

Analyse de sensibilité de variables dépendantes par les indices de Shapley

B. Broto (1), L. Clouvel (3), M. Depecker (1), F. Bachoc (2), JM. Martinez (3)

(1) CEA/DRT, (3) CEA/DEN, (2) Inst. Math. Toulouse.

GdR MaNu - 7 décembre 2018

1 Introduction

- Typologie des incertitudes en simulation numérique
- Analyse de sensibilité globale par modélisation probabiliste des incertitudes
- Cas de variables indépendantes - Indices de Sobol


2 Prise en compte des dépendances

- Indices de Shapley
- Relations entre indices Sobol/Shapley (variables indépendantes)
- Application au modèle linéaire gaussien
- Application au modèle additif par blocs de variables indépendants
- Cas d'étude en physique des réacteurs

Incertitudes au coeur du processus de Vérification et Validation des Outils de Calcul Scientifique

MODÈLE CONCEPTUEL	
Aléatoire <ul style="list-style-type: none"> ● variabilité <i>naturelle</i> : régimes turbulents, géométrie d'une brèche, signal sismique ● pas de valeur unique ● irréductibles : générateurs aléatoires de variables, champs, processus 	Epistémique <ul style="list-style-type: none"> ● méconnaissance : sections efficaces, modèles physiques, lois de fermeture, lois de comportement ● on ne sait pas quelle est la bonne valeur, la <i>bonne</i> loi ● réductibles : assimilation de données (mesures), calibration Bayésienne adaptée (<i>connaissances a priori</i>)
MODÈLE OPÉRATIONNEL := OCS	
Statistique <ul style="list-style-type: none"> ● calculs Monte Carlo ● réductibles : plus de simulations/particules, méthodes de réduction de variance 	Numérique <ul style="list-style-type: none"> ● méthodes, discrétisations, seuils de convergence ● réductibles : finesse/adaptativité du maillage, de la convergence

- CONSENSUS sur la modélisation probabiliste des incertitudes aléatoires, statistiques et épistémiques (interprétation subjective) lorsqu'elles portent sur des constantes physiques
- CRITIQUES sur l'utilisation de variables aléatoires pour représenter les incertitudes épistémiques des modèles physiques
- VERROUS SCIENTIFIQUES : transposition (changements d'échelles géométrie/physique), interactions entre incertitudes épistémiques et numériques
- INTÉRÊT DE L'ANALYSE DE SENSIBILITÉ sur les modèles conceptuel et opérationnel



W. Oberkampf (2004)

Society of Computer Simulation (1979)

Incertitudes modélisées par des variables aléatoires

- **ANALYSE DE SENSIBILITÉ** : quantifier l'influence des paramètres, des variables incertaines (entrées) sur les grandeurs calculées (sorties) par l'OCS
 - aide à la vérification du modèle opérationnel et à la validation (calibration) du modèle conceptuel
- Pour une **MODÉLISATION PROBABILISTE** des incertitudes, l'AS est obtenue par décomposition de la variance des grandeurs calculées par l'OCS sur la base des variables aléatoires
 - représentation de l'incertitude par la variance
- **FORMALISATION**
 - $X = (X_1, \dots, X_p)$ un vecteur aléatoire réel modélisant les incertitudes
 - $Y = \varphi(X)$ la variable aléatoire à analyser associée à une des grandeurs calculées par l'OCS
- **QUANTIFICATION** de l'influence des variables X_i sur Y par des indices de sensibilité
 - variables X_i indépendantes \rightarrow indices de Sobol
 - variables X_i dépendantes \rightarrow indices de Shapley
- L'AS fondée sur l'ANOVA (ANalysis Of VAriance) utilise les **ESPÉRANCES CONDITIONNELLES** $\mathbb{E}(Y|X_{u \subseteq [1:p]})$ modélisant chacune la meilleure approximation de Y par une fonction de X_u , vecteurs de composantes $X_{i \in u}$:

$$\mathbb{E}(Y|X_u) = \arg \min_{f(X_u)} \mathbb{E}_{X_{-u}} [(Y - f(X_u))^2]$$

Indices de Sobol

- $Y = \varphi(X_1, \dots, X_p)$, indépendance des X_i et $\mathbb{E}(Y^2) < \infty$

- DÉCOMPOSITION FONCTIONNELLE (Hoeffding)

$$Y = \sum_{u \subseteq [1:p]} \varphi_u(X_u)$$

- UNICITÉ si $\varphi_\emptyset = \mathbb{E}(Y)$ et $\varphi_u(X_u)$ mutuellement non corrélées

$$\varphi_u(X_u) = \mathbb{E}(Y|X_u) - \sum_{v \subset u} \varphi_v(X_v)$$

- $\varphi_u(X_u)$ fonction qui modélise l'effet dû aux interactions éventuelles entre les composantes de X_u
- DÉCOMPOSITION FONCTIONNELLE DE LA VARIANCE en notant $\sigma_u^2 = \text{Var}(\varphi_u^2(X_u))$:

$$\text{Var}(Y) = \sum_{u \subseteq [1:p]} \sigma_u^2 = \sigma^2$$

- Indices de Sobol (I. M. Sobol 2001) : S_u^i quantifie la part de la variance due aux interactions entre les composantes de X_u et l'indice dit complet S_u^c caractérise la part de la variance due au groupe X_u et S_u^t la part de la variance due au groupe X_u et aux interactions avec les autres variables X_{-u}

$$S_u^i = \frac{\text{Var}(\varphi_u(X_u))}{\sigma^2} = \frac{\sigma_u^2}{\sigma^2} \Rightarrow \sum_{u \subseteq [1:p]} S_u^i = 1$$

$$S_u^c = \frac{\text{Var}(\mathbb{E}(Y|X_u))}{\sigma^2} = \frac{\sum_{v \subseteq u} \sigma_v^2}{\sigma^2}$$

$$S_u^t = \frac{\sum_{v \cap u \neq \emptyset} \sigma_v^2}{\sigma^2}, \Rightarrow S_u^i + S_{-u}^t = 1$$

- si Y a une forme additive : $\varphi(X) = \sum_{i=1}^p \varphi_i(X(i)) \Rightarrow S_{\{i\}}^i = S_{\{i\}}^c = S_{\{i\}}^t$
- et si $Y = \varphi_u(X_u) + \varphi_{-u}(X_{-u}) \Rightarrow S_u^c + S_{-u}^c = 1$

Transposition des travaux de Shapley (théorie des jeux) à l'AS

- Dans la décomposition fonctionnelle, on perd l'orthogonalité entre les $\varphi_u(X_u)$
 - due à la dépendance entre les X_u
 - pas de formule explicite pour calculer les $\varphi_u(X_u)$
- Indices de Sobol généralisés issus des travaux de G. Chastaing (2013)
 - aux S_u on rajoute des termes de covariances
 - préservation de $\sum_{u \subseteq \{1:p\}} S_u = 1$
 - mais interprétation difficile car certains S_u peuvent être négatifs.
- Indices proposés par A. Owen (2014) à partir des travaux de L. S. Shapley (1953, théorie des jeux)
 - diffusés dans la communauté *incertitudes* (GdR MascotNum) par C. Prieur et B. Iooss (2017)
 - travaux actuels de B. Broto (thésard CEA) pour le cas paramétrique *linéaire gaussien* et dans le cas où on ne dispose que d'un n-échantillon i.i.d. (GdR MascotNum, soumis Mathematics and Computers in Simulation)
 - en neutronique, mise en oeuvre par L. Clouel (thésarde CEA) sur les incertitudes sur les données nucléaires (fluence cuve, Physor 2018, M&C2019)

Indices de Shapley proposés par Owen pour les études en AS

- Evaluation des joueurs dans un jeu à p joueurs
- L'ensemble des coalitions/équipes $u \subseteq [1 : p]$ au nombre $\leq 2^p$
- Fonction de gain $c(u)$ définie pour l'ensemble des coalitions avec $c(\emptyset) = 0$
- Valeur de Shapley η_i d'un joueur i est la valeur moyenne du gain qu'il apporte lorsqu'il intègre les équipes u constituées par les autres joueurs

$$\eta_i = \frac{1}{p} \sum_{u \subseteq -i} \binom{p-1}{|u|}^{-1} (c(u \cup \{i\}) - c(u)) \Rightarrow \sum_{i=1}^p \eta_i = c([1 : p])$$

- Pour l'AS, A. Owen (2014) propose comme fonction de gain la part de la variance de Y apportée par la coalition X_u (comme Sobol)

$$c(u) := \frac{\text{Var}(\mathbb{E}(Y|X_u))}{\text{Var}(Y)} \Rightarrow \sum_{i=1}^p \eta_i = 1$$

- Complexité combinatoire : cas général, 2^p calculs/estimations du gain
 - reformulation du calcul des indices en considérant l'ensemble des permutations des joueurs \rightarrow estimateurs par tirages Monte Carlo des permutations (E. Song)
 - solution analytique dans le cas linéaire gaussien, réduction du coût calculatoire en présence de groupes de variables indépendants (B. Broto)

Dans le cas de variables indépendantes

- Dans ce cas, l'indice de Shapley s'exprime en fonction des indices de Sobol

$$\eta_i = \sum_{u \subseteq [1:p] | u \ni i} \frac{S_u^i}{|u|}, \quad |u| = \text{cardinal de } u$$

- lien avec l'indice total de Sobol $S_{\{i\}}^t = \sum_{u \subseteq [1:p] | u \ni i} S_u^i$ intégrant toutes les éventuelles interactions entre X_i et les autres variables (sans la pondération par $1/|u|$)
- La valeur de l'indice de Shapley se situe alors entre celle de l'indice de Sobol du 1er ordre et celle de l'indice de sensibilité totale :

$$S_{\{i\}}^i \leq \eta_i \leq S_{\{i\}}^t$$

- L'égalité entre les 3 indices est obtenue si le modèle est de forme additive :

$$\left(\begin{array}{l} Y \\ X_i \end{array} = \sum_{i=1}^p \varphi_i(X_i) \right) \Rightarrow S_{\{i\}}^i = \eta_i = S_{\{i\}}^t, \quad i = 1, \dots, p$$

- Dans le cas général, par rapport aux indices de Sobol, les indices de Shapley ne permettent pas de distinguer entre la part due à la corrélation de celle due aux interactions (lorsque le modèle est non linéaire)

Indices de Shapley d'un modèle linéaire gaussien

- Cas particulier du modèle linéaire gaussien

$$Y = \beta^T X, \quad X \sim \mathcal{N}(\mu, \Gamma)$$

- Expression analytique des indices de Shapley en fonction
 - des paramètres du modèle β^T
 - de la matrice des variances, covariances Γ de la loi multivariée X

$$\eta_i = \frac{1}{\rho(\beta^T \Gamma \beta)} \sum_{u \subseteq -i} \binom{p-1}{|u|}^{-1} [\beta_{-u}^T (\Gamma_{-u, -u} - \Gamma_{-u, u} \Gamma_{u, u}^{-1} \Gamma_{u, -u}) \beta_{-u} - \beta_v^T (\Gamma_{v, v} - \Gamma_{v, u+i} \Gamma_{u+i, u+i}^{-1} \Gamma_{u+i, v}) \beta_v]$$

- A noter la même complexité combinatoire : 2^p termes à évaluer
- Algorithme LG-Shapley (B. Broto)
 - scripts R, Scilab
 - intégrée dans URANIE (plate-forme incertitudes du CEA/DEN)

Réduction de la complexité combinatoire

- En présence plusieurs groupes de variables indépendants, une méthode (B. Broto) permet de réduire considérablement la complexité calculatoire dans le cas d'un modèle additif
- Soient p variables avec k groupes indépendants de $n_{j=[1:k]}$ variables. Partition $[1 : p] = [u_1, u_2, \dots, u_k]$

$$Y = \sum_{j=1}^k \varphi_j(X_{u_j})$$

- L'analyse de sensibilité des p variables se ramène à k analyses de sensibilité découplées

$$\begin{aligned} \eta_{i \in u_j}^{(j)} &= \text{indice de Shapley de } X_{i \in u_j} \text{ de } \varphi_j(X_{u_j}) \\ \eta_i &= \eta_i^{(j)} \frac{\text{Var}(\varphi_j(X_{u_j}))}{\text{Var}(Y)} \end{aligned}$$

- Le nombre d'évaluations se réduit considérablement à $\sum_j 2^{n_j}$ comparé à 2^p
- Exemple : pour 2 groupes de 10 variables, réduction du nombre de calculs $2 \times 2^{10} / 2^{20} \simeq 2 \times 10^{-3}$

Interprétation des indices de Shapley sur un exemple à 2D

- Toute AS d'un modèle linéaire gaussien à 2D se ramène à l'AS du modèle

$$\begin{aligned} X &\sim \mathcal{N}\left(\begin{pmatrix} 0 \\ 0 \end{pmatrix}, \begin{pmatrix} 1 & \rho \\ \rho & 1 \end{pmatrix}\right) \\ Y &= \beta_1 X_1 + \beta_2 X_2 \end{aligned}$$

- Valeurs des indices de Shapley

$$\eta_1 = \frac{\beta_1^2 + \rho\beta_1\beta_2 - \rho^2(\beta_1^2 - \beta_2^2)/2}{\beta_1^2 + \beta_2^2 + 2\rho\beta_1\beta_2}, \quad \eta_2 = 1 - \eta_1$$

- Les effets des sensibilités *locales* (β_1, β_2) s'estompent lorsque le coefficient de corrélation tend vers 1 :

$$\forall \beta_1, \beta_2 \quad \lim_{\rho \rightarrow 1} \eta_1 = \eta_2 = 0.5$$

- Si $\rho_{X_1, X_2} = 1$, l'AS par les indices de Shapley des 2 modèles ...




$$\begin{aligned} Y_1 &= 1 \times X_1 + 0 \times X_2 \\ Y_2 &= 0 \times X_1 + 1 \times X_2 \end{aligned}$$

- ... affectera la même valeur aux 2 indices de Shapley $\eta_1 = \eta_2 = 0.5$
- Par construction, deux variables fortement corrélées sont indiscernables par Shapley
 - déroutant mais logique!!

Corrélations des incertitudes sur les données nucléaires

- Mise en oeuvre dans les études sur le vieillissement de la cuve des REP (L. Clouel, CEA/SERMA)
 - Traitement de la dosimétrie du programme de surveillance des effets de l'irradiation (projet PRFLU)
 - Analyse de sensibilité du flux neutronique aux incertitudes sur des données nucléaires avec prise en compte de leurs corrélations
 - Incertitudes sur la distribution spatiale de la source neutronique représentées par une loi normale multivariée
 - Plan d'expériences numériques suivi d'une approximation linéaire validée $Y = \varphi(X) \simeq \mathbb{E}(Y) + \beta^T (X - \mathbb{E}(X))$

Sensitivity of the neutron source spatial distribution on the fast fluence calculation



- L. Clouel, P. Mosca, J.M. Martinez, Uncertainty propagation of double-differential scattering cross section in fast fluence calculation for the PWR surveillance capsule, Physor2018
- ⇒ L. Clouel, P. Mosca, J.M. Martinez, Shapley effects for sensitivity analysis of PWR power distribution in fast fluence calculation, M&C2019
- Etude menée via la plateforme Uranie (DEN) après intégration de l'algorithme LG-Shapley

Quelques références



B. Broto, F. Bachoc, M. Depecker, and J.M. Martinez, *Sensitivity indices for independent groups of variables*, hal-01680687 (2018).



N. Benoumecharia and K. Elie-Dit-Cosaque, *Shapley effects for sensitivity analysis with dependent inputs : bootstrap and kriging-based algorithms*, hal-01677501 (2018).



L. Clouvel, P. Mosca, and J.M. Martinez, *Uncertainty propagation of double-differential scattering cross section in fast fluence calculation for the pwr surveillance capsules*, april 2018.



B. Iooss and C. Prieur, *Analyse de sensibilité avec entrées dépendantes : estimation par échantillonnage et par métamodèles des indices de shapley*, 49èmes Journées de la SFdS, Avignon (2017).



———, *Shapley effects for sensitivity analysis with dependent inputs : comparaisons with sobol indices, numerical estimation and applications*, hal-01556303v3 (2018).



A. Owen and C. Prieur, *On shapley value for measuring importance of dependent inputs*, arXiv :1610.02080v3 (2017).



A. Owen, *Sobol's indices and shapley value*, SIAM/ASA Journal on Uncertainty Quantification **2(1)** (2014).



E. Song, B. Nelson, and J. Staum, *Shapley effects for global sensitivity analysis : theory and computation*, SIAM/ASA Journal on Uncertainty Quantification **4** (2016).