

Estimation efficace des indices de Sobol du premier ordre

S. Da Veiga-F. G

IMT Toulouse

BoSanTouVal09

jeudi 04 Juin 2009





- 1 Modélisation d'un système physique et incertitudes
- 2 Analyse de sensibilité
- 3 Estimation efficace d'intégrales de fonctionnelles de densité

- 1 Modélisation d'un système physique et incertitudes
- 2 Analyse de sensibilité
- 3 Estimation efficace d'intégrales de fonctionnelles de densité

- Phénomène physique, chimique, économique : modélisation
- Sorties, variables d'entrées, paramètres, etc.
- Confiance du modèle ?
 - Entrées incertaines
 - Paramètres incertains

Conséquence : **incertitudes sur les sorties du modèle**

Modèle :

$$Y = f(X_1, \dots, X_d)$$

avec Y sorties du modèle et $\mathbf{X} = (X_1, \dots, X_d)$ vecteur des d facteurs (entrées + paramètres incertains).

Objectif

Quels sont les entrées et les paramètres qui ont le plus grand impact sur les sorties du modèle ?

- 1 Modélisation d'un système physique et incertitudes
- 2 Analyse de sensibilité
- 3 Estimation efficace d'intégrales de fonctionnelles de densité

Indices de sensibilité

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

- Interprétation :
 - $\mathbb{E}(Y|X_i)$: fonction de X_i uniquement qui *approche* le mieux Y
 - $\text{Var}(\mathbb{E}(Y|X_i))$: fluctuation de la sortie si elle était fonction uniquement de X_i
 - puis normalisation par la fluctuation totale de Y , $\text{Var}(Y)$

Indices de sensibilité

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

- Interprétation :
 - $\mathbb{E}(Y|X_i)$: fonction de X_i **uniquement** qui *approche* le mieux Y
 - $\text{Var}(\mathbb{E}(Y|X_i))$: fluctuation de la sortie si elle était fonction uniquement de X_i
 - puis normalisation par la fluctuation totale de Y , $\text{Var}(Y)$

- Techniques usuelles :
 - Sobol
 - FAST

Limitations

Nombre de runs
Hypothèse d'indépendance des entrées

- Exemples de cas problématiques
 - Réservoir pétrolier (temps de calcul)
 - Cinétique chimique (pas d'indépendance)

- Techniques usuelles :
 - Sobol
 - FAST

Limitations

Nombre de runs
Hypothèse d'indépendance des entrées

- Exemples de cas problématiques
 - Réservoir pétrolier (temps de calcul)
 - Cinétique chimique (pas d'indépendance)

- Techniques usuelles :
 - Sobol
 - FAST

Limitations

Nombre de runs
Hypothèse d'indépendance des entrées

- Exemples de cas problématiques
 - Réservoir pétrolier (temps de calcul)
 - Cinétique chimique (pas d'indépendance)

Sans hypothèse d'indépendance

- Méthode de Oakley et O'Hagan :
 - $f(\mathbf{X})$ approchée par processus Gaussiens
 - Puis intégration / loi de \mathbf{X}

Evaluation numérique d'intégrales multiples (dimension $2d - 1$)

- Méthode de Da-Veiga, Wahl et Gamboa :
 - $\mathbb{E}(Y|X_i)$ approchée par polynômes locaux
 - Plug-in pour $\text{Var}(\mathbb{E}(Y|X_i))$

Vitesse de convergence non-paramétrique

Sans hypothèse d'indépendance

- Méthode de Oakley et O'Hagan :
 - $f(\mathbf{X})$ approchée par processus Gaussiens
 - Puis intégration / loi de \mathbf{X}

Evaluation numérique d'intégrales multiples (dimension $2d - 1$)

- Méthode de Da-Veiga, Wahl et Gamboa :
 - $\mathbb{E}(Y|X_i)$ approchée par polynômes locaux
 - Plug-in pour $\text{Var}(\mathbb{E}(Y|X_i))$

Vitesse de convergence non-paramétrique

Sans hypothèse d'indépendance

- Méthode de Oakley et O'Hagan :
 - $f(\mathbf{X})$ approchée par processus Gaussiens
 - Puis intégration / loi de \mathbf{X}

Evaluation numérique d'intégrales multiples (dimension $2d - 1$)

- Méthode de Da-Veiga, Wahl et Gamboa :
 - $\mathbb{E}(Y|X_i)$ approchée par polynômes locaux
 - Plug-in pour $\text{Var}(\mathbb{E}(Y|X_i))$

Vitesse de convergence non-paramétrique

- 1 Modélisation d'un système physique et incertitudes
- 2 Analyse de sensibilité
- 3 Estimation efficace d'intégrales de fonctionnelles de densité

Réécriture du problème

$(X_i, Y_i), i = 1, \dots, n$ échantillon de (X, Y) , densité f

On veut estimer

$$\text{Var}(\mathbb{E}(Y|X)) = \mathbb{E}(\mathbb{E}(Y|X)^2) - (\mathbb{E}(Y))^2.$$

On définit l'opérateur T tel que

$$T(f) = \mathbb{E}(\mathbb{E}(Y|X)^2) = \iint \left(\frac{\int y f(x, y) dy}{\int f(x, y) dy} \right)^2 f(x, y) dx dy.$$

B. Laurent (1996) a étudié l'estimation efficace de fonctionnelles de la forme

$$T(f) = \int \phi(f(\mathbf{x}), \mathbf{x}) d\mathbf{x}$$

où ϕ régulière et X_1, \dots, X_n de densité de probabilité f .

Idée de construction d'un estimateur

Développer $u \rightarrow \phi(u, x) \in C^3$ autour d'un estimateur \hat{f} préliminaire

B. Laurent (1996) a étudié l'estimation efficace de fonctionnelles de la forme

$$T(f) = \int \phi(f(\mathbf{x}), \mathbf{x}) d\mathbf{x}$$

où ϕ régulière et X_1, \dots, X_n de densité de probabilité f .

Idée de construction d'un estimateur

Développer $u \rightarrow \phi(u, x) \in C^3$ autour d'un estimateur \hat{f} préliminaire

B. Laurent (1996) a étudié l'estimation efficace de fonctionnelles de la forme

$$T(f) = \int \phi(f(\mathbf{x}), \mathbf{x}) d\mathbf{x}$$

où ϕ régulière et X_1, \dots, X_n de densité de probabilité f .

Idée de construction d'un estimateur

Développer $u \rightarrow \phi(u, x) \in C^3$ autour d'un estimateur \hat{f} préliminaire

$$\begin{aligned} \phi(f(\mathbf{x}), \mathbf{x}) &= \phi(\hat{f}(\mathbf{x}), \mathbf{x}) + \frac{\partial \phi}{\partial u}(\hat{f}(\mathbf{x}), \mathbf{x}) \left(f(\mathbf{x}) - \hat{f}(\mathbf{x}) \right) \\ &\quad + \frac{\partial^2 \phi}{\partial u^2}(\hat{f}(\mathbf{x}), \mathbf{x}) \left(f(\mathbf{x}) - \hat{f}(\mathbf{x}) \right)^2 + \gamma. \end{aligned}$$

B. Laurent (1996) a étudié l'estimation efficace de fonctionnelles de la forme

$$T(f) = \int \phi(f(\mathbf{x}), \mathbf{x}) d\mathbf{x}$$

où ϕ régulière et X_1, \dots, X_n de densité de probabilité f .

Idée de construction d'un estimateur

Développer $u \rightarrow \phi(u, x) \in C^3$ autour d'un estimateur \hat{f} préliminaire

$$\begin{aligned} \phi(f(\mathbf{x}), \mathbf{x}) &= \phi(\hat{f}(\mathbf{x}), \mathbf{x}) + \phi'_1(\hat{f}(\mathbf{x}), \mathbf{x}) (f(\mathbf{x}) - \hat{f}(\mathbf{x})) \\ &\quad + \phi''_1(\hat{f}(\mathbf{x}), \mathbf{x}) (f(\mathbf{x}) - \hat{f}(\mathbf{x}))^2 + \gamma. \end{aligned}$$

$$T(f) = \int \phi(f(\mathbf{x}), \mathbf{x}) d\mathbf{x}$$

- Γ_n négligeable
- $\int H(\hat{f}, \cdot) f$ fonctionnelle linéaire de f : pas de problème
- $\int K(\hat{f}, \cdot) f^2$ fonctionnelle quadratique de f : estimation optimale (efficacité) ?

$$\begin{aligned}T(f) &= \int \phi(f(\mathbf{x}), \mathbf{x}) d\mathbf{x} \\ &= \int \phi(\hat{f}(\mathbf{x}), \mathbf{x}) d\mathbf{x} + \int \phi'_1(\hat{f}(\mathbf{x}), \mathbf{x}) (f(\mathbf{x}) - \hat{f}(\mathbf{x})) d\mathbf{x} \\ &\quad + \int \phi''_1(\hat{f}(\mathbf{x}), \mathbf{x}) (f(\mathbf{x}) - \hat{f}(\mathbf{x}))^2 d\mathbf{x} + \Gamma_n\end{aligned}$$

- Γ_n négligeable
- $\int H(\hat{f}, \cdot) f$ fonctionnelle linéaire de f : pas de problème
- $\int K(\hat{f}, \cdot) f^2$ fonctionnelle quadratique de f : estimation optimale (efficacité) ?

$$\begin{aligned}T(f) &= \int \phi(f(\mathbf{x}), \mathbf{x}) d\mathbf{x} \\&= \int \phi(\hat{f}(\mathbf{x}), \mathbf{x}) d\mathbf{x} + \int \phi'_1(\hat{f}(\mathbf{x}), \mathbf{x}) (f(\mathbf{x}) - \hat{f}(\mathbf{x})) d\mathbf{x} \\&\quad + \int \phi''_1(\hat{f}(\mathbf{x}), \mathbf{x}) (f(\mathbf{x}) - \hat{f}(\mathbf{x}))^2 d\mathbf{x} + \Gamma_n \\&= \int G(\hat{f}, \cdot) + \int H(\hat{f}, \cdot) f + \int K(\hat{f}, \cdot) f^2 + \Gamma_n\end{aligned}$$

- Γ_n négligeable
- $\int H(\hat{f}, \cdot) f$ fonctionnelle linéaire de f : pas de problème
- $\int K(\hat{f}, \cdot) f^2$ fonctionnelle quadratique de f : estimation optimale (efficacité) ?

$$\begin{aligned}T(f) &= \int \phi(f(\mathbf{x}), \mathbf{x}) d\mathbf{x} \\&= \int \phi(\hat{f}(\mathbf{x}), \mathbf{x}) d\mathbf{x} + \int \phi'_1(\hat{f}(\mathbf{x}), \mathbf{x}) (f(\mathbf{x}) - \hat{f}(\mathbf{x})) d\mathbf{x} \\&\quad + \int \phi''_1(\hat{f}(\mathbf{x}), \mathbf{x}) (f(\mathbf{x}) - \hat{f}(\mathbf{x}))^2 d\mathbf{x} + \Gamma_n \\&= \int G(\hat{f}, \cdot) + \int H(\hat{f}, \cdot) f + \int K(\hat{f}, \cdot) f^2 + \Gamma_n\end{aligned}$$

- Γ_n négligeable
- $\int H(\hat{f}, \cdot) f$ fonctionnelle linéaire de f : pas de problème
- $\int K(\hat{f}, \cdot) f^2$ fonctionnelle quadratique de f : estimation optimale (efficacité) ?

$$\begin{aligned}T(f) &= \int \phi(f(\mathbf{x}), \mathbf{x}) d\mathbf{x} \\&= \int \phi(\hat{f}(\mathbf{x}), \mathbf{x}) d\mathbf{x} + \int \phi'_1(\hat{f}(\mathbf{x}), \mathbf{x}) (f(\mathbf{x}) - \hat{f}(\mathbf{x})) d\mathbf{x} \\&\quad + \int \phi''_1(\hat{f}(\mathbf{x}), \mathbf{x}) (f(\mathbf{x}) - \hat{f}(\mathbf{x}))^2 d\mathbf{x} + \Gamma_n \\&= \int G(\hat{f}, \cdot) + \int H(\hat{f}, \cdot) f + \int K(\hat{f}, \cdot) f^2 + \Gamma_n\end{aligned}$$

- Γ_n négligeable
- $\int H(\hat{f}, \cdot) f$ fonctionnelle linéaire de f : pas de problème
- $\int K(\hat{f}, \cdot) f^2$ fonctionnelle quadratique de f : estimation optimale (efficacité) ?

$$\begin{aligned}T(f) &= \int \phi(f(\mathbf{x}), \mathbf{x}) d\mathbf{x} \\&= \int \phi(\hat{f}(\mathbf{x}), \mathbf{x}) d\mathbf{x} + \int \phi'_1(\hat{f}(\mathbf{x}), \mathbf{x}) (f(\mathbf{x}) - \hat{f}(\mathbf{x})) d\mathbf{x} \\&\quad + \int \phi''_1(\hat{f}(\mathbf{x}), \mathbf{x}) (f(\mathbf{x}) - \hat{f}(\mathbf{x}))^2 d\mathbf{x} + \Gamma_n \\&= \int G(\hat{f}, \cdot) + \int H(\hat{f}, \cdot) f + \int K(\hat{f}, \cdot) f^2 + \Gamma_n\end{aligned}$$

- Γ_n négligeable
- $\int H(\hat{f}, \cdot) f$ fonctionnelle linéaire de f : pas de problème
- $\int K(\hat{f}, \cdot) f^2$ fonctionnelle quadratique de f : estimation optimale (efficacité) ?

Estimation efficace de fonctionnelles quadratique

On veut estimer

$$\int K(\hat{f}, \cdot) f^2 \equiv \int \psi f^2$$

où $f \in \mathbb{L}^2(dx)$ densité de X , échantillon (X_1, \dots, X_n) .

Estimation efficace de fonctionnelles quadratique

On veut estimer

$$\int K(\hat{f}, \cdot) f^2 \equiv \int \psi f^2$$

où $f \in \mathbb{L}^2(dx)$ densité de X , échantillon (X_1, \dots, X_n) .

Soit $(p_i)_{i \in D}$ base orthonormale de $\mathbb{L}^2(dx)$, D dénombrable, $a_i = \int f p_i$.

Estimation par projection

Estimation efficace de fonctionnelles quadratique

On veut estimer

$$\int K(\hat{f}, \cdot) f^2 \equiv \int \psi f^2$$

où $f \in \mathbb{L}^2(dx)$ densité de X , échantillon (X_1, \dots, X_n) .

Soit $(p_i)_{i \in D}$ base orthonormale de $\mathbb{L}^2(dx)$, D dénombrable, $a_i = \int f p_i$.

Estimation par projection

Cas particulier : $\psi = 1$

- $\int f^2 = \sum_{i \in D} a_i^2 \Rightarrow \tilde{\theta} = \sum_{i \in M} \hat{a}_i^2, \hat{a}_i = \frac{1}{n} \sum_{j=1}^n p_i(X_j), M \subset D$
- Réduction du biais : $\tilde{\theta} = \frac{1}{n(n-1)} \sum_{i \in M} \sum_{j \neq k=1}^n p_i(X_j) p_i(X_k)$

Estimation efficace de fonctionnelles quadratique

$$\psi = 1 \quad \tilde{\theta} = \frac{1}{n(n-1)} \sum_{i \in M} \sum_{j \neq k=1}^n p_i(X_j) p_i(X_k)$$

Estimation efficace de fonctionnelles quadratique

$$\psi = 1 \quad \tilde{\theta} = \frac{1}{n(n-1)} \sum_{i \in M} \sum_{j \neq k=1}^n p_i(X_j) p_i(X_k)$$

$$\text{Biais}(\tilde{\theta}) = - \int (S_M f - f)^2 \quad \text{avec} \quad S_M f = \sum_{i \in M} a_i p_i$$

Seulement un biais de projection

Estimation efficace de fonctionnelles quadratique

$$\psi = 1 \quad \tilde{\theta} = \frac{1}{n(n-1)} \sum_{i \in M} \sum_{j \neq k=1}^n p_i(X_j) p_i(X_k)$$

$$\text{Biais}(\tilde{\theta}) = - \int (S_M f - f)^2 \quad \text{avec} \quad S_M f = \sum_{i \in M} a_i p_i$$

Seulement un biais de projection

$$\psi \text{ quelconque} : - \int (S_M f - f)^2 \psi = 2 \int (S_M f) f \psi - \int (S_M f)^2 \psi - \int \psi f^2$$

Estimation efficace de fonctionnelles quadratique

$$\psi = 1 \quad \tilde{\theta} = \frac{1}{n(n-1)} \sum_{i \in M} \sum_{j \neq k=1}^n p_i(X_j) p_i(X_k)$$

$$\text{Biais}(\tilde{\theta}) = - \int (S_M f - f)^2 \quad \text{avec} \quad S_M f = \sum_{i \in M} a_i p_i$$

Seulement un biais de projection

$$\psi \text{ quelconque} : - \int (S_M f - f)^2 \psi = 2 \int (S_M f) f \psi - \int (S_M f)^2 \psi - \int \psi f^2$$

Estimateur proposé :

$$\hat{\theta} = \frac{2}{n(n-1)} \sum_{i \in M} \sum_{j \neq k=1}^n p_i(X_j) (p_i \psi)(X_k) \\ - \frac{1}{n(n-1)} \sum_{i, i' \in M} \sum_{j \neq k=1}^n p_i(X_j) p_{i'}(X_k) \int p_i p_{i'} \psi(x) dx$$

Hypothèses

X_1, \dots, X_n i.i.d. $f \in \mathbb{L}^2(dx)$. $(p_i)_{i \in D}$ base orthonormée de $\mathbb{L}^2(dx)$

- ψ bornée, f uniformément bornée et $f \in \mathcal{E}$,

$$\mathcal{E} = \left\{ \sum_{i \in D} a_i p_i; \sum_{i \in D} \left| \frac{a_i^2}{c_i^2} \right| \leq 1 \right\}$$

- $M_n \subset D$ tq $\left(\sup_{i \notin M_n} |c_i|^2 \right)^2 \approx \frac{|M_n|}{n^2}$
- $\forall t \in \mathbb{L}^2(d\mu), \int (S_{M_n} t - t)^2 d\mu \rightarrow 0$

Théorème (Estimation efficace de $\theta = \int \psi f^2$)

(i) Si $|M|/n \rightarrow 0$

$$\sqrt{n} (\hat{\theta} - \theta) \rightarrow \mathcal{N}(0, \Lambda(f, \psi)),$$

$$\left| \mathbb{E} (\hat{\theta} - \theta)^2 - \Lambda(f, \psi) \right| \leq \gamma_1 \left[\frac{|M|}{n} + \|S_M f - f\|_2 + \|S_M(f\psi) - f\psi\|_2 \right]$$

$$\text{où } \Lambda(f, \psi) = 4 \left[\int f^3 \psi^2 - \left(\int f^2 \psi \right)^2 \right],$$

(ii) Sinon

$$\mathbb{E} (\hat{\theta} - \theta)^2 \leq \gamma_2 \frac{|M|}{n}.$$

Théorème (Estimation efficace de $\theta = \int \psi f^2$)

(i) Si $|M|/n \rightarrow 0$

$$\sqrt{n} (\hat{\theta} - \theta) \rightarrow \mathcal{N}(0, \Lambda(f, \psi)),$$

$$\left| \mathbb{E} (\hat{\theta} - \theta)^2 - \Lambda(f, \psi) \right| \leq \gamma_1 \left[\frac{|M|}{n} + \|S_M f - f\|_2 + \|S_M(f\psi) - f\psi\|_2 \right]$$

$$\text{où } \Lambda(f, \psi) = 4 \left[\int f^3 \psi^2 - \left(\int f^2 \psi \right)^2 \right],$$

(ii) Sinon

$$\mathbb{E} (\hat{\theta} - \theta)^2 \leq \gamma_2 \frac{|M|}{n}.$$

$$\lim_{n \rightarrow \infty} n \mathbb{E} (\hat{\theta}_n - \theta)^2 = \Lambda(f, \psi)$$

Estimation efficace de fonctionnelles quadratique

Théorème (Estimation efficace de $\theta = \int \psi f^2$)

(i) Si $|M|/n \rightarrow 0$

$$\sqrt{n} (\hat{\theta} - \theta) \rightarrow \mathcal{N}(0, \Lambda(f, \psi)),$$

$$\left| \mathbb{E} (\hat{\theta} - \theta)^2 - \Lambda(f, \psi) \right| \leq \gamma_1 \left[\frac{|M|}{n} + \|S_M f - f\|_2 + \|S_M(f\psi) - f\psi\|_2 \right]$$

$$\text{où } \Lambda(f, \psi) = 4 \left[\int f^3 \psi^2 - \left(\int f^2 \psi \right)^2 \right],$$

(ii) Sinon

$$\mathbb{E} (\hat{\theta} - \theta)^2 \leq \gamma_2 \frac{|M|}{n}.$$

$\Lambda(f, \psi)$ optimale (borne de Cramér-Rao semi-paramétrique)

Estimation efficace de fonctionnelles quadratique

Théorème (Estimation efficace de $\theta = \int \psi f^2$)

(i) Si $|M|/n \rightarrow 0$

$$\sqrt{n} (\hat{\theta} - \theta) \rightarrow \mathcal{N}(0, \Lambda(f, \psi)),$$

$$\left| \mathbb{E} (\hat{\theta} - \theta)^2 - \Lambda(f, \psi) \right| \leq \gamma_1 \left[\frac{|M|}{n} + \|S_M f - f\|_2 + \|S_M(f\psi) - f\psi\|_2 \right]$$

$$\text{où } \Lambda(f, \psi) = 4 \left[\int f^3 \psi^2 - \left(\int f^2 \psi \right)^2 \right],$$

(ii) Sinon

$$\mathbb{E} (\hat{\theta} - \theta)^2 \leq \gamma_2 \frac{|M|}{n}.$$

Bornes explicites car ψ aléatoire et dépendant de n dans Taylor

Esquisse de la démonstration

$$\mathbb{E} \left(\hat{\theta} - \int \psi f^2 \right)^2 = \text{Biais}^2(\hat{\theta}) + \text{Var}(\hat{\theta})$$

- $\text{Biais}(\hat{\theta}) = - \int (S_M f - f)^2 \psi :$

$$\left| \text{Biais}(\hat{\theta}) \right| \leq \|\psi\|_\infty \int (S_M f - f)^2 = \|\psi\|_\infty \sum_{i \neq M} |a_i|^2 \leq \|\psi\|_\infty \sup_{i \neq M} |c_i|^2$$

- Partie technique : majoration de $\text{Var}(\hat{\theta})$

$$T(f) = \int G(\hat{f}, \cdot) + \int \left(\phi_1'(\hat{f}, \cdot) - \hat{f} \phi_1''(\hat{f}, \cdot) \right) f + \int \frac{1}{2} \phi_1''(\hat{f}, \cdot) f^2 + \Gamma_n$$

estimé par

$$\begin{aligned} \hat{T}_n &= \int G(\hat{f}, \cdot) + \frac{1}{n_2} \sum_{j=1}^{n_2} \left(\phi_1'(\hat{f}, \cdot) - \hat{f} \phi_1''(\hat{f}, \cdot) \right) (X_j) \\ &\quad + \frac{2}{n_2(n_2 - 1)} \sum_{i \in M} \sum_{j \neq k=1}^{n_2} p_i(X_j) \left(p_i \frac{1}{2} \phi_1''(\hat{f}, \cdot) \right) (X_k) \\ &\quad - \frac{1}{n_2(n_2 - 1)} \sum_{i, i' \in M} \sum_{j \neq k=1}^{n_2} p_i(X_j) p_{i'}(X_k) \int p_i p_{i'} \frac{1}{2} \phi_1''(\hat{f}, \cdot) \end{aligned}$$

On montre que $\hat{T}_n - T(f)$ a même comportement asymptotique que

$$\frac{1}{n_2} \sum_{j=1}^{n_2} \phi'_1(f, \cdot)(X_j) - \int \phi'_1(f, \cdot) f$$

Hypothèses

X_1, \dots, X_n i.i.d. $f \in \mathbb{L}^2(dx)$. $(p_i)_{i \in D}$ base orthonormée de $\mathbb{L}^2(dx)$

- $\phi \in C^3$, f uniformément bornée et $f \in \mathcal{E}$

- $a \leq f \leq b$ et $a - \epsilon \leq \hat{f} \leq b + \epsilon$

- $\mathbb{E} \|\hat{f} - f\|_q^l \leq C n_1^{-l\lambda} \forall l, q \geq 2, \lambda > 1/6$

- $M_n \subset D$ tq $\left(\sup_{i \notin M_n} |c_i|^2 \right)^2 \approx \frac{|M_n|}{n^2}$

- $\forall t \in \mathbb{L}^2(d\mu), \int (S_{M_n} t - t)^2 d\mu \rightarrow 0$

Théorème (Estimation efficace de $T(f)$)

(i) Si $|M|/n \rightarrow 0$

$$\sqrt{n} (\hat{T}_n - T(f)) \rightarrow \mathcal{N}(0, C(f, \phi))$$

(ii)

$$\lim_{n \rightarrow \infty} n \mathbb{E}(\hat{T}_n - T(f))^2 = C(f, \phi)$$

où

$$C(f, \phi) = \int (\phi'_1(f, \cdot))^2 f - \left(\int \phi'_1(f, \cdot) f \right)^2$$

$C(f, \phi)$ constante optimale

On veut estimer

$$T(f) = \mathbb{E}(\mathbb{E}(Y|X)^2) = \iint \left(\frac{\int y f(x, y) dy}{\int f(x, y) dy} \right)^2 f(x, y) dx dy.$$

On suit la méthode précédente : on développe $T(f)$ autour d'un estimateur préliminaire \hat{f} .

Développement de $T(f)$

$$\begin{aligned}T(f) &= \iint [2y\hat{m}(x) - \hat{m}(x)^2] f(x, y) dx dy \\ &+ \iiint \frac{1}{(\int \hat{f}(x, y) dy)} [yz + \hat{m}(x)^2 - (y + z)\hat{m}(x)] f(x, y) f(x, z) dx dy dz \\ &+ \Gamma_n \\ &= \iint H(\hat{f}, x, y) f(x, y) dx dy + \iiint K(\hat{f}, x, y, z) f(x, y) f(x, z) dx dy dz \\ &+ \Gamma_n\end{aligned}$$

où

$$\begin{aligned}H(\hat{f}, x, y) &= 2y\hat{m}(x) - \hat{m}(x)^2 \\ K(\hat{f}, x, y, z) &= \frac{1}{(\int \hat{f}(x, y) dy)} [yz + \hat{m}(x)^2 - (y + z)\hat{m}(x)] .\end{aligned}$$

Estimation de fonctionnelles quadratiques

On veut estimer

$$\iiint K(\hat{f}, x, y, z)f(x, y)f(x, z) = \iiint \psi(x, y, z)f(x, y)f(x, z)$$

- Idée : même procédure que B. Laurent
- On cherche un estimateur de biais

$$\begin{aligned} & - \iiint [S_M f(x, y) - f(x, y)][S_M f(x, z) - f(x, z)]\psi(x, y, z) dx dy dz \\ & = 2 \iiint S_M f(x, y)f(x, z)\psi(x, y, z) dx dy dz \\ & \quad - \iiint S_M f(x, y)S_M f(x, z)\psi(x, y, z) dx dy dz \\ & \quad - \iiint f(x, y)f(x, z)\psi(x, y, z) dx dy dz \end{aligned}$$

Estimateur proposé :

$$\begin{aligned}\hat{\theta}_n &= \frac{2}{n(n-1)} \sum_{i \in M} \sum_{j \neq k=1}^n p_i(X_j, Y_j) \int p_i(X_k, u) \psi(X_k, u, Y_k) du \\ &\quad - \frac{1}{n(n-1)} \sum_{i, i' \in M} \sum_{j \neq k=1}^n p_i(X_j, Y_j) p_{i'}(X_k, Y_k) \\ &\quad \iiint p_i(x, y) p_{i'}(x, z) \psi(x, y, z) dx dy dz.\end{aligned}$$

Hypothèses

X_1, \dots, X_n i.i.d. $f \in \mathbb{L}^2(dx)$. $(p_i)_{i \in D}$ base orthonormée de $\mathbb{L}^2(dx)$

- $\psi(x, y, z)$ bornée, f uniformément bornée et $f \in \mathcal{E}$,

$$\mathcal{E} = \left\{ \sum_{i \in D} a_i p_i; \sum_{i \in D} \left| \frac{a_i^2}{c_i^2} \right| \leq 1 \right\}$$

- $M_n \subset D$ tq $\left(\sup_{i \notin M_n} |c_i|^2 \right)^2 \approx \frac{|M_n|}{n^2}$
- $\forall t \in \mathbb{L}^2(d\mu), \int (S_{M_n} t - t)^2 d\mu \rightarrow 0$

Théorème (Estimation efficace de $\theta = \int \psi(x, y, z)f(x, y)f(x, z)$)

(i) Si $|M|/n \rightarrow 0$

$$\sqrt{n} (\hat{\theta} - \theta) \rightarrow \mathcal{N}(0, \Lambda(f, \psi)),$$

$$\left| \mathbb{E} (\hat{\theta} - \theta)^2 - \Lambda(f, \psi) \right| \leq \gamma_1 \left[\frac{|M|}{n} + \|S_M f - f\|_2 + \|S_M(g) - g\|_2 \right]$$

$$\text{où } \Lambda(f, \psi) = 4 \left[\iint g(x, y)^2 f(x, y) dx dy - \left(\iint g(x, y) f(x, y) dx dy \right)^2 \right]$$

où

$$g(x, y) = \int f(x, u) \psi(x, y, u) du$$

Retour au dvt de Taylor

$$T(f) = \iint H(\hat{f}, x, y)f(x, y)dxdy + \iiint K(\hat{f}, x, y, z)f(x, y)f(x, z)dxdydz \\ + \Gamma_n$$

Estimateur proposé :

$$\hat{\theta}_n = \frac{1}{n_2} \sum_{j=1}^{n_2} H(\hat{f}, X_j, Y_j) \\ + \frac{2}{n_2(n_2 - 1)} \sum_{i \in M} \sum_{j \neq k=1}^{n_2} p_i(X_j, Y_j) \int p_i(X_k, u) K(\hat{f}, X_k, u, Y_k) du \\ - \frac{1}{n_2(n_2 - 1)} \sum_{i, i' \in M} \sum_{j \neq k=1}^{n_2} p_i(X_j, Y_j) p_{i'}(X_k, Y_k) \\ \iiint p_i(x, y) p_{i'}(x, z) K(\hat{f}, x, y, z) dxdydz.$$

Théorème (Estimation efficace de $T(f)$)

(i) Si $|M|/n \rightarrow 0$

$$\sqrt{n} (\hat{T}_n - T(f)) \rightarrow \mathcal{N}(0, C(f))$$

(ii)

$$\lim_{n \rightarrow \infty} n \mathbb{E}(\hat{T}_n - T(f))^2 = C(f)$$

où

$$C(f) = \iint H(f, x, y)^2 f(x, y) d\mu(x, y) - \left(\iint H(f, x, y) f(x, y) d\mu(x, y) \right)^2$$

$C(f) = 4\mathbb{E}(\text{Var}(Y|X)\mathbb{E}(Y|X)^2) + \text{Var}(\mathbb{E}(Y|X)^2)$ constante optimale

- On peut généraliser très facilement ce résultat aux estimateurs des fonctionnelles

$$\mathbb{E}\left(\psi\left(\mathbb{E}(\phi(Y)|X)\right)\right)$$

si $f \in \mathbb{L}^2(dx dy)$, $\phi \in C^0$ et $\psi \in C^3$.

- Constante optimale :

$$C(f) = \mathbb{E}\left(\text{Var}(\phi(Y)|X) \left[\dot{\psi}\left(\mathbb{E}(Y|X)\right)\right]^2\right) + \text{Var}\left(\psi\left(\mathbb{E}(\phi(Y)|X)\right)\right)$$

Meilleure procédure d'estimation

- Pour estimer $\mathbb{E}(\mathbb{E}(Y|X^i)^2)$, on utilise un échantillon du couple (X^i, Y)
- On ne tient pas compte des réalisations des autres facteurs X^j , $j \neq i$

Perd-on de l'information ?

Asymptotiquement, les autres composantes n'apportent pas d'information pour estimer S_i

Meilleure procédure d'estimation

- Pour estimer $\mathbb{E}(\mathbb{E}(Y|X^i)^2)$, on utilise un échantillon du couple (X^i, Y)
- On ne tient pas compte des réalisations des autres facteurs X^j , $j \neq i$

Perd-on de l'information ?

Asymptotiquement, les autres composantes n'apportent pas d'information pour estimer S_i

Meilleure procédure d'estimation

- Pour estimer $\mathbb{E}(\mathbb{E}(Y|X^i)^2)$, on utilise un échantillon du couple (X^i, Y)
- On ne tient pas compte des réalisations des autres facteurs X^j , $j \neq i$

Perd-on de l'information ?

Réponse :

- La constante optimale en considérant toutes les composantes (X^1, \dots, X^d) est encore $C(f)$
- Or notre estimateur \hat{T}_n atteint cette vitesse en travaillant uniquement avec (X^i, Y)

Asymptotiquement, les autres composantes n'apportent pas d'information pour estimer S_i

Meilleure procédure d'estimation

- Pour estimer $\mathbb{E}(\mathbb{E}(Y|X^i)^2)$, on utilise un échantillon du couple (X^i, Y)
- On ne tient pas compte des réalisations des autres facteurs X^j , $j \neq i$

Perd-on de l'information ?

Réponse :

- La constante optimale en considérant toutes les composantes (X^1, \dots, X^d) est encore $C(f)$
- Or notre estimateur \hat{T}_n atteint cette vitesse en travaillant uniquement avec (X^i, Y)

Asymptotiquement, les autres composantes n'apportent pas d'information pour estimer S_i

Meilleure procédure d'estimation

- Pour estimer $\mathbb{E}(\mathbb{E}(Y|X^i)^2)$, on utilise un échantillon du couple (X^i, Y)
- On ne tient pas compte des réalisations des autres facteurs X^j , $j \neq i$

Perd-on de l'information ?


Réponse :

- La constante optimale en considérant toutes les composantes (X^1, \dots, X^d) est encore $C(f)$
- Or notre estimateur \hat{T}_n atteint cette vitesse en travaillant uniquement avec (X^i, Y)

Asymptotiquement, les autres composantes n'apportent pas d'information pour estimer S_i


Exemple analytique

$$Y = 0.2 \exp(X_1 - 3) + 2.2|X_2| + 1.3X_2^6 - 2X_2^2 - 0.5X_2^4 - 0.5X_1^4 + 2.5X_1^2 + 0.7X_1^3 + \frac{3}{(8X_1 - 2)^2 + (5X_2 - 3)^2 + 1} + \sin(5X_1) \cos(3X_1^2)$$




Krigeage (courbe théorique, approximation)


$$f(X_1, X_2)$$



$$\mathbb{E}(Y|X_1)$$





$$\mathbb{E}(Y|X_2)$$





Polynômes locaux (courbe théorique, approximation)

Échantillons marginaux

$$\mathbb{E}(Y|X_1)$$



$$\mathbb{E}(Y|X_2)$$



Exemple analytique

		Krigeage	Poly. loc.	Est. eff.
		100 pts	100 pts	100 pts
$\text{Var}(\mathbb{E}(Y X_1))$	1.0932	1.0539	1.0643	1.1701
$\text{Var}(\mathbb{E}(Y X_2))$	0.0729	0.1121	0.0527	0.0939

X_1 : résultats comparables

X_2 : meilleure précision pour les approximations marginales

- Tests numériques (efficacité asymptotique, quid avec n petit ?)
- Autres fonctionnelles faisant intervenir ces formes quadratiques ?
- Méthodes adaptatives ?

Muchas Gracias