

Utilisation d'échantillonnage pondéré dans les estimations répétées

Dorota Gajda^{1 2}
Chantal Guihenneuc-Jouyaux^{2 3}

¹IGR ²INSERM U1018 - EQ01PTB - CESP
³Université Paris Descartes

AppliBUGS, 20 décembre 2012

Étude empirique d'estimateurs par simulations

- Différentes valeurs des paramètres : L paramétrisations
- Simulation de K jeux de données sous le modèle d'intérêt
- Estimation des paramètres sur chaque jeu de données ($K \times L$)
- Etude des performances des estimations des paramètres (pour chaque paramétrisation)

Étude empirique d'estimateurs par simulations

- Différentes valeurs des paramètres : L paramétrisations
- Simulation de K jeux de données sous le modèle d'intérêt
- Estimation des paramètres sur chaque jeu de données ($K \times L$)
- Etude des performances des estimations des paramètres (pour chaque paramétrisation)

Étude empirique d'estimateurs par simulations

- Différentes valeurs des paramètres : L paramétrisations
- Simulation de K jeux de données sous le modèle d'intérêt
- Estimation des paramètres sur chaque jeu de données ($K \times L$)
- Etude des performances des estimations des paramètres (pour chaque paramétrisation)

Étude empirique d'estimateurs par simulations

- Différentes valeurs des paramètres : L paramétrisations
- Simulation de K jeux de données sous le modèle d'intérêt
- Estimation des paramètres sur chaque jeu de données ($K \times L$)
- Etude des performances des estimations des paramètres (pour chaque paramétrisation)

Modèle Bayésien

Modèle paramétrique M_θ pour les données (X)

- idée a priori sur θ $\Rightarrow \pi(\theta)$
- information provenant des données $\Rightarrow \pi(X|\theta)$
- Combinaison des 2 sources d'information
(a priori + données)= loi a posteriori $\Rightarrow \pi(\theta|X)$

par Théorème de Bayes

$$\pi(\theta|X) = \frac{\pi(\theta, X)}{\pi(X)} = \frac{\pi(X|\theta) \cdot \pi(\theta)}{\pi(X)}$$

Estimations répétées

- Étude « empirique » d'estimateurs → via les simulations
- Nécessité d'un grand nombre de réplifications de jeux de données
- Les résultats d'une approche bayésienne
 - loi a posteriori (souvent multidimensionnelle)
ainsi que ses caractéristiques
(en pratique approchées par algorithmes itératifs)
- Temps de calcul parfois lourd
 - ⇒ Diminution du nombre de réplifications ou
 - ⇒ Étude considérée non faisable

Étude de simulations dans le cadre Bayésien

- Simuler K jeux de données $X^{(K)} = (X_1, \dots, X_N)$ sous le modèle M_θ en fixant les paramètres $\theta = \theta_0$

$$X_i \sim \pi(X|\theta_0)$$

- Fixer une même loi a priori sur les paramètres $\pi(\theta)$
- Calculer des espérances d'une fonction d'intérêt $g(\theta)$:

$$E_{[\theta|X]}[g(\theta)] = \int_{\Theta} g(\theta)\pi(\theta|X)d\theta$$

$$g(\theta) = \theta, \quad g(\theta) = \theta^2, \quad g(\theta) = \dots$$

- Étudier L scénarios pour les différents choix de θ_0

Problème calculatoire

- $\pi(\theta|X^{(K)})$ et/ou les intégrales de $\pi(\theta|X^{(K)})$ non explicites

Méthode classique : MCMC systématiquement

- Algorithme permettant de simuler une chaîne de Markov $\{\theta_1, \dots, \theta_N\}$ ayant pour loi stationnaire la loi a posteriori $\pi(\theta|X)$

(N=nombre total d'itérations)

- Par théorème ergodique,

Si CM $\{\theta_1, \dots, \theta_N\} \sim \pi(\theta|X)$ alors

$$\frac{1}{N} \sum_{i=1}^N g(\theta_i) \longrightarrow E_{[\theta|X]}[g(\theta)]$$

pour $g(\theta) = \theta$, $g(\theta) = \theta^2$, $g(\theta) = \dots$

Méthode itérative pour $K \times L$ estimations

⇒ procédure coûteuse en temps

Importance Sampling avec 2 jeux de données

- On a déjà une réalisation Markov. de la loi a posteriori $\pi(\theta|X^{(1)})$ (MCMC avec $X^{(1)}$)
- On veut estimer $E_{[\theta|X^{(2)}]}[g(\theta)]$ sans faire de MCMC

$$E_{[\theta|X^{(2)}]}[g(\theta)] = \int g(\theta)\pi(\theta|X^{(2)})d\theta = \int g(\theta)\frac{\pi(\theta|X^{(2)})}{\pi(\theta|X^{(1)})}\pi(\theta|X^{(1)})d\theta$$

Par th. ergodique,

si $\theta_1, \dots, \theta_N \sim \pi(\theta|X^{(1)})$ alors

$$\frac{1}{N} \sum_{i=1}^N g(\theta_i) \frac{\pi(\theta_i|X^{(2)})}{\pi(\theta_i|X^{(1)})} \rightarrow E_{[\theta|X^{(2)}]}[g(\theta)]$$

$\pi(\theta|X^{(1)})$ est appelée **fonction d'importance**

IS combinée avec MCMC pour $K=101$

1^{ère} stratégie : "Référence fixe"

1 × MCMC + 100 × IS

⇒ la même fonction d'importance $\pi(\theta|X^{(1)})$ obtenue via MCMC avec $X^{(1)}$

2^{ème} stratégie : "Référence choisie"

10 × MCMC + 91 × IS

⇒ la fonction d'importance est différente $\pi(\theta|X^{(m_k)})$ où $X^{(m_k)}$ est choisie parmi $X^{(1)}, \dots, X^{(10)}$ via un des trois critères (Gajda et al. 2010) :

- critère 1 : minimisation de la norme L_1 : $\|\pi(\theta^{(m_k)}|X^{(k)}) - \pi(\theta^{(m_k)}|X^{(m_k)})\|_{L_1}$
- critère 2 : minimisation de la KL-divergence : $KL(\pi(\theta^{(m_k)}|X^{(k)}), \pi(\theta^{(m_k)}|X^{(m_k)}))$
- critère 3 : minimisation de la variance IS

3^{ème} stratégie : "Mélange de densités"

10 × MCMC + 91 × IS

⇒ la fonction d'importance $\pi_{mix}(\theta) = \frac{1}{10} \sum_{j=1}^{10} \pi(\theta|X^{(j)})$ (Gajda et al. 2011)

IS combinée avec MCMC pour $K=101$

1^{ère} stratégie : "Référence fixe"

1 × MCMC + 100 × IS

⇒ la même fonction d'importance $\pi(\theta|X^{(1)})$ obtenue via MCMC avec $X^{(1)}$

2^{ème} stratégie : "Référence choisie"

10 × MCMC + 91 × IS

⇒ la fonction d'importance est différente $\pi(\theta|X^{(m_k)})$ où $X^{(m_k)}$ est choisie parmi $X^{(1)}, \dots, X^{(10)}$ via un des trois critères (Gajda et al. 2010) :

- critère 1 : minimisation de la norme L_1 : $\|\pi(\theta^{(m_k)}|X^{(k)}) - \pi(\theta^{(m_k)}|X^{(m_k)})\|_{L_1}$
- critère 2 : minimisation de la KL-divergence : $KL(\pi(\theta^{(m_k)}|X^{(k)}), \pi(\theta^{(m_k)}|X^{(m_k)}))$
- critère 3 : minimisation de la variance IS

3^{ème} stratégie : "Mélange de densités"

10 × MCMC + 91 × IS

⇒ la fonction d'importance $\pi_{mix}(\theta) = \frac{1}{10} \sum_{j=1}^{10} \pi(\theta|X^{(j)})$ (Gajda et al. 2011)

IS combinée avec MCMC pour $K=101$

1^{ère} stratégie : "Référence fixe"

1 × MCMC + 100 × IS

⇒ la même fonction d'importance $\pi(\theta|X^{(1)})$ obtenue via MCMC avec $X^{(1)}$

2^{ème} stratégie : "Référence choisie"

10 × MCMC + 91 × IS

⇒ la fonction d'importance est différente $\pi(\theta|X^{(m_k)})$ où $X^{(m_k)}$ est choisie parmi $X^{(1)}, \dots, X^{(10)}$ via un des trois critères (Gajda et al. 2010) :


- critère 1 : minimisation de la norme L_1 : $\|\pi(\theta^{(m_k)}|X^{(k)}) - \pi(\theta^{(m_k)}|X^{(m_k)})\|_{L_1}$
- critère 2 : minimisation de la KL-divergence : $KL(\pi(\theta^{(m_k)}|X^{(k)}), \pi(\theta^{(m_k)}|X^{(m_k)}))$
- critère 3 : minimisation de la variance IS

3^{ème} stratégie : "Mélange de densités"

10 × MCMC + 91 × IS

⇒ la fonction d'importance $\pi_{mix}(\theta) = \frac{1}{10} \sum_{j=1}^{10} \pi(\theta|X^{(j)})$ (Gajda et al. 2011)

1^{ère} stratégie : "Référence fixe"




2^{ème} stratégie : "Référence choisie" - objectif

$$\text{supp} \{g\pi(\cdot|X^{(k)})\} \subset \text{supp} \{\pi(\cdot|X^{(1)})\} \quad ???$$

Objectif : Améliorer le choix de la fonction d'importance


- ⇒ Supports plus proches
- ⇒ Choix de la référence parmi 10 jeux de données présélectionnés pour chaque nouvelle estimation via IS
- ⇒ Étude de l'amélioration des performances par rapport à la 1^{ère} stratégie

2^{ème} stratégie : "Référence choisie" - démarche



2^{ème} stratégie : "Référence choisie" - critère 1

Critère 1 basé sur la minimisation de la norme L^1 de la différence entre deux densités a posteriori $\|\pi(\theta^{(m_k)}|X^{(k)}) - \pi(\theta^{(m_k)}|X^{(m_k)})\|_{L^1}$



avec $\tilde{w}_i(k, m_k) = \frac{w_i(k, m_k)}{\sum_{i=1}^N w_i(k, m_k)}$ et $w_i(k, m_k) = \frac{\pi(X^{(k)}|\theta_i^{(m_k)})}{\pi(X^{(m_k)}|\theta_i^{(m_k)})}$

$$\min_{m_k \in \{1, \dots, M\}} \left\{ \sum_{i=1}^N \left| \tilde{w}_i(k, m_k) - \frac{1}{N} \right| \right\}.$$

2^{ème} stratégie : "Référence choisie" - critère 2

Critère 2 basé sur la minimisation de la divergence de Kullback-Leibler entre deux densités a posteriori

$$KL(\pi(\theta|X^{(k)}), \pi(\theta|X^{(m_k)})) = \int \log\left(\frac{\pi(\theta|X^{(k)})}{\pi(\theta|X^{(m_k)})}\right) \pi(\theta|X^{(k)}) d\theta$$

⇒ "contrôle" du comportement des queues de la distribution

avec $\tilde{w}_i(k, m_k) = \frac{w_i(k, m_k)}{\sum_{i=1}^N w_i(k, m_k)}$ et $w_i(k, m_k) = \frac{\pi(x^{(k)}|\theta_i^{(m_k)})}{\pi(x^{(m_k)}|\theta_i^{(m_k)})}$

$$\min_{m_k \in \{1, \dots, M\}} \left\{ \sum_{i=1}^N \tilde{w}_i(k, m_k) \ln w_i(k, m_k) - \frac{\ln \frac{1}{N} \sum_{i=1}^N w_i(k, m_k)}{\frac{1}{N} \sum_{i=1}^N w_i(k, m_k)} \right\}$$

2^{ème} stratégie : "Référence choisie" - critère 3

Critère 3 basé sur la minimisation de la variance de l'estimateur IS

⇒ en pratique (Robert 2007) pour garantir que

$$E_{[\theta|X^{(m_k)}]} \left[\left(g(\theta) \frac{\pi(\theta|X^{(k)})}{\pi(\theta|X^{(m_k)})} \right)^2 \right] \text{ soit finie}$$

$$\Rightarrow |g(\theta)| \frac{\pi(X^{(k)}|\theta)}{\pi(X^{(m_k)}|\theta)} \text{ "le plus stable"}$$

avec $u(\theta_i^{(m_k)}) = |g(\theta_i^{(m_k)})| \cdot \pi(X^{(k)}|\theta_i^{(m_k)}) / \pi(X^{(m_k)}|\theta_i^{(m_k)})$

$$\min_{m_k \in \{1, \dots, M\}} \left\{ \frac{\max_{i=1, \dots, N} u(\theta_i^{(m_k)}) - \min_{i=1, \dots, N} u(\theta_i^{(m_k)})}{\sum_{i=1}^N u(\theta_i^{(m_k)})} \right\}$$

3^{ème} stratégie : "Mélange de densités"

Mélange de densités *a posteriori* $\Rightarrow \pi_{mix}(\theta) = \frac{1}{10} \sum_{j=1}^{10} \pi(\theta|X^{(j)})$

- MCMC avec $X^{(1)}, \dots, X^{(10)}$ ($\leftarrow n=10N$ =nombre total d'itérations)
- Pour $k=11, \dots, 101$,
IS pour $X^{(k)}$ avec la même fonction d'importance π_{mix}

$$\frac{1}{n} \sum_{j=1}^{10} \sum_{i=1}^N g(\theta_i^{(j)}) \frac{\pi(\theta_i^{(j)}|X^{(k)})}{\pi_{mix}(\theta_i^{(j)})} \rightarrow E_{[\theta|X^{(k)}]} [g(\theta)]$$

avec $\{\theta_i^{(j)}\} \sim \pi(\theta|X^{(j)}), \quad j = 1, \dots, 10$

- Problème : $\pi(X^{(j)}) =$ constante de normalisation doit être connue sinon estimée (cf. Chen and Shao, 1997)

Modèles étudiés

- Modèle 1 (Modèle de Poisson) :

$$X_i | \lambda \sim \mathcal{P}(\lambda)$$

- Modèle 2 (Régression de Poisson) :

$$\begin{aligned} X_i | \lambda_i &\sim \mathcal{P}(\lambda_i) \\ \log(\lambda_i) &= a + bZ_i \\ Z_i &\sim \mathcal{N}(0, 1) \end{aligned}$$

- Modèle 3 (Régression de Poisson avec extravariabilité) :

$$\begin{aligned} X_i | \lambda_i &\sim \mathcal{P}(\lambda_i) \\ \log(\lambda_i) &= a + \sum_{j=1}^n b_j Z_{ij} + \epsilon_i \\ Z_{ij} &\sim \mathcal{N}(0, 1) \quad , \quad \epsilon_i \sim \mathcal{N}(0, \sigma_\epsilon^2) \end{aligned}$$

Résultats avec le modèle 1

Simulation

$$X_i | \lambda_0 \sim \mathcal{P}(\lambda_0) \quad \text{pour} \quad \lambda_0 = 1 \quad \text{ou} \quad \lambda_0 = 20$$

$$X = (X_1, \dots, X_N) \text{ pour } N = 20$$

\Rightarrow on réplique 101 fois : $X^{(1)}, \dots, X^{(101)}$

Estimation

$$X_i | \lambda \sim \mathcal{P}(\lambda), \quad \lambda \sim \mathcal{G}(\alpha, \beta) \quad \text{où} \quad \alpha = 0.01 \quad \text{et} \quad \beta = 0.01$$

\Rightarrow on estime 101 espérances

$$E_{[\theta | X^{(1)}]}(g(\theta)), \dots, E_{[\theta | X^{(101)}]}(g(\theta)) \text{ pour chaque fonction } g$$

Loi a posteriori connue

$$g(\sum_{i=1}^N X_i^{(k)} + \alpha, \beta + N) \quad \Rightarrow \quad E_{[\lambda | X^{(k)}]}[\lambda] = (\sum_{i=1}^N X_i^{(k)} + \alpha) / (\beta + N)$$


Stratégie		EQM ($\times 10^{05}$)
MCMC		9.1
Référence fixe	la pire	10823.4
Référence fixe	la meilleure réf. fixe	103.7
Référence choisie	critère 1 (norme L^1)	4.2
Référence choisie	critère 2 (Dv KL)	12.5
Référence choisie	critère 3 (Min var.)	4.5
Mélange [†]		4.0

[†] avec les constantes de normalisation estimées par « reverse logistic regression »

TABLE : Erreurs quadratiques moyennes entre estimation et vraie moyenne a posteriori dans le modèle de Poisson avec $\lambda = 20$.

Comparaison entre référence fixe et référence choisie

Modèle de régression de Poisson
avec extravariabilité ($\sigma_\epsilon^2 = 1/2$)



Stratégie	EQM* ($\times 10^{-03}$)
La meilleure réf. "fixe"	1.2
La pire réf. "fixe"	9.1
Réf. "choisie"	
avec le critère 1	2.1
avec le critère 2	3.1
avec le critère 3	2.0

* EQM de b entre estimation via IS et MCMC

Conclusion

- Pour les modèles étudiés, IS donne des bonnes performances
- Importance de choix de la référence
 - référence fixe
 - ⇒ danger d'un choix maladroit
 - référence choisie
 - ⇒ amélioration des résultats
 - stratégie du mélange
 - ⇒ bons résultats
 - ⇒ fonction d'importance identique (+)
 - ⇒ estimation des constantes de normalisation (-)

Merci pour votre attention !