

Méthodes de Monte Carlo – Projet

stoehr@ceremade.dauphine.fr

- **À rendre avant le 28 décembre 2020. Chaque jour de retard sera pénalisé d'un point.**
- **R est le seul langage autorisé.** Les questions nécessitant un code R sont indiquées par le symbole ♠.
- Le rapport (**nom du fichier : numero_groupe_rapport_noms**)
 - à rendre au format **.pdf** et doit contenir vos réponses et commentaires. Une rédaction soignée est attendue. Il est important de justifier/commenter les résultats théoriques et numériques
 - Pour intégrer tout ou partie de votre code et des sorties dans votre rapport, vous pouvez utiliser les outils dédiés : Notebook, Rmarkdown ou \LaTeX + knitr. En revanche, **il est interdit de copier-coller du code brut dans le corps du texte.**
 - Les graphiques doivent être soigneusement annotés et présentés (titre, couleur, légendes, ...).
- Une version du code pouvant être testée doit être fournie (**même nom de fichier**). Ce code doit
 - s'exécuter sans erreurs et permettre de reproduire l'intégralité des résultats présentés dans le rapport. Vous préciserez la graine utilisée pour les résultats obtenus.
 - être bien commenté. Il est possible qu'une explication orale vous soit demandée.
 - utiliser autant que possible les spécificités du langage (bonus pour les codes les plus efficaces).

Exercice 1. Soit f une densité de \mathbb{R}^2 définie pour $(x, y) \in \mathbb{R}^2$ par $f(x, y) = a\psi(x, y)$ avec $a \in \mathbb{R}_+^*$ et

$$\psi(x, y) = \left[\left| \sin\left(\frac{2}{\pi}x^2 - \frac{\pi}{4}\right) \right| + 4 \cos(x)^2 + y^4 \right] e^{-2(x+|y|)} \mathbb{1}_{\{x \in [-\pi/2, \pi/2]\}} \mathbb{1}_{\{y \in [-1, 1]\}}.$$

Pour (X, Y) de densité f , l'objectif est d'estimer f_X la densité marginale de X .

Contrainte. Les générateurs `runif` et `rexp` peuvent être utilisés directement. Les autres générateurs de variables aléatoires doivent être démontrés et codés en conséquence.

Simulation suivant la densité f

1. Montrer que pour simuler suivant f , il n'est pas nécessaire de connaître a et il suffit de trouver une constante $m \in \mathbb{R}_+^*$ et une densité g pour laquelle on dispose d'un générateur aléatoire telles que

$$\forall (x, y) \in \mathbb{R}^2, \quad \psi(x, y) \leq mg(x, y). \quad (1)$$

Trouver alors m et g qui satisfont (1).

Dans la suite, on désigne par ratio d'acceptation, la fonction définie pour $(x, y) \in \text{supp}(g)$ par

$$\rho(x, y) = \frac{\psi(x, y)}{mg(x, y)}.$$

2. (♠) Coder les fonctions `rgen_g(n)` qui simule n réalisations suivant la densité g et `rgen_f` qui retourne n réalisations suivant la densité f ainsi que toutes les valeurs du ratio d'acceptation utilisées pour obtenir ces réalisations.

3. (♠) Simuler un échantillon z de taille $n = 10000$ suivant f à l'aide de la fonction `rgen_f`. Auto-évaluer votre solution à l'aide du tableau suivant. n_t désigne le nombre moyen de simulations suivant g pour différents choix de g possibles. n_ℓ est le nombre moyen de passages dans une boucle `for` ou `while` pour le code utilisé pour générer les réalisations de f .

g	★		★★		★★★		★★★★		★★★★★	
Code	n_t	n_ℓ	n_t	n_ℓ	n_t	n_ℓ	n_t	n_ℓ	n_t	n_ℓ
★		527000		263000		84000		42000		36000
★★	527000	503	263000	248	84000	75	42000	36	36000	30
★★★		3		3		4		4		7

Méthode n°1 – Estimation de a

4. (a) Construire un estimateur de a en fonction de ρ , noté \hat{b}_n . Montrer qu'il est biaisé et converge presque sûrement. En déduire un intervalle de confiance asymptotique de a au niveau $1 - \alpha$ calculable en pratique.
- (b) (♠) À l'aide des variables aléatoires simulées question 3., évaluer \hat{b}_n et l'intervalle de confiance au niveau 95%.
- (c) (♠) Proposer une méthode d'estimation du biais ne nécessitant pas de simulations supplémentaires suivant f ou g .
5. (a) Montrer que l'algorithme de simulation suivant f fournit un autre estimateur de a , noté \hat{a}_n , qui converge presque sûrement mais qui est sans biais. En déduire un intervalle de confiance asymptotique de a au niveau $1 - \alpha$ calculable en pratique.
- (b) (♠) À l'aide de l'échantillon z , évaluer \hat{a}_n et l'intervalle de confiance au niveau 95%.
6. (♠) Exprimer le rapport des coûts pour lesquels \hat{b}_n et \hat{a}_n atteignent la même précision. Évaluer le à l'aide des résultats précédents. Quel est l'estimateur le plus efficace?
7. (a) Pour $x \in [-\pi/2, \pi/2]$ donner un estimateur $\hat{f}_{X,n}(x)$ de $f_X(x)$ à l'aide de \hat{a}_n .
- (b) (♠) Comparer graphiquement la distribution marginale de l'échantillon z à l'estimateur $\hat{f}_{X,n}(x)$.

Méthode n°2 – Estimateur ponctuel

8. Soient $(X_1, Y_1), \dots, (X_n, Y_n)$ une suite de variables indépendantes suivant la loi jointes $f(x, y)$ et $w(\cdot)$ une densité quelconque telle que $\text{supp}(w) \subseteq \text{supp}(f_X)$. Montrer que

$$\hat{w}_n(x) = \frac{1}{n} \sum_{k=1}^n \frac{\psi(x, Y_k) w(X_k)}{\psi(X_k, Y_k)} \xrightarrow[n \rightarrow +\infty]{p.s.} f_X(x).$$

En déduire un intervalle de confiance asymptotique de $f_X(x)$ au niveau $1 - \alpha$ calculable en pratique.

9. Pour quel choix de w obtient-on l'estimateur de variance minimale? Commenter ce résultat et expliquer comment l'utiliser en pratique.
10. (♠) À l'aide de l'échantillon z , évaluer $\hat{w}_n(-1)$ et l'intervalle de confiance au niveau 95%.
11. (♠) Exprimer le rapport des coûts pour lesquels $\hat{w}_n(-1)$ et $\hat{f}_{X,n}(-1)$ atteignent la même erreur quadratique moyenne. Évaluer le à l'aide des résultats précédents. Quel est l'estimateur le plus efficace?

Exercice 2. Soit $\mathbf{X} = (X_1, X_2, X_3)$ un vecteur aléatoire de \mathbb{R}^3 distribué suivant la loi $\mathcal{N}(\mu, \Sigma)$ avec

$$\mu = \begin{pmatrix} 0.1 \\ 0 \\ 0.1 \end{pmatrix} \quad \text{et} \quad \Sigma = \begin{pmatrix} 0.047 & 0 & 0.0117 \\ 0 & 0.047 & 0 \\ 0.0117 & 0 & 0.047 \end{pmatrix}.$$

On s'intéresse à

$$\delta = \mathbb{E} \left[\min \left(3, \frac{1}{3} \sum_{k=1}^3 e^{-X_k} \right) \right].$$

Contrainte. Le générateur `rmvnorm` peut être utilisé directement. Les autres générateurs de variables aléatoires doivent être codés en conséquence.

1. (♠) Écrire une fonction `rmvnorm(n, mu, sigma)` qui permet de générer n réalisation de la loi normale multivariée de moyenne `mu` et de matrice de variance-covariance `sigma`. Simuler à l'aide de cette fonction un échantillon \mathbf{x} de taille $n = 10000$ suivant la loi de \mathbf{X} .
2. (a) Étant donné une ensemble de variables aléatoires $\mathbf{X}_i = (X_{1,i}, X_{2,i}, X_{3,i})$, $i = 1, \dots, n$, *i.i.d.* suivant la loi de \mathbf{X} , donner l'expression de l'estimateur de Monte Carlo de δ , noté $\bar{\delta}_n$.
(b) (♠) Pour l'échantillon \mathbf{x} , évaluer $\bar{\delta}_n$ et l'erreur quadratique moyenne associée.
3. (a) Montrer qu'il existe une transformation mesurable A qui laisse la loi $\mathcal{N}(\mu, \Sigma)$ invariante et telle que pour l'estimateur de δ par la méthode de la variable antithétique, noté $\hat{\delta}_n$, $\text{Var}[\hat{\delta}_n] \leq \text{Var}[\bar{\delta}_n]/2$. Exprimer le facteur de réduction de variance théorique, noté R_1 , de $\hat{\delta}_n$ par rapport à $\bar{\delta}_n$.
(b) (♠) Pour l'échantillon \mathbf{x} , évaluer $\hat{\delta}_n$, l'erreur quadratique moyenne associée et R_1 . Qu'en concluez vous?
4. (a) (♠) En utilisant des moments d'ordre 1 et/ou d'ordre 2 associés à la loi de \mathbf{X} , trouver une fonction h_0 , telle que la corrélation entre $h_0(\mathbf{X})$ et $\min(3, \sum_{k=1}^3 e^{-X_k}/3)$ soit supérieure à 0.5. En déduire, pour $b \in \mathbb{R}$, l'expression de l'estimateur par la méthode de la variable de contrôle simple, noté $\hat{\delta}_n(b)$.
(b) (♠) Pour l'échantillon \mathbf{x} et une valeur de b judicieusement choisie, évaluer $\hat{\delta}_n(b)$ et l'erreur quadratique moyenne associée. Discuter le résultat obtenu en fonction du nombre global de simulations effectuées et du nombre de simulations utilisées pour le calcul de $\hat{\delta}_n(b)$.

Exercice 3. On suppose Y est distribué suivant la loi géométrique $\mathcal{G}(p)$, *i.e.*, pour $k \in \mathbb{N}^*$, $\mathbb{P}[Y = k] = p(1 - p)^{k-1}$. Pour $(X_n)_{n \geq 1}$ de variables aléatoires *i.i.d.* suivant la loi gamma $\Gamma(m, \theta)$, on s'intéresse à

$$\delta = \mathbb{E}[S], \quad \text{avec} \quad S = \sum_{i=1}^Y \log(X_i + 1).$$

On prendra $p = 0.2$, $m = 2$ et $\theta = 2$.

1. (♠) Pour $n = 10000$ tirages, donner une estimation de δ par la méthode de Monte Carlo classique et de l'erreur quadratique moyenne associée.
2. (a) Proposer un ensemble de strates D_1, \dots, D_L , $L \in \mathbb{N}^*$. En déduire un estimateur de δ par la méthode de stratification avec allocation proportionnelle (n_1, \dots, n_L) . On le notera $\hat{\delta}_n(n_1, \dots, n_L)$.

(b) (♣) Évaluer $\widehat{\delta}_n(n_1, \dots, n_L)$ pour $n = 10000$ tirages et $L = 15$ strates. Donner l'erreur quadratique moyenne associée. Quelle est l'efficacité relative $\widehat{\delta}_n(n_1, \dots, n_L)$ par rapport à la méthode de Monte Carlo classique? Discuter de façon concise les résultats obtenus.

Auto-évaluation du code. Évaluer votre code à l'aide des critères suivants :

- Nombre de déclarations du type « c() »

Code	Ex. n°1	Ex. n°2	Ex. n°3
★	≥ 3	≥ 1	≥ 1
★★	≤ 2		
★★★		0	0

- Nombre de boucles for ou while utilisées

Code	Ex. n°1	Ex. n°2	Ex. n°3
★	≥ 3	≥ 2	≥ 4
★★	2	1	≤ 3
★★★	1	0	0

- Nombre de boucles conditionnelles if utilisées

Code	Ex. n°1	Ex. n°2	Ex. n°3
★	≥ 1	≥ 1	≥ 1
★★	0	0	0
★★★			

- Nombre d'appel à Vectorize (sapply)

Code	Ex. n°1	Ex. n°2	Ex. n°3
★	≥ 1 (0 ou ≥ 2)	≥ 1 (≥ 1)	≥ 1 (0)
★★			0 (3)
★★★	0 (1)	0 (0)	0 (4)