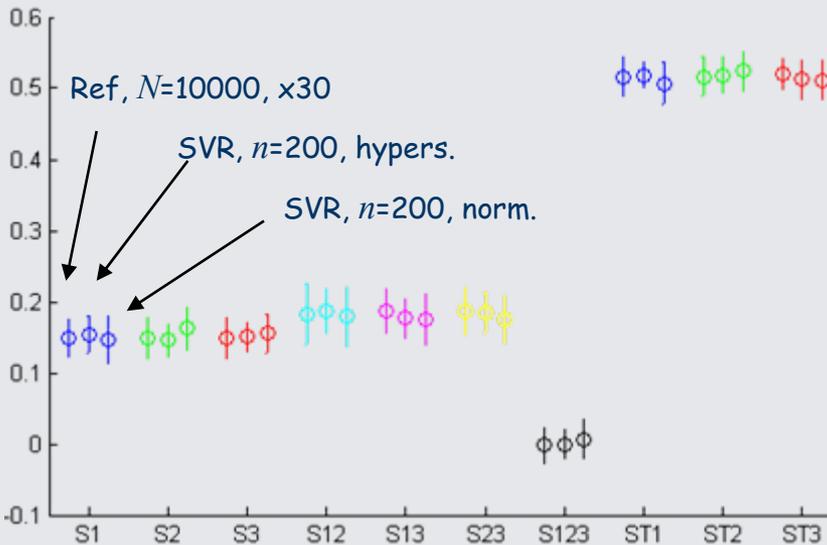
- ▶ *Modèle Ellingwood (Nie & Ellingwood, 2004)*
- ▶ *Tuyau fissuré - Code Aster (Berveiller, 2005)*

▲ Variables aléatoires indépendantes

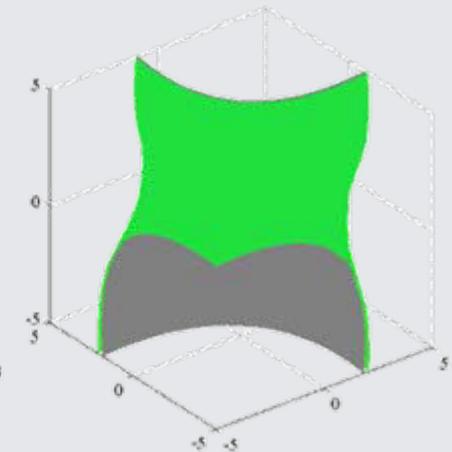
$$X_1 \sim N(0,1) \quad X_2 \sim N(0,1) \quad X_3 \sim N(0,1)$$

▲ Modèle analytique

$$f(x) = -0.5(x_1^2 + x_2^2 + x_3^2 - 2x_1x_2 - \dots - 2x_1x_3 - 2x_2x_3) - \frac{(x_1 + x_2 + x_3)}{\sqrt{3}} + 3$$



Base : Multinormale



Base : Hypersphère uniforme

$$n = 200, \sigma = 50, \varepsilon = 4,8810^{-4}, C = 1000000$$

▲ Coût sans SVR : nombre d'appels à f

- ↳ Indices tout ordre : $[(2^3+1) \times 10000] \times 30$
- ↳ Indices totaux : $[(3+2) \times 10000] \times 30 = 1500000$

▲ Coût avec SVR : nombre d'appels à f

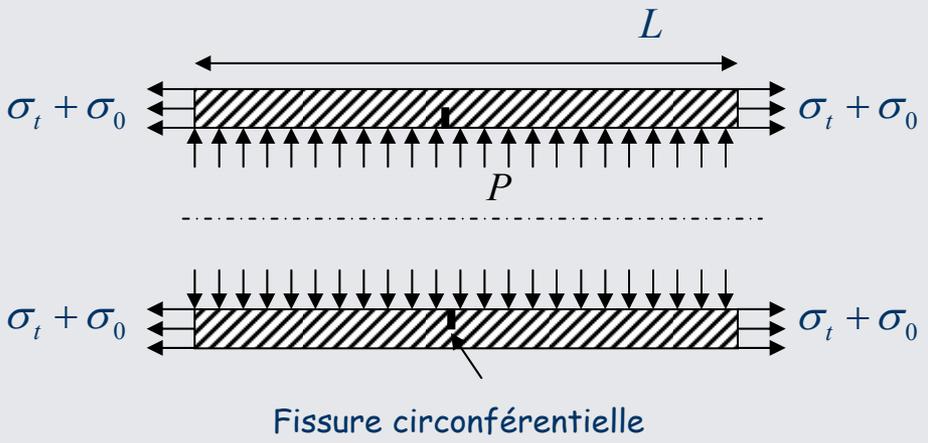
- ↳ Indices tout ordre + totaux : $n = 200$

▲ Remarque

- ↳ Interaction du 2nd ordre



▲ Structure Etudiée



▲ Données du problème

- Longueur de fissure: $a = 15\text{mm}$
- Longueur de tuyauterie: $L = 1000\text{mm}$
- Pression interne: $P = 15.5\text{MPa}$
- Rayon interne de tuyau: $R_i = 393.5\text{mm}$
- Epaisseur de tuyau: $t = 62.5\text{mm}$
- Contrainte de traction appliquée: $\sigma_t = 135\text{MPa}$

Contrainte de traction due à l'effet de fond: $\sigma_0 = P \frac{R_i^2}{(R_i + t)^2 - R_i^2}$

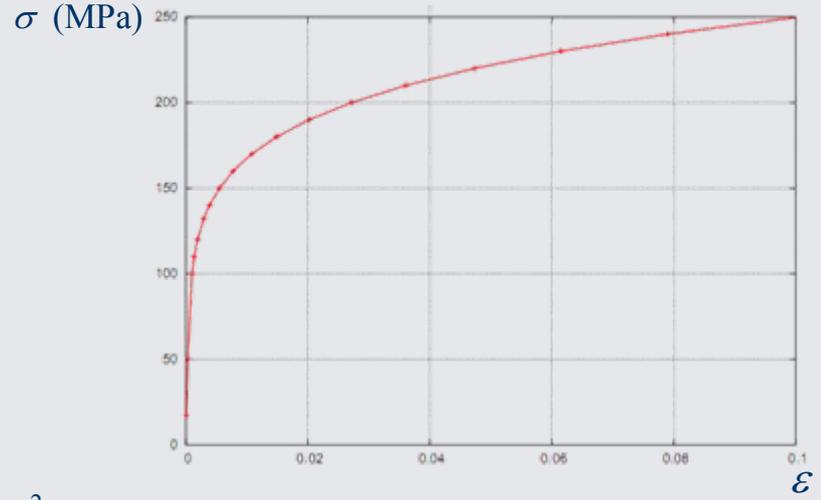
▲ Calculs EF: Code_Aster

↳ <http://www.code-aster.org>

▲ Comportement du matériau

↳ Loi Ramberg Osgood : non linéaire

$$\varepsilon = \frac{\sigma}{E} + \alpha \frac{\sigma_y}{E} \left(\frac{\sigma}{\sigma_y} \right)^n$$



▲ Analyse de fiabilité

État limite : $g = J_{0.2} - J(E, \sigma_y, n, \alpha)$ $J = \int_{\Gamma} \left(W dy - T \frac{\partial u}{\partial x} ds \right)$: Intégrale de Rice, 1 calcul EF \approx 8 min

Variables aléatoires indépendantes	Notation	Loi	Moyenne	Coefficient de variation
Module d'Young	E	Lognormale	175500 MPa	5%
Coefficient de lissage	α	Normale	1.15	13%
Coefficient d'érouissage	n	Normale	3.5	3%
Limite d'élasticité	σ_y	Lognormale	259.5 MPa	3.8%
Ténacité	$J_{0.2}$	Lognormale	52 MPa.mm	18.27%

▲ Résultats FORM et sensibilités globales sur SVR, base: hypersphère uniforme, $n = 200$

Nombre itérations: 4

Nombre d'appels à g : 42

Indice de fiabilité: $\beta = 3.09$

Probabilité de défaillance: $p_f = 9.89 \cdot 10^{-4}$

Facteurs d'importance	Indices Totaux	Moyenne	Ecart-type
α^2_E	ST_E	0.0016	0.0015
α^2_α	ST_α	0.007	0.0106
α^2_n	ST_n	0.0013	0.0110
$\alpha^2_{\sigma_y}$	ST_{σ_y}	0.0015	0.0107
$\alpha^2_{J_{0.2}}$	$ST_{J_{0.2}}$	0.9917	0.0106

▲ Modèle numérique

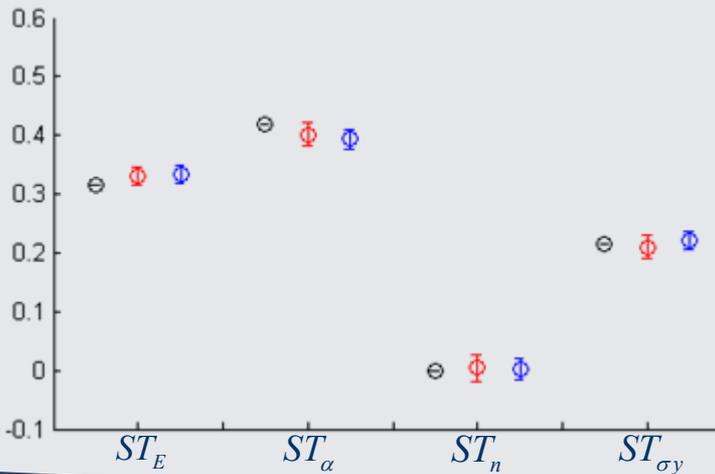
$$f(E, \sigma_y, n, \alpha) = J(E, \sigma_y, n, \alpha)$$

▲ Indices de Sobol' de référence

Modèle directement

$N = 5000$, Coût = $(d + 2)N = 30000$

ST_E	0.314
ST_α	0.420
ST_n	≈ 0
ST_{σ_y}	0.215



▲ Indices de Sobol' sur SVR

SVR, base d'apprentissage : hypersphère uniforme
rayon R

$n = 200$, $R = 5.3$, $\sigma = 50$, $\varepsilon = 0.0039$, $C = 1000000$
 $N = 10000 \times 30$, Coût = $n = 200$

	moyenne	Ecart type		moyenne	Ecart type
S_E	0.364	0.006	ST_E	0.331	0.009
S_α	0.437	0.006	ST_α	0.402	0.01
S_n	0.018	0.001	ST_n	≈ 0	0.012
S_{σ_y}	0.244	0.006	ST_{σ_y}	0.210	0.01

SVR, base d'apprentissage : multinormale

$n = 500$, $\sigma = 50$, $\varepsilon = 0.0039$, $C = 1000000$
 $N = 10000 \times 30$, Coût = $n = 500$

	moyenne	Ecart type		moyenne	Ecart type
S_E	0.366	0.006	ST_E	0.333	0.007
S_α	0.428	0.007	ST_α	0.394	0.009
S_n	0.016	0.0003	ST_n	≈ 0	0.009
S_{σ_y}	0.254	0.005	ST_{σ_y}	0.220	0.008

▲ Bilan de la stratégie de calcul à coût réduit des indices de Sobol'

- ↳ Méthode validée sur deux exemples : 1 modèle analytique et un modèle numérique
- ↳ Gain considérable en terme d'appels au modèle et donc en temps de calculs
- ↳ Influence de la base sur la solution SVR et donc sur l'estimation des indices de Sobol'

▲ Perspectives d'améliorations

- ↳ Tester la robustesse de la méthode sur des exemples en grandes dimensions
- ↳ Améliorer la génération de la base d'apprentissage: seules deux méthodes ont été testées : hypersphère uniforme de rayon choisi et multinormale
- ↳ Améliorer la recherche des hyper paramètres optimaux

Calcul à coût réduit des indices de Sobol' par apprentissage SVM

C. Mattrand, J.-M. Bourinet, M. Lemaire
IFMA / LaMI, Clermont-Ferrand, France

Merci de votre attention
Questions?