

# Analyse de sensibilité généralisée à base de noyaux

## Application aux entrées / sorties fonctionnelles

Sébastien Da Veiga

Snecma

Séminaire MIA INRA 30/01/2015

# PLAN

## → Contexte et problématique

- Décomposition de Sobol – ANOVA fonctionnelle

## → Analyse de sensibilité généralisée

- Cadre général à base de densités
- Vers de nouveaux indices de sensibilité

## → Décompositions orthogonales pour GSA généralisée


- Décomposition 1
- Décomposition 2
- Le cas des données fonctionnelles

## → Conclusions et perspectives


**/01/**

# CONTEXTE ET PROBLÉMATIQUE

# CONTEXTE



# UNE PROBLÉMATIQUE MULTI-SECTORIELLE



# CONTEXTE

## → Enjeux

- Comprendre l'influence des incertitudes
  - *Orienter les choix de modélisation*
  - *Prioriser les efforts de R&D*
  - *Conduire des actions supplémentaires*
  
- Donner du crédit à un modèle
  - *Atteindre un niveau de qualité acceptable pour son utilisation*
  - *Calibrer les paramètres du modèle*
  - *Réduire l'incertitude des sorties du modèle pour améliorer la prédiction*
  
- Démontrer la conformité du système avec un critère explicite ou un seuil réglementaire
  
- ...

# CONTEXTE

## → Caractéristiques propres aux gros codes numériques

- Coût calculatoire très élevé
  - ~ 10mn – qqs heures
- Un très grand nombre de paramètres
  - *Calibrés, réglage simulation, convergence algo résolution EDP, ...*
- Des sorties complexes
  - *Courbes d'évolution, cartes ou cubes 3D de propriétés physiques, ...*
- Plusieurs codes de complexité différente pour simuler le même phénomène physique
  - *Modèles analytiques, modèles 1D / 2D, choix taille maillage et discrétisation temporelle pour résolution EDP, ...*
- ...

# CONTEXTE

## → La démarche “standard” de traitement des incertitudes

- Comment modéliser les incertitudes sur les paramètres d'entrée ?
  - *Expériences labo, avis d'experts, calibration, ...*
- Comment estimer la dispersion de la sortie d'un modèle en fonction de la dispersion des paramètres d'entrée ?
  - *MC, QMC, IS*
- Comment estimer la sensibilité de la sortie d'un code vis-à-vis d'un paramètre ou d'un groupe de paramètres d'entrée ?

# CONTEXTE

## → La démarche “standard” de traitement des incertitudes

- Comment modéliser les incertitudes sur les paramètres d'entrée ?
  - *Expériences labo, avis d'experts, calibration, ...*
- Comment estimer la dispersion de la sortie d'un modèle en fonction de la dispersion des paramètres d'entrée ?
  - *MC, QMC, IS*
- Comment estimer la sensibilité de la sortie d'un code vis-à-vis d'un paramètre ou d'un groupe de paramètres d'entrée ?

# CONTEXTE

## → Analyse de sensibilité

- Objectif : identifier et hiérarchiser, parmi les paramètres d'entrée, ceux qui influencent le plus la sortie
- Pourquoi ?
  - Réduire les incertitudes sur la réponse plus efficacement en tentant de réduire l'incertitude des plus gros contributeurs
  - Améliorer la compréhension des phénomènes, guider la R&D
  - Obtenir une meilleure connaissance dans les résultats
  - Améliorer la modélisation (simplifier le modèle par exemple)

## ▪ Notations

Modèle numérique

$$\text{Sortie } Y = \eta(X_1, \dots, X_d)$$

Paramètres d'entrée

# CONTEXTE

## → Deux écoles

- Sensibilité locale : analyse le comportement de la réponse localement autour d'un point choisi (par exemple le point nominal)

$$S_i = \frac{\sigma_{X_i}^2}{\text{Var}(Y)} \left( \left. \frac{\partial \eta(X)}{\partial X_i} \right|_{X=X_0} \right)^2$$

- *Très simple à mettre en oeuvre (différence finies, différenciation automatique, . . .)*
  - *MAIS approche locale, passage au global seulement sous hypothèses de linéarité du modèle*
- Sensibilité globale : faire varier l'ensemble des paramètres d'entrées du modèle dans son domaine incertain et analyser les variations des sorties

Note : liens entre les 2 approches récemment étudiés par Lamboni et al. 2013 (inégalités)

# CONTEXTE

## → Analyse de sensibilité globale : 2 grandes familles

- Méthodes de criblage (screening)
  - Plans d'expériences classiques
  - Criblage
  - Méthode de Morris


$$n \approx d/2 - 10d$$

- Méthodes quantitatives basées sur la décomposition de la variance
  - Techniques de régression linéaire (ou monotone sur rangs)
  - Indices de Sobol

$$n \approx 2d - 10^4 d$$

# CONTEXTE

Iooss 2009



# CONTEXTE

## → Décomposition de la variance

- Décomposition de Sobol-Hoeffding (paramètres indépendants)

$$\eta(X) = \eta_0 + \sum_{i=1}^d \eta_i(X_i) + \sum_{1 \leq i < j \leq d} \eta_{i,j}(X_i, X_j) + \dots + \eta_{1,\dots,d}(X_1, \dots, X_d)$$

- Fonctions centrées et orthogonales
- Expression en fonction des espérances conditionnelles :

$$\eta_0 = \mathbb{E}(Y)$$

$$\eta_i(X_i) = \mathbb{E}(Y|X_i) - \mathbb{E}(Y)$$

$$\eta_{i,j}(X_i, X_j) = \mathbb{E}(Y|X_i, X_j) - \mathbb{E}(Y|X_i) - \mathbb{E}(Y|X_j) + \mathbb{E}(Y)$$

...

# CONTEXTE

## → Décomposition de la variance

- Par orthogonalité

$$\text{Var}(\eta(X)) = \sum_{i=1}^d \text{Var}(\eta_i(X_i)) + \sum_{1 \leq i < j \leq d} \text{Var}(\eta_{i,j}(X_i, X_j)) + \dots + \text{Var}(\eta_{1,\dots,d}(X_1, \dots, X_d))$$

- Variance totale décomposée selon effets principaux, interactions, etc de chaque paramètre
- => Indice de sensibilité pour un groupe de paramètres

$$S_I(X_I) = \frac{\text{Var}(\eta_I(X_I))}{\text{Var}(\eta(X))}$$

$$S_i(X_i) = \frac{\text{Var}(\mathbb{E}(Y|X_i))}{\text{Var}(Y)} \quad \text{Effets 1}^{\text{er}} \text{ ordre}$$

$$S_i^T(X_i) = \sum_{I \supseteq i} S_I \quad \text{Effets totaux}$$

# CONTEXTE

## → Estimation des indices de sensibilité

- Monte-Carlo
  - Saltelli 2002, ...
- Plans spéciaux
  - FAST (Cukier 1973), RBD-FAST (Mara 2009)
- Permutations (coût indépendant de la dimension)
  - Effets principaux (Mara & Joseph 2008), interactions ordre 2 (Tissot & Prieur 2014)
- Propriétés convergence, efficacité asymptotique
  - Janon et al. 2012, D. & Gamboa 2013

# CONTEXTE

## → Résumé de la démarche pratique :

1. Screening pour limiter le nombre de paramètres
2. Analyse quantitative pour hiérarchiser finement ceux qui restent

## → Mais pour des problèmes industriels sérieux

- Coût calculatoire important du modèle numérique
  - Même les estimateurs state-of-the-art sont impossibles à utiliser
- La dimension du vecteur des entrées peut être très grande
  - Techniques de screening pas forcément robustes
- La variance de la sortie n'est pas forcément la quantité d'intérêt
  - Autres indices de sensibilité ? (e.g. pour probabilité dépassement seuil réglementaire)
- Les entrées et les sorties ne sont pas forcément des scalaires
  - Courbes d'évolution, maillages 3D, ...

# CONTEXTE

## → Résumé de la démarche pratique :

1. Screening pour limiter le nombre de paramètres
2. Analyse quantitative pour hiérarchiser finement ceux qui restent

## → Mais pour des problèmes industriels sérieux

*Emulateurs*

- Coût calculatoire important du modèle numérique
  - Même les estimateurs state-of-the-art sont impossibles à utiliser
- La dimension du vecteur des entrées peut être très grande
  - Techniques de screening pas forcément robustes
- La variance de la sortie n'est pas forcément la quantité d'intérêt
  - Autres indices de sensibilité ? (e.g. pour probabilité dépassement seuil réglementaire)
- Les entrées et les sorties ne sont pas forcément des scalaires
  - Courbes d'évolution, maillages 3D, ...

# CONTEXTE

## → Résumé de la démarche pratique :

1. Screening pour limiter le nombre de paramètres
2. Analyse quantitative pour hiérarchiser finement ceux qui restent

## → Mais pour des problèmes industriels sérieux

- Coût calculatoire important du modèle numérique
  - Même les estimateurs state-of-the-art sont impossibles à utiliser
- La dimension du vecteur des entrées peut être très grande
  - Techniques de screening pas forcément robustes
- La variance de la sortie n'est pas forcément la quantité d'intérêt
  - Autres indices de sensibilité ? (e.g. pour probabilité dépassement seuil réglementaire)
- Les entrées et les sorties ne sont pas forcément des scalaires
  - Courbes d'évolution, maillages 3D, ...

*Emulateurs*

*Feature selection*

# CONTEXTE

## → Résumé de la démarche pratique :

1. Screening pour limiter le nombre de paramètres
2. Analyse quantitative pour hiérarchiser finement ceux qui restent

## → Mais pour des problèmes industriels sérieux

- Coût calculatoire important du modèle numérique
  - Même les estimateurs state-of-the-art sont impossibles à utiliser
- La dimension du vecteur des entrées peut être très grande
  - Techniques de screening pas forcément robustes
- La variance de la sortie n'est pas forcément la quantité d'intérêt
  - Autres indices de sensibilité ? (e.g. pour probabilité dépassement seuil réglementaire)
- Les entrées et les sorties ne sont pas forcément des scalaires
  - Courbes d'évolution, maillages 3D, ...

*Emulateurs*

*Feature selection*

*Nvx indices*

# CONTEXTE

## → Résumé de la démarche pratique :

1. Screening pour limiter le nombre de paramètres
2. Analyse quantitative pour hiérarchiser finement ceux qui restent

## → Mais pour des problèmes industriels sérieux

- Coût calculatoire important du modèle numérique
  - Même les estimateurs state-of-the-art sont impossibles à utiliser

*Emulateurs*
- La dimension du vecteur des entrées peut être très grande
  - Techniques de screening pas forcément robustes

*Feature selection*
- La variance de la sortie n'est pas forcément la quantité d'intérêt
  - Autres indices de sensibilité ? (e.g. pour probabilité dépassement seuil réglementaire)

*Nvx indices*
- Les entrées et les sorties ne sont pas forcément des scalaires
  - Courbes d'évolution, maillages 3D, ...

*Distances, décompositions*

# CONTEXTE

## → Résumé de la démarche pratique :

1. Screening pour limiter le nombre de paramètres
2. Analyse quantitative pour hiérarchiser finement ceux qui restent

## → Mais pour des problèmes industriels sérieux

- Coût calculatoire important du modèle numérique
  - Même les estimateurs state-of-the-art sont impossibles à utiliser
- La dimension du vecteur des entrées peut être très grande
  - Techniques de screening pas forcément robustes
- La variance de la sortie n'est pas forcément la quantité d'information
  - Autres indices de sensibilité ? (e.g. pour probabilité de dépassement)
- Les entrées et les sorties ne sont pas forcément des scalaires
  - Courbes d'évolution, maillages 3D, ...

Un cadre général ?

*Emulateurs*

*Feature selection*

*Nvx indices*

*Distances,  
décompositions*

**/02/**

# ANALYSE DE SENSIBILITÉ GÉNÉRALISÉE

# ANALYSE DE SENSIBILITÉ GÉNÉRALISÉE

## → La variance de la sortie n'est pas forcément la quantité d'intérêt

- Très fréquemment, on est intéressé par la probabilité que la sortie dépasse un seuil (e.g. réglementaire)
- On souhaite alors identifier les paramètres d'entrée qui influencent le plus cette probabilité
  - L'analyse de sensibilité standard (à base d'indices de Sobol) ne permet pas de répondre à la question

# ANALYSE DE SENSIBILITÉ GÉNÉRALISÉE

## → La variance de la sortie n'est pas forcément la quantité d'intérêt

- Très fréquemment, on est intéressé par la probabilité que la sortie dépasse un seuil (e.g. réglementaire)
- On souhaite alors identifier les paramètres d'entrée qui influencent le plus cette probabilité
  - L'analyse de sensibilité standard (à base d'indices de Sobol) ne permet pas de répondre à la question

## → Nécessité de définir de nouveaux indices

- Perturbation loi des entrées (Sergienko et al. 2013)
- Indices basés sur fonction de contraste (Fort et al. 2014)

$$S_i^\psi = \mathbb{E}\psi(Y; \theta^*) - \mathbb{E}_{(X_i, Y)}\psi(Y; \theta_i(X_i))$$

$$\theta^* = \arg \min_{\theta} \mathbb{E}\psi(Y; \theta)$$

$$\theta_i(x) = \arg \min_{\theta} \mathbb{E}(\psi(Y; \theta) | X_i = x)$$

# ANALYSE DE SENSIBILITÉ GÉNÉRALISÉE

→ La variance de la sortie n'est qu'un résumé de la dispersion de la sortie

- Question : est-il possible de définir un indice qui quantifie l'impact d'un paramètre d'entrée sur la loi de la sortie ?

# ANALYSE DE SENSIBILITÉ GÉNÉRALISÉE

## → La variance de la sortie n'est qu'un résumé de la dispersion de la sortie

- Question : est-il possible de définir un indice qui quantifie l'impact d'un paramètre d'entrée sur la loi de la sortie ?
- Indices « distributionnels »

$$S_i^{TV} = \int |p_Y(y) - p_{Y|X_i=x}(y)| p_{X_i}(x) dx dy$$

Borgonovo 2007

$$S_i^{KL} = \int p_{Y|X_i=x}(y) \ln \left( \frac{p_{Y|X_i=x}(y)}{p_Y(y)} \right) p_{X_i}(x) dx dy$$

Kraskov et al. 2001

# ANALYSE DE SENSIBILITÉ GÉNÉRALISÉE

## → La variance de la sortie n'est qu'un résumé de la dispersion de la sortie

- Question : est-il possible de définir un indice qui quantifie l'impact d'un paramètre d'entrée sur la loi de la sortie ?
- Indices « distributionnels »

$$S_i^{TV} = \int |p_Y(y) - p_{Y|X_i=x}(y)| p_{X_i}(x) dx dy$$

Borgonovo 2007

$$S_i^{KL} = \int p_{Y|X_i=x}(y) \ln \left( \frac{p_{Y|X_i=x}(y)}{p_Y(y)} \right) p_{X_i}(x) dx dy$$

Kraskov et al. 2001

- On reconnaît facilement la distance TV et l'information mutuelle (j'y reviendrai)

# ANALYSE DE SENSIBILITÉ GÉNÉRALISÉE

## → Cadre général pour les indices distributionnels

- En toute généralité, l'impact d'un paramètre d'entrée peut être défini par l'intermédiaire d'une mesure de dissimilarité entre lois de probabilité

$$S_i = \mathbb{E}_{X_i} \left( d(P_Y, P_{Y|X_i}) \right)$$

Baucells and Borgonovo 2013  
D. 2014

- Si la loi de la sortie et la loi conditionnelle sont « proches », le paramètre n'a pas d'influence

# ANALYSE DE SENSIBILITÉ GÉNÉRALISÉE

## → Cadre général pour les indices distributionnels

- En toute généralité, l'impact d'un paramètre d'entrée peut être défini par l'intermédiaire d'une mesure de dissimilarité entre lois de probabilité

$$S_i = \mathbb{E}_{X_i} (d(P_Y, P_{Y|X_i}))$$

Baucells and Borgonovo 2013  
D. 2014


- Si la loi de la sortie et la loi conditionnelle sont « proches », le paramètre n'a pas d'influence
- Un exemple qui va nous servir tout au long de cet exposé

$$Y = \sin(X_1) + 5 \sin^2(X_2) + 0.1 X_3^4 \sin(X_1)$$


$$X_1, X_2, X_3, X_4 \sim U(-\pi, \pi)$$

Fonction d'Ishigami avec  
variable dummy


# ANALYSE DE SENSIBILITÉ GÉNÉRALISÉE




# ANALYSE DE SENSIBILITÉ GÉNÉRALISÉE




# ANALYSE DE SENSIBILITÉ GÉNÉRALISÉE




**X1 fixed**




**X2 fixed**



**X3 fixed**



**X4 fixed**



Analyse visuelle ?

# ANALYSE DE SENSIBILITÉ GÉNÉRALISÉE

## → Comment comparer des lois de probabilité ?

- Le plus « basique »

# ANALYSE DE SENSIBILITÉ GÉNÉRALISÉE

## → Comment comparer des lois de probabilité ?

- Le plus « basique »
  - Comparer leur moyenne

$$d(P_Y, P_{Y|X_i}) = (\mathbb{E}(Y) - \mathbb{E}(Y|X_i))^2$$


# ANALYSE DE SENSIBILITÉ GÉNÉRALISÉE

## → Comment comparer des lois de probabilité ?


- Le plus « basique »
  - Comparer leur moyenne

$$d(P_Y, P_{Y|X_i}) = (\mathbb{E}(Y) - \mathbb{E}(Y|X_i))^2 \quad \rightarrow \text{Sobol !}$$


**X1 fixed**




**X1 fixed**




**X2 fixed**



**X2 fixed**




**X3 fixed**



**X3 fixed**



**X4 fixed**



**X4 fixed**



# ANALYSE DE SENSIBILITÉ GÉNÉRALISÉE

## → Comment comparer des lois de probabilité ?

- Le plus « basique »
  - Comparer leur moyenne

$$d(P_Y, P_{Y|X_i}) = (\mathbb{E}(Y) - \mathbb{E}(Y|X_i))^2 \quad \rightarrow \text{Sobol !}$$

- La famille des f-divergences

$$d_f(P_Y || P_{Y|X_i}) = \int f\left(\frac{p_Y(y)}{p_{Y|X_i}(y)}\right) p_{Y|X_i}(y) dy$$

# ANALYSE DE SENSIBILITÉ GÉNÉRALISÉE

## → Comment comparer des lois de probabilité ?

- Le plus « basique »
  - Comparer leur moyenne

$$d(P_Y, P_{Y|X_i}) = (\mathbb{E}(Y) - \mathbb{E}(Y|X_i))^2 \quad \rightarrow \text{Sobol !}$$

- La famille des f-divergences

$$d_f(P_Y || P_{Y|X_i}) = \int f\left(\frac{p_Y(y)}{p_{Y|X_i}(y)}\right) p_{Y|X_i}(y) dy$$

$$S_i^f = \int f\left(\frac{p_Y(y)p_{X_i}(x)}{p_{X_i,Y}(x,y)}\right) p_{X_i,Y}(x,y) dx dy \quad \text{D. 2014}$$

# ANALYSE DE SENSIBILITÉ GÉNÉRALISÉE

## → Comment comparer des lois de probabilité ?

- Le plus « basique »
  - Comparer leur moyenne

$$d(P_Y, P_{Y|X_i}) = (\mathbb{E}(Y) - \mathbb{E}(Y|X_i))^2 \quad \rightarrow \text{Sobol !}$$

- La famille des f-divergences

$$d_f(P_Y || P_{Y|X_i}) = \int f\left(\frac{p_Y(y)}{p_{Y|X_i}(y)}\right) p_{Y|X_i}(y) dy$$

- Inclut comme cas particuliers d'indices de sensibilité la distance TV et l'information mutuelle

$$S_i^{TV} = \int |p_Y(y) - p_{Y|X_i=x}(y)| p_{X_i}(x) dx dy \quad S_i^{KL} = \int p_{Y|X_i=x}(y) \ln\left(\frac{p_{Y|X_i=x}(y)}{p_Y(y)}\right) p_{X_i}(x) dx dy$$

Borgonovo 2007

Kraskov et al. 2001

# ANALYSE DE SENSIBILITÉ GÉNÉRALISÉE

## → Avantages de ces indices

- Prise en compte de l'effet général d'un paramètre sur la loi de la sortie et pas seulement en moyenne
- A base de densités
  - Beaucoup de codes/routines existantes pour l'estimation
  - Plusieurs distances possibles (sans coût de calcul supplémentaire)

# ANALYSE DE SENSIBILITÉ GÉNÉRALISÉE

## → Avantages de ces indices

- Prise en compte de l'effet général d'un paramètre sur la loi de la sortie et pas seulement en moyenne
- A base de densités
  - Beaucoup de codes/routines existantes pour l'estimation
  - Plusieurs distances possibles (sans coût de calcul supplémentaire)

## → Un problème ?

- Penser par exemple au cas où la sortie est multi-dimensionnelle

# ANALYSE DE SENSIBILITÉ GÉNÉRALISÉE

## → Avantages de ces indices

- Prise en compte de l'effet général d'un paramètre sur la loi de la sortie et pas seulement en moyenne
- A base de densités
  - Beaucoup de codes/routines existantes pour l'estimation
  - Plusieurs distances possibles (sans coût de calcul supplémentaire)

## → Un problème ?

- Penser par exemple au cas où la sortie est multi-dimensionnelle
- L'estimation de densité en grande dimension est très difficile
- Biais des estimateurs

# ANALYSE DE SENSIBILITÉ GÉNÉRALISÉE

## → Avantages de ces indices

- Prise en compte de l'effet général d'un paramètre sur la loi de la sortie et pas seulement en moyenne
- A base de densités
  - Beaucoup de codes/routines existantes pour l'estimation
  - Plusieurs distances possibles (sans coût de calcul supplémentaire)


## → Un problème ?

- Penser par exemple au cas où la sortie est multi-dimensionnelle
- L'estimation de densité en grande dimension est très difficile
- Biais des estimateurs

## → Travaux récents pour comparer des distributions

- La moyenne n'est peut-être pas si bête ...
- ... et son estimation est beaucoup plus aisée

# ANALYSE DE SENSIBILITÉ GÉNÉRALISÉE




# ANALYSE DE SENSIBILITÉ GÉNÉRALISÉE

## → Idée

- Pas besoin d'estimation de densité si le problème est vraiment simple
- Dans l'exemple de Smola, il suffit de comparer les moyennes

# ANALYSE DE SENSIBILITÉ GÉNÉRALISÉE



Gretton 2012

# ANALYSE DE SENSIBILITÉ GÉNÉRALISÉE


## → Idée

- Pas besoin d'estimation de densité si le problème est vraiment simple
- Dans l'exemple de Smola, il suffit de comparer les moyennes

## → De manière générale

- Regarder la différence entre les moyennes de caractéristiques (« features) des variables aléatoires


# ANALYSE DE SENSIBILITÉ GÉNÉRALISÉE




Gretton 2012

# ANALYSE DE SENSIBILITÉ GÉNÉRALISÉE

Two Gaussians with different variances



Densities of feature  $X^2$



Gretton 2012

# ANALYSE DE SENSIBILITÉ GÉNÉRALISÉE

## → Idée


- Pas besoin d'estimation de densité si le problème est vraiment simple
- Dans l'exemple de Smola, il suffit de comparer les moyennes

## → De manière générale

- Regarder la différence entre les moyennes de caractéristiques (« features ») des variables aléatoires
- Dans le 2<sup>ème</sup> exemple de Gretton, il suffit de considérer des features d'ordre 2 et de comparer leurs moyennes

$$\varphi_x = x^2$$

# ANALYSE DE SENSIBILITÉ GÉNÉRALISÉE



Gretton 2012

# ANALYSE DE SENSIBILITÉ GÉNÉRALISÉE

## → Idée

- Pas besoin d'estimation de densité si le problème est vraiment simple
- Dans l'exemple de Smola, il suffit de comparer les moyennes

## → De manière générale

- Regarder la différence entre les moyennes de caractéristiques (« features ») des variables aléatoires
- Dans le 2<sup>ème</sup> exemple de Gretton, il suffit de considérer des features d'ordre 2 et de comparer leurs moyennes

$$\varphi_x = x^2$$

- Dans le 3<sup>ème</sup> exemple de Gretton, il faut étudier la différence des moyennes de features d'ordre plus élevé

# ANALYSE DE SENSIBILITÉ GÉNÉRALISÉE

## → Théorie générale : Maximum Mean Discrepancy


$$\text{MMD}(P, Q; F) := \sup_{f \in F} [\mathbb{E}_P f(x) - \mathbb{E}_Q f(x)]$$

Gretton 2012

# ANALYSE DE SENSIBILITÉ GÉNÉRALISÉE

## → Théorie générale : Maximum Mean Discrepancy

$$\text{MMD}(P, Q; F) := \sup_{f \in F} [\mathbb{E}_P f(x) - \mathbb{E}_Q f(x)]$$



Gretton 2012

# ANALYSE DE SENSIBILITÉ GÉNÉRALISÉE

## → Théorie générale : Maximum Mean Discrepancy

$$\text{MMD}(P, Q; F) := \sup_{f \in F} [\mathbb{E}_P f(x) - \mathbb{E}_Q f(x)]$$

## → Résultats classiques : distance nulle ssi les lois sont égales quand

- F = fonctions continues bornées (métrique de Dudley)
- F = fonctions de variations bornées à 1 (métrique de Kolmogorov)
- F = fonctions bornées Lipschitz (« Earth mover's distance »)

# ANALYSE DE SENSIBILITÉ GÉNÉRALISÉE

## → Théorie générale : Maximum Mean Discrepancy

$$\text{MMD}(P, Q; F) := \sup_{f \in F} [\mathbb{E}_P f(x) - \mathbb{E}_Q f(x)]$$

## → Résultats classiques : distance nulle ssi les lois sont égales quand

- F = fonctions continues bornées (métrique de Dudley)
- F = fonctions de variations bornées à 1 (métrique de Kolmogorov)
- F = fonctions bornées Lipschitz (« Earth mover's distance »)

## → Résultat plus récent

- F = boule unité dans un RKHS caractéristique

# ANALYSE DE SENSIBILITÉ GÉNÉRALISÉE

## → Fonctions dans un RKHS

$\mathcal{F}$  RKHS de  $\mathcal{X}$  dans  $\mathbb{R}$  avec noyau défini positif  $k(x, x')$

$$\mathcal{F} = \overline{\text{span} \{k(x, \cdot) | x \in \mathcal{X}\}}$$

$$f(x) = \sum_{i=1}^m \alpha_i k(x_i, x) \text{ pour } m \in \mathbb{N}, \alpha_i \in \mathbb{R}, x_i \in \mathcal{X} \text{ arbitraires}$$


# ANALYSE DE SENSIBILITÉ GÉNÉRALISÉE

## → Fonctions dans un RKHS

$\mathcal{F}$  RKHS de  $\mathcal{X}$  dans  $\mathbb{R}$  avec noyau défini positif  $k(x, x')$

$$\mathcal{F} = \overline{\text{span} \{k(x, \cdot) | x \in \mathcal{X}\}}$$

$$f(x) = \sum_{i=1}^m \alpha_i k(x_i, x) \text{ pour } m \in \mathbb{N}, \alpha_i \in \mathbb{R}, x_i \in \mathcal{X} \text{ arbitraires}$$



# ANALYSE DE SENSIBILITÉ GÉNÉRALISÉE

→ Lien avec les features vues précédemment ?

# ANALYSE DE SENSIBILITÉ GÉNÉRALISÉE

→ Lien avec les features vues précédemment ?

$x \in \mathbb{R}^2$ , feature  $\varphi_x$

$$\varphi_x^{(p)} = \begin{bmatrix} x_1^2 & x_2^2 & x_1 x_2 \sqrt{2} \end{bmatrix}$$

$$\varphi_x^{(g)} = \exp(-\lambda \|x - \cdot\|^2)$$

# ANALYSE DE SENSIBILITÉ GÉNÉRALISÉE

→ Lien avec les features vues précédemment ?

$x \in \mathbb{R}^2$ , feature  $\varphi_x$

$$\varphi_x^{(p)} = \begin{bmatrix} x_1^2 & x_2^2 & x_1 x_2 \sqrt{2} \end{bmatrix}$$

$$\varphi_x^{(g)} = \exp(-\lambda \|x - \cdot\|^2)$$

- Produit scalaire entre fonctions features

$$\left\langle \varphi_x^{(p)}, \varphi_{x'}^{(p)} \right\rangle_{\mathcal{F}} = \langle x, x' \rangle^2$$

$$\left\langle \varphi_x^{(g)}, \varphi_{x'}^{(g)} \right\rangle_{\mathcal{F}} = \exp(-\lambda \|x - x'\|^2)$$

# ANALYSE DE SENSIBILITÉ GÉNÉRALISÉE

## → Lien avec les features vues précédemment ?

$x \in \mathbb{R}^2$ , feature  $\varphi_x$

$$\varphi_x^{(p)} = \begin{bmatrix} x_1^2 & x_2^2 & x_1 x_2 \sqrt{2} \end{bmatrix}$$

$$\varphi_x^{(g)} = \exp(-\lambda \|x - \cdot\|^2)$$

- Produit scalaire entre fonctions features

$$\left\langle \varphi_x^{(p)}, \varphi_{x'}^{(p)} \right\rangle_{\mathcal{F}} = \langle x, x' \rangle^2$$

$$\left\langle \varphi_x^{(g)}, \varphi_{x'}^{(g)} \right\rangle_{\mathcal{F}} = \exp(-\lambda \|x - x'\|^2)$$

- De manière générale


$$\left\langle \varphi_x, \varphi_{x'} \right\rangle_{\mathcal{F}} = k(x, x')$$

Les noyaux sont des produits scalaires de fonctions features

# ANALYSE DE SENSIBILITÉ GÉNÉRALISÉE

## → Exemple

$$f(x) = \sum_{i=1}^m \alpha_i k(x_i, x) = \sum_{i=1}^m \alpha_i \langle \varphi_{x_i}, \varphi_x \rangle_{\mathcal{F}} = \langle f, \varphi_x \rangle_{\mathcal{F}}$$



$$f = \sum_{i=1}^m \alpha_i \varphi_{x_i}$$

# ANALYSE DE SENSIBILITÉ GÉNÉRALISÉE

→ Finalement, Maximum Mean Discrepancy dans le cadre RKHS

$$\text{MMD}^2(P, Q; F) = \left( \sup_{f \in F} [\mathbb{E}_P f(x) - \mathbb{E}_Q f(x)] \right)^2$$

# ANALYSE DE SENSIBILITÉ GÉNÉRALISÉE

→ Finalement, Maximum Mean Discrepancy dans le cadre RKHS

$$\begin{aligned} \text{MMD}^2(P, Q; F) &= \left( \sup_{f \in F} [\mathbb{E}_P f(x) - \mathbb{E}_Q f(x)] \right)^2 \\ &= \left( \sup_{f \in F} \langle f, \mu_P - \mu_Q \rangle_{\mathcal{F}} \right)^2 \end{aligned}$$
$$\begin{aligned} \mathbb{E}_P f(x) &= \mathbb{E}_P [\langle \varphi_x, f \rangle_{\mathcal{F}}] \\ &:= \langle \mu_P, f \rangle_{\mathcal{F}} \\ \mu_P &= \mathbb{E}_P \varphi_x = \int k(x, \cdot) dP(x) \end{aligned}$$

# ANALYSE DE SENSIBILITÉ GÉNÉRALISÉE

→ Finalement, Maximum Mean Discrepancy dans le cadre RKHS

$$\begin{aligned} \text{MMD}^2(P, Q; F) &= \left( \sup_{f \in F} [\mathbb{E}_P f(x) - \mathbb{E}_Q f(x)] \right)^2 \\ &= \left( \sup_{f \in F} \langle f, \mu_P - \mu_Q \rangle_{\mathcal{F}} \right)^2 \\ &= \|\mu_P - \mu_Q\|_{\mathcal{F}}^2 \end{aligned}$$
$$\begin{aligned} \mathbb{E}_P f(x) &= \mathbb{E}_P [\langle \varphi_x, f \rangle_{\mathcal{F}}] \\ &:= \langle \mu_P, f \rangle_{\mathcal{F}} \\ \mu_P &= \mathbb{E}_P \varphi_x = \int k(x, \cdot) dP(x) \\ \|h\|_{\mathcal{F}} &= \sup_{f \in F} \langle f, h \rangle_{\mathcal{F}} \end{aligned}$$

# ANALYSE DE SENSIBILITÉ GÉNÉRALISÉE

→ Finalement, Maximum Mean Discrepancy dans le cadre RKHS

$$\begin{aligned} \text{MMD}^2(P, Q; F) &= \left( \sup_{f \in F} [\mathbb{E}_P f(x) - \mathbb{E}_Q f(x)] \right)^2 \\ &= \left( \sup_{f \in F} \langle f, \mu_P - \mu_Q \rangle_{\mathcal{F}} \right)^2 \\ &= \|\mu_P - \mu_Q\|_{\mathcal{F}}^2 \end{aligned}$$
$$\begin{aligned} \mathbb{E}_P f(x) &= \mathbb{E}_P [\langle \varphi_x, f \rangle_{\mathcal{F}}] \\ &:= \langle \mu_P, f \rangle_{\mathcal{F}} \\ \mu_P &= \mathbb{E}_P \varphi_x = \int k(x, \cdot) dP(x) \\ \|h\|_{\mathcal{F}} &= \sup_{f \in F} \langle f, h \rangle_{\mathcal{F}} \end{aligned}$$

Equivalence entre point de vue  
fonctionnel et point de vue feature

# ANALYSE DE SENSIBILITÉ GÉNÉRALISÉE

→ Finalement, Maximum Mean Discrepancy dans le cadre RKHS

$$\begin{aligned} \text{MMD}^2(P, Q; F) &= \left( \sup_{f \in F} [\mathbb{E}_P f(x) - \mathbb{E}_Q f(x)] \right)^2 \\ &= \left( \sup_{f \in F} \langle f, \mu_P - \mu_Q \rangle_{\mathcal{F}} \right)^2 \\ &= \|\mu_P - \mu_Q\|_{\mathcal{F}}^2 \end{aligned}$$

Equivalence entre point de vue  
fonctionnel et point de vue feature

$$\begin{aligned} \mathbb{E}_P f(x) &= \mathbb{E}_P [\langle \varphi_x, f \rangle_{\mathcal{F}}] \\ &:= \langle \mu_P, f \rangle_{\mathcal{F}} \end{aligned}$$

$$\mu_P = \mathbb{E}_P \varphi_x = \int k(x, \cdot) dP(x)$$

$$\|h\|_{\mathcal{F}} = \sup_{f \in F} \langle f, h \rangle_{\mathcal{F}}$$

Représentation d'une loi de  
probabilité dans un RKHS

# ANALYSE DE SENSIBILITÉ GÉNÉRALISÉE

→ Finalement, Maximum Mean Discrepancy dans le cadre RKHS

$$\text{MMD}^2(P, Q; F) = \left( \sup_{f \in F} [\mathbb{E}_P f(x) - \mathbb{E}_Q f(x)] \right)^2$$

→ Estimateur non biaisé

$$\widehat{\text{MMD}}^2 = \frac{1}{n(n-1)} \sum_{i=1}^n \sum_{j \neq i}^n [k(x_i, x_j) - k(x_i, x'_j) - k(x'_i, x_j) + k(x'_i, x'_j)]$$

$$\{x_i\}_{i=1}^n \sim P, \quad \{x'_i\}_{i=1}^n \sim Q$$

# ANALYSE DE SENSIBILITÉ GÉNÉRALISÉE

## → Comment comparer des lois de probabilité ?

- Le plus « basique »
  - Comparer leur moyenne

$$d(P_Y, P_{Y|X_i}) = (\mathbb{E}(Y) - \mathbb{E}(Y|X_i))^2 \quad \rightarrow \text{Sobol !}$$


- La famille des f-divergences

$$d_f(P_Y || P_{Y|X_i}) = \int f\left(\frac{p_Y(y)}{p_{Y|X_i}(y)}\right) p_{Y|X_i}(y) dy$$


- MMD version noyau

$$d(P_Y, P_{Y|X_i}) = \text{MMD}^2(Y, Y|X_i)$$


**X1 fixed**




**X1 fixed**




**X1 fixed**




**X2 fixed**




**X2 fixed**



**X2 fixed**




**X3 fixed**




**X3 fixed**



**X3 fixed**



**X4 fixed**



**X4 fixed**



**X4 fixed**



# ANALYSE DE SENSIBILITÉ GÉNÉRALISÉE

## → Note : pourquoi parler d'analyse de sensibilité généralisée ?

- Choix du noyau « libre »
- Pour garantir un indice réellement « distributionnel », il faut un noyau caractéristique
  - Gaussien, Laplace

# ANALYSE DE SENSIBILITÉ GÉNÉRALISÉE

## → Note : pourquoi parler d'analyse de sensibilité généralisée ?

- Choix du noyau « libre »
- Pour garantir un indice réellement « distributionnel », il faut un noyau caractéristique
  - Gaussien, Laplace
- Mais on peut en théorie utiliser le noyau que l'on veut, par exemple le noyau le plus simple qui soit :


$$k(y, y') = \langle y, y' \rangle \stackrel{1D}{=} yy'$$

# ANALYSE DE SENSIBILITÉ GÉNÉRALISÉE

## → Note : pourquoi parler d'analyse de sensibilité généralisée ?

- Choix du noyau « libre »
- Pour garantir un indice réellement « distributionnel », il faut un noyau caractéristique
  - Gaussien, Laplace
- Mais on peut en théorie utiliser le noyau que l'on veut, par exemple le noyau le plus simple qui soit :

$$k(y, y') = \langle y, y' \rangle \stackrel{1D}{=} yy'$$



$$\mathbb{E} \left( \text{MMD}^2(P_Y, P_{Y|X_i}) \right) = \text{Var}(\mathbb{E}(Y|X_i))$$

Sobol non normalisé par  
la variance de la sortie !

# ANALYSE DE SENSIBILITÉ GÉNÉRALISÉE

## → Bilan à mi-parcours

- Nouveaux indices « distributionnels »
  - Quantification réel de l'impact sur la loi de la sortie
  - Pas de fléau de la dimension pour l'estimation de densité
  - Indices de Sobol comme cas particulier

# ANALYSE DE SENSIBILITÉ GÉNÉRALISÉE

## → Bilan à mi-parcours

- Nouveaux indices « distributionnels »
  - Quantification réel de l'impact sur la loi de la sortie
  - Pas de fléau de la dimension pour l'estimation de densité
  - Indices de Sobol comme cas particulier

## → Reste un avantage de Sobol

- Décomposition ANOVA
- L'orthogonalité permet de dissocier les effets principaux des interactions
  - Pour certains codes physiques complexes, les interactions sont très importantes
- Peut-on exhiber une décomposition orthogonale pour des indices distributionnels ?

**/03/**

# DÉCOMPOSITIONS ORTHOGONALES POUR GSA GÉNÉRALISÉE

# PLAN

## → Contexte et problématique

- Décomposition de Sobol – ANOVA fonctionnelle

## → Analyse de sensibilité généralisée

- Cadre général à base de densités
- Vers de nouveaux indices de sensibilité

## → **Décompositions orthogonales pour GSA généralisée**

- Décomposition 1
- Décomposition 2
- Le cas des données fonctionnelles

## → Conclusions et perspectives

# DÉCOMPOSITIONS ORTHOGONALES

- **Avant les indices à base de noyaux, distances plus « classiques »**
  - Variation totale : aucune décomposition (à ma connaissance)

# DÉCOMPOSITIONS ORTHOGONALES

## → Avant les indices à base de noyaux, distances plus « classiques »

- Variation totale : aucune décomposition (à ma connaissance)
- Information mutuelle
  - Une piste dans les travaux sur les mesures d'importance dans les forêts aléatoires

# DÉCOMPOSITIONS ORTHOGONALES

## → Avant les indices à base de noyaux, distances plus « classiques »

- Variation totale : aucune décomposition (à ma connaissance)
- Information mutuelle
  - Une piste dans les travaux sur les mesures d'importance dans les forêts aléatoires

$$\text{MDI}(X_i) = \sum_{k=0}^{d-1} \frac{1}{C_d^k} \frac{1}{d-k} \sum_{B \in P_k(X_{-i})} I(X_i; Y|B)$$

Mean Decrease Impurity

Mesure d'impureté = entropie

Valable pour un ensemble infini d'arbres totalement randomisés  
et développés avec un échantillon infiniment grand

Entrées et sortie catégorielles

$$\sum_{i=1}^d \text{MDI}(X_i) = I(X_1, \dots, X_d; Y)$$

Louppe et al. 2013

# DÉCOMPOSITIONS ORTHOGONALES

## → Avant les indices à base de noyaux, distances plus « classiques »

- Variation totale : aucune décomposition (à ma connaissance)
- Information mutuelle
  - Une piste dans les travaux sur les mesures d'importance dans les forêts aléatoires
- A priori, pas grand chose d'utilisable ...

# DÉCOMPOSITIONS ORTHOGONALES

## → Avant les indices à base de noyaux, distances plus « classiques »

- Variation totale : aucune décomposition (à ma connaissance)
- Information mutuelle
  - Une piste dans les travaux sur les mesures d'importance dans les forêts aléatoires
- A priori, pas grand chose d'utilisable ...

## → Est-ce le cas pour les indices MMD ?

- Un espoir car basé sur des moyennes et non sur des densités
- Relativement “proche” de Sobol
  - Rappelez-vous, cas particulier noyau

# DÉCOMPOSITIONS ORTHOGONALES

## → Ré-écriture de la décomposition ANOVA

$$\text{Var}(Y) = \sum_{u \subseteq \{1, \dots, d\}, u \neq \emptyset} g_u$$

$$g_u = \sum_{v \subseteq u} (-1)^{|u|-|v|} \text{Var}(\mathbb{E}(Y | X_v))$$

# DÉCOMPOSITIONS ORTHOGONALES

## → Décomposition orthogonale pour indices MMD

$$\mathbb{E} \left( \text{MMD}^2 \left( P_{Y|X_{1:d}}, P_Y \right) \right) = \sum_{u \subseteq \{1, \dots, p\}, u \neq \emptyset} g_u$$

$$g_u = \sum_{v \subseteq u} (-1)^{|u|-|v|} \mathbb{E} \left( \text{MMD}^2 \left( P_{Y|X_v}, P_Y \right) \right)$$

- Preuve : combinatoire

$$P_{Y|X_{1:d}} - P_Y = \sum_{u \subseteq \{1, \dots, d\}, u \neq \emptyset} \sum_{v \subseteq u} (-1)^{|u|-|v|} P_{Y|X_v}$$
$$\mathbb{E} \left( \left\langle \sum_{v \subseteq u} (-1)^{|u|-|v|} P_{Y|X_v}, \sum_{v \subseteq u'} (-1)^{|u'-|v|} P_{Y|X_v} \right\rangle_k \right) = 0$$

# DÉCOMPOSITIONS ORTHOGONALES

## → Décomposition orthogonale pour indices MMD

$$\mathbb{E} \left( \text{MMD}^2 \left( P_{Y|X_{1:d}}, P_Y \right) \right) = \sum_{u \subseteq \{1, \dots, p\}, u \neq \emptyset} g_u$$

$$g_u = \sum_{v \subseteq u} (-1)^{|u|-|v|} \mathbb{E} \left( \text{MMD}^2 \left( P_{Y|X_v}, P_Y \right) \right)$$

$$S_u^{\text{MMD}} = \frac{\sum_{v \subseteq u} (-1)^{|u|-|v|} \mathbb{E} \left( \text{MMD}^2 \left( P_{Y|X_v}, P_Y \right) \right)}{\mathbb{E} \left( \text{MMD}^2 \left( P_{Y|X_{1:d}}, P_Y \right) \right)}$$

# INTERLUDE : ESTIMATION

- **Les indices de Sobol et MMD évitent l'estimation de densité**
  - Déjà vu, avantage vs autres indices distributionnels

# INTERLUDE : ESTIMATION

## → Les indices de Sobol et MMD évitent l'estimation de densité

- Déjà vu, avantage vs autres indices distributionnels

## → MAIS ils font malgré tout intervenir les lois conditionnelles

$$d(P_Y, P_{Y|X_i}) = (\mathbb{E}(Y) - \mathbb{E}(Y|X_i))^2$$

$$d(P_Y, P_{Y|X_i}) = \text{MMD}^2(Y, Y|X_i)$$

- Coûteux, d'où l'utilisation en pratique de modèles approchés (émulateur, proxy, ...)

# INTERLUDE : ESTIMATION

## → Les indices de Sobol et MMD évitent l'estimation de densité

- Déjà vu, avantage vs autres indices distributionnels

## → MAIS ils font malgré tout intervenir les lois conditionnelles

$$d(P_Y, P_{Y|X_i}) = (\mathbb{E}(Y) - \mathbb{E}(Y|X_i))^2$$

$$d(P_Y, P_{Y|X_i}) = \text{MMD}^2(Y, Y|X_i)$$

- Coûteux, d'où l'utilisation en pratique de modèles approchés (émulateur, proxy, ...)

## → Peut-on s'inspirer du cas de l'information mutuelle ?

- Estimation de densité certes, mais pas de lois conditionnelles (uniquement lois jointes)

# INTERLUDE : MESURE DE DÉPENDANCE ENTRE VARIABLES ALÉATOIRES

## → Comment comparer des lois de probabilité ?

- Le plus « basique »
  - Comparer leur moyenne

$$d(P_Y, P_{Y|X_i}) = (\mathbb{E}(Y) - \mathbb{E}(Y|X_i))^2 \quad \rightarrow \text{Sobol !}$$

- La famille des f-divergences

$$d_f(P_Y || P_{Y|X_i}) = \int f\left(\frac{p_Y(y)}{p_{Y|X_i}(y)}\right) p_{Y|X_i}(y) dy$$

- Inclut comme cas particuliers d'indices de sensibilité la distance TV et l'information mutuelle

$$S_i^{TV} = \int |p_Y(y) - p_{Y|X_i=x}(y)| p_{X_i}(x) dx dy$$

Borgonovo 2007

$$S_i^{KL} = \int p_{Y|X_i=x}(y) \ln\left(\frac{p_{Y|X_i=x}(y)}{p_Y(y)}\right) p_{X_i}(x) dx dy$$

# INTERLUDE : MESURE DE DÉPENDANCE ENTRE VARIABLES ALÉATOIRES

→ L'information mutuelle est une mesure de la dépendance entre deux vecteurs aléatoires

$$\begin{aligned} S_i^{KL} &= \int p_{Y|X_i=x}(y) \ln \left( \frac{p_{Y|X_i=x}(y)}{p_Y(y)} \right) p_{X_i}(x) dx dy \\ &= \int p_{Y,X_i}(y, x) \ln \left( \frac{p_{Y,X_i}(y, x)}{p_Y(y)p_{X_i}(x)} \right) dx dy = I(X_i; Y) \end{aligned}$$

# INTERLUDE : MESURE DE DÉPENDANCE ENTRE VARIABLES ALÉATOIRES

→ L'information mutuelle est une mesure de la dépendance entre deux vecteurs aléatoires

$$\begin{aligned} S_i^{KL} &= \int p_{Y|X_i=x}(y) \ln \left( \frac{p_{Y|X_i=x}(y)}{p_Y(y)} \right) p_{X_i}(x) dx dy \\ &= \int p_{Y,X_i}(y, x) \ln \left( \frac{p_{Y,X_i}(y, x)}{p_Y(y)p_{X_i}(x)} \right) dx dy = I(X_i; Y) \end{aligned}$$

→ On voit donc qu'un indice de sensibilité peut dans certains cas s'interpréter comme une mesure de dépendance entre entrées et sortie

- Question : l'information mutuelle souffrant du fléau de la dimension, peut-on envisager d'autres mesures de dépendance ?
- Subsidaire : avec une décomposition orthogonale ?

# INTERLUDE : MESURE DE DÉPENDANCE ENTRE VARIABLES ALÉATOIRES

→ **En toute généralité, une mesure de dépendance compare la loi jointe et le produit des marginales**

- Si proche, les variables sont dépendantes
- Comment comparer loi jointe et produit des marginales ?
  - Sans estimation de densité, une idée ?

# INTERLUDE : MESURE DE DÉPENDANCE ENTRE VARIABLES ALÉATOIRES

→ **En toute généralité, une mesure de dépendance compare la loi jointe et le produit des marginales**

- Si proche, les variables sont dépendantes
- Comment comparer loi jointe et produit des marginales ?
  - Sans estimation de densité, une idée ?

$$\text{MMD}^2 (P_{Y,X}, P_Y P_X)$$

# INTERLUDE : MESURE DE DÉPENDANCE ENTRE VARIABLES ALÉATOIRES

→ **En toute généralité, une mesure de dépendance compare la loi jointe et le produit des marginales**

- Si proche, les variables sont dépendantes
- Comment comparer loi jointe et produit des marginales ?
  - Sans estimation de densité, une idée ?

$$\text{MMD}^2 (P_{Y,X}, P_Y P_X) = \left( \sup_{f \in F} [\mathbb{E}_{P_{XY}} f(x, y) - \mathbb{E}_{P_X P_Y} f(x, y)] \right)^2$$

# INTERLUDE : MESURE DE DÉPENDANCE ENTRE VARIABLES ALÉATOIRES

→ En toute généralité, une mesure de dépendance compare la loi jointe et le produit des marginales

- Si proche, les variables sont dépendantes
- Comment comparer loi jointe et produit des marginales ?
  - Sans estimation de densité, une idée ?

$$\begin{aligned} \text{MMD}^2 (P_{Y,X}, P_Y P_X) &= \left( \sup_{f \in F} [\mathbb{E}_{P_{XY}} f(x, y) - \mathbb{E}_{P_X P_Y} f(x, y)] \right)^2 \\ &= \|\mu_{P_{XY}} - \mu_{P_X P_Y}\|_{\mathcal{F} \times \mathcal{G}}^2 \end{aligned}$$

# INTERLUDE : MESURE DE DÉPENDANCE ENTRE VARIABLES ALÉATOIRES

→ En toute généralité, une mesure de dépendance compare la loi jointe et le produit des marginales

- Si proche, les variables sont dépendantes
- Comment comparer loi jointe et produit des marginales ?
  - Sans estimation de densité, une idée ?

$$\begin{aligned} \text{MMD}^2 (P_{Y,X}, P_Y P_X) &= \left( \sup_{f \in F} [\mathbb{E}_{P_{XY}} f(x, y) - \mathbb{E}_{P_X P_Y} f(x, y)] \right)^2 \\ &= \|\mu_{P_{XY}} - \mu_{P_X P_Y}\|_{\mathcal{F} \times \mathcal{G}}^2 \\ &= \text{HSIC}(X, Y) \quad \text{Hilbert-Schmidt Independence Criterion} \\ &\quad \text{Gretton 2005} \end{aligned}$$

# INTERLUDE : MESURE DE DÉPENDANCE ENTRE VARIABLES ALÉATOIRES

## → En toute généralité, une mesure de dépendance compare la loi jointe et le produit des marginales

- Si proche, les variables sont dépendantes
- Comment comparer loi jointe et produit des marginales ?
  - Sans estimation de densité, une idée ?

$$\begin{aligned} \text{MMD}^2 (P_{Y,X}, P_Y P_X) &= \left( \sup_{f \in F} [\mathbb{E}_{P_{XY}} f(x, y) - \mathbb{E}_{P_X P_Y} f(x, y)] \right)^2 \\ &= \|\mu_{P_{XY}} - \mu_{P_X P_Y}\|_{\mathcal{F} \times \mathcal{G}}^2 \\ &= \text{HSIC}(X, Y) \quad \text{Hilbert-Schmidt Independence Criterion} \\ &\quad \text{Gretton 2005} \end{aligned}$$

## → La mesure HSIC dépend d'un noyau défini dans l'espace joint

- En pratique, produit de noyaux définis sur chaque vecteur
- Estimation ne faisant pas intervenir les lois conditionnelles !

# INTERLUDE : MESURE DE DÉPENDANCE ENTRE VARIABLES ALÉATOIRES

## → Estimation de la mesure HSIC

$$\widehat{\text{HSIC}}(X, Y) = \frac{1}{n^2} \text{trace}(KHLH)$$


$$[K]_{ij} = k_{\mathcal{X}}(x_i, x_j) \quad [L]_{ij} = k_{\mathcal{Y}}(y_i, y_j) \quad [H]_{ij} = \delta_{ij} - \frac{1}{n}$$

$$\{(x_i, y_i)\}_{i=1}^n \sim P_{XY}$$

# INTERLUDE : MESURE DE DÉPENDANCE ENTRE VARIABLES ALÉATOIRES

- **Une version normalisée de cette mesure de dépendance a été étudiée comme indice de sensibilité et comparée aux indices de Sobol (D. 2014)**
- Beaucoup moins d'observations nécessaires que pour les indices de Sobol
  - Très bonnes propriétés de screening

# INTERLUDE : MESURE DE DÉPENDANCE ENTRE VARIABLES ALÉATOIRES



D. 2014

# INTERLUDE : MESURE DE DÉPENDANCE ENTRE VARIABLES ALÉATOIRES

- **Une version normalisée de cette mesure de dépendance a été étudiée comme indice de sensibilité et comparée aux indices de Sobol (D. 2014)**
  - Beaucoup moins d'observations nécessaires que pour les indices de Sobol
  - Très bonnes propriétés de screening
  
- **Mais ce n'était qu'un travail préliminaire**
  - La normalisation proposée n'était en fait pas la bonne !
  - Pas de décomposition ANOVA ...

# INTERLUDE : MESURE DE DÉPENDANCE ENTRE VARIABLES ALÉATOIRES

- **Une version normalisée de cette mesure de dépendance a été étudiée comme indice de sensibilité et comparée aux indices de Sobol (D. 2014)**
  - Beaucoup moins d'observations nécessaires que pour les indices de Sobol
  - Très bonnes propriétés de screening
  
- **Mais ce n'était qu'un travail préliminaire**
  - La normalisation proposée n'était en fait pas la bonne !
  - Pas de décomposition ANOVA ...
  - ... jusqu'à aujourd'hui
    - Décomposition orthogonale, mais pas dans le cas général (hypothèse sur noyau entrées)
    - Fournit donc la bonne normalisation comme pour Sobol et MMD

# DÉCOMPOSITIONS ORTHOGONALES

## → Ré-écriture de la décomposition ANOVA

$$\text{Var}(Y) = \sum_{u \subseteq \{1, \dots, d\}, u \neq \emptyset} g_u$$

$$g_u = \sum_{v \subseteq u} (-1)^{|u|-|v|} \text{Var}(\mathbb{E}(Y | X_v))$$

# DÉCOMPOSITIONS ORTHOGONALES

## → Décomposition orthogonale pour indices HSIC

$$\text{HSIC}(Y, X_{1:d}) = \sum_{u \subseteq \{1, \dots, p\}, u \neq \emptyset} g_u$$

$$g_u = \sum_{v \subseteq u} (-1)^{|u|-|v|} \text{HSIC}(Y, X_v)$$

- Sous l'hypothèse que le noyau sur chaque entrée vérifie

$$\int_{\mathcal{X}} k_{\mathcal{X}}(x, x') dP_X(x) = 1$$

$$\begin{aligned} k_{\mathcal{X}} &= 1 + k_{\mathcal{X}}^0 \\ k_{\mathcal{X}}^0(x, x') &= k(x, x') - \frac{\int_{\mathcal{X}} k(x, x') dP_X(x') \int_{\mathcal{X}} k(x, x') dP_X(x)}{\iint_{\mathcal{X} \times \mathcal{X}} k(x, x') dP_X(x) dP_X(x')} \\ k_{\mathcal{X}}^0(x, x') &= k(x, x') - \int_{\mathcal{X}} k(x, x') dP_X(x') - \int_{\mathcal{X}} k(x, x') dP_X(x) \\ &\quad + \iint_{\mathcal{X} \times \mathcal{X}} k(x, x') dP_X(x) dP_X(x') \end{aligned}$$

# DÉCOMPOSITIONS ORTHOGONALES

## → Décomposition orthogonale pour indices HSIC

$$\text{HSIC}(Y, X_{1:d}) = \sum_{u \subseteq \{1, \dots, p\}, u \neq \emptyset} g_u$$

$$g_u = \sum_{v \subseteq u} (-1)^{|u|-|v|} \text{HSIC}(Y, X_v)$$

$$S_u^{\text{HSIC}} = \frac{\sum_{v \subseteq u} (-1)^{|u|-|v|} \text{HSIC}(Y, X_v)}{\text{HSIC}(Y, X_{1:d})}$$

# DÉCOMPOSITIONS ORTHOGONALES

## → Note le retour : pourquoi parler d'analyse de sensibilité généralisée ?

- Choix du noyau « libre »
- Pour garantir un indice réellement « distributionnel », il faut un noyau caractéristique
  - Gaussien, Laplace
- Pour garantir la décomposition orthogonale, hypothèse sur noyau entrées

# DÉCOMPOSITIONS ORTHOGONALES

## → Note le retour : pourquoi parler d'analyse de sensibilité généralisée ?

- Choix du noyau « libre »
- Pour garantir un indice réellement « distributionnel », il faut un noyau caractéristique
  - Gaussien, Laplace
- Pour garantir la décomposition orthogonale, hypothèse sur noyau entrées
- Si entrées uniformes et noyau tend vers le « noyau » Dirac

$$k_{\mathcal{X}}(x, x') \rightarrow \delta(x, x')$$

$$\text{ex: } k_{\mathcal{X}}(x, x') = \frac{1}{\sqrt{2\pi a^2}} \exp\left(-\frac{1}{2a^2}(x - x')^2\right), \quad a \rightarrow 0$$

# DÉCOMPOSITIONS ORTHOGONALES

## → Note le retour : pourquoi parler d'analyse de sensibilité généralisée ?

- Choix du noyau « libre »
- Pour garantir un indice réellement « distributionnel », il faut un noyau caractéristique
  - Gaussien, Laplace
- Pour garantir la décomposition orthogonale, hypothèse sur noyau entrées
- Si entrées uniformes et noyau tend vers le « noyau » Dirac

$$k_{\mathcal{X}}(x, x') \rightarrow \delta(x, x')$$

$$\text{ex: } k_{\mathcal{X}}(x, x') = \frac{1}{\sqrt{2\pi a^2}} \exp\left(-\frac{1}{2a^2}(x - x')^2\right), \quad a \rightarrow 0$$

$$S_u^{\text{HSIC}} \longrightarrow S_u^{\text{MMD}}$$

# DÉCOMPOSITIONS ORTHOGONALES

## → Note le retour : pourquoi parler d'analyse de sensibilité généralisée ?

- Choix du noyau « libre »
- Pour garantir un indice réellement « distributionnel », il faut un noyau caractéristique
  - Gaussien, Laplace
- Pour garantir la décomposition orthogonale, hypothèse sur noyau entrées
- Si entrées uniformes et noyau tend vers le « noyau » Dirac

$$k_{\mathcal{X}}(x, x') \rightarrow \delta(x, x')$$

$$\text{ex: } k_{\mathcal{X}}(x, x') = \frac{1}{\sqrt{2\pi a^2}} \exp\left(-\frac{1}{2a^2}(x - x')^2\right), \quad a \rightarrow 0$$

$$S_u^{\text{HSIC}} \longrightarrow S_u^{\text{MMD}}$$

$$k_{\mathcal{Y}}(y, y') = yy'$$

$$S_u^{\text{MMD}} = S_u^{\text{Sobol}}$$

# DÉCOMPOSITIONS ORTHOGONALES VOUS SOUVENEZ-VOUS DU MENU ?

## → Résumé de la démarche pratique :

1. Screening pour limiter le nombre de paramètres
2. Analyse quantitative pour hiérarchiser finement ceux qui restent

## → Mais pour des problèmes industriels sérieux

- Coût calculatoire important du modèle numérique
  - Même les estimateurs state-of-the-art sont impossibles à utiliser
- La dimension du vecteur des entrées peut être très grande
  - Techniques de screening pas forcément robustes
- La variance de la sortie n'est pas forcément la quantité d'intérêt
  - Autres indices de sensibilité ? (e.g. pour probabilité de dépassement)
- Les entrées et les sorties ne sont pas forcément des scalaires
  - Courbes d'évolution, maillages 3D, ...

Un cadre général ?

*Emulateurs*

*Feature selection*

*Nvx indices*


*Distances,  
décompositions*

# DÉCOMPOSITIONS ORTHOGONALES


## → Prise en compte d'entrées/sorties fonctionnelles

- Dans la « vraie » vie, cela ressemble à ça


Réservoir de pétrole produit par injection de vapeur



Entrées : proportions d'argile dans certaines zones



Sortie : cube 3D de propagation de la chambre de vapeur dans le réservoir



Sortie : évolution temporelle du débit de vapeur et de la pression au puits producteur

# DÉCOMPOSITIONS ORTHOGONALES

## → Prise en compte d'entrées/sorties fonctionnelles

- Dans la « vraie » vie, cela ressemble à ça
- Pour indices de Sobol, généralisation pour un vecteur de sorties (Gamboa et al. 2013)
  - Combinaison linéaire des indices de chaque composante
  - Parmi les mesures basées sur la variance, seule façon d'avoir des propriétés d'invariance
- L'approche par noyaux permet un point de vue complètement nouveau
  - En recyclant les (très nombreux) travaux déjà effectués pour construire des noyaux adaptés dans plusieurs applications !
    - Ex: noyaux pour l'analyse d'images
    - Ex: noyaux pour le texte (sait-on jamais !)
    - Ex: noyaux pour séries temporelles
    - Etc ...



# DÉCOMPOSITIONS ORTHOGONALES

## → Prise en compte d'entrées/sorties fonctionnelles

- Dans la « vraie » vie, cela ressemble à ça
- Pour indices de Sobol, généralisation pour un vecteur de sorties (Gamboa et al. 2013)
  - Combinaison linéaire des indices de chaque composante
  - Parmi les mesures basées sur la variance, seule façon d'avoir des propriétés d'invariance
- L'approche par noyaux permet un point de vue complètement nouveau
  - En recyclant les (très nombreux) travaux déjà effectués pour construire des noyaux adaptés dans plusieurs applications !
    - Ex: noyaux pour l'analyse d'images
    - Ex: noyaux pour le texte (sait-on jamais !)
    - Ex: noyaux pour séries temporelles
    - Etc ...
- Exemple sur le cas du réservoir de pétrole avec un cube 3D de propriétés physiques en sortie

# DÉCOMPOSITIONS ORTHOGONALES

→ **Modèle de simulation d'écoulement de pétrole dans un réservoir de pétrole produit par injection de vapeur d'eau (sables bitumineux Canada)**




**Entrées** : 11 proportions d'argile dans certaines zones du réservoir

**Sortie** : cube 3D d'impédances (rouge = argile, bleu = vapeur)  
Permet de localiser le panache de vapeur et vérifier que toutes les régions du réservoir sont chauffées

# DÉCOMPOSITIONS ORTHOGONALES

- Modèle de simulation d'écoulement de pétrole dans un réservoir de pétrole produit par injection de vapeur d'eau (sables bitumineux Canada)
- Noyau basé sur une mesure de similarité entre cubes 3D adaptée au problème




Tillier et al. 2013

# DÉCOMPOSITIONS ORTHOGONALES


- **Modèle de simulation d'écoulement de pétrole dans un réservoir de pétrole produit par injection de vapeur d'eau (sables bitumineux Canada)**
- **Noyau basé sur une mesure de similarité entre cubes 3D adaptée au problème**
  - Et comparaison avec un autre noyau ACP
- **Analyse de sensibilité à l'aide de la mesure HSIC**
  - Echantillon de taille 100
  - Bootstrap pour évaluer la variabilité de l'estimation

# DÉCOMPOSITIONS ORTHOGONALES

## Noyau ACP



## Noyau LDM



**/04/**

# CONCLUSIONS & PERSPECTIVES

# CONCLUSION

## → Nouvelle perspective GSA

- Consistante, englobe indices de Sobol mais plus générale
- Très proche du machine learning finalement
  - Recyclage noyaux
- La complexité des entrées ou des sorties est transparente
  - Une fois les noyaux choisis
  - Richesse au-delà du simple noyau produit scalaire (Sobol)
- Logiciels
  - f-divergences + HSIC (mauvaise normalisation) disponibles dans le package R **sensitivity**

## → Les sujets d'intérêt à l'heure actuelle :

- Choix du noyau
- Travaux intensifs de comparaison sur plusieurs cas test vs Sobol
  - Notamment, analyse des différences de détection

# CONCLUSION

## → Communauté française : GDR Mascot-Num

- Ateliers, conférence annuelle
- News, bibliographie, formations



*Merci de votre attention !  
Questions ?*