

## Méthodes de Monte Carlo – Projet

stoehr@ceremade.dauphine.fr

- **À rendre avant 23 : 59, le 21 décembre 2022. Tout retard sera pénalisé : 1 point en moins toutes les 30 minutes à partir de 00 : 01.**
- **R est le seul langage autorisé.** Les questions nécessitant un code R sont indiquées par le symbole ♠. L'ensemble des générateurs aléatoires de la librairie de base de R sont autorisés.
- Le rapport (**nom du fichier : numero\_groupe\_noms, e.g., 001\_Stoehr\_Luciano**)
  - 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  $\text{\LaTeX}$ + knitr.
  - 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.** Soient  $X$  et  $Y$  deux variables aléatoires réelles indépendantes telles que

- $X$  suit la loi gamma de densité par rapport à la mesure de Lebesgue sur  $\mathbb{R}_+^*$

$$f(x) = \frac{1}{\Gamma(\alpha)\theta^\alpha} x^{\alpha-1} \exp\left(-\frac{x}{\theta}\right), \quad \text{avec } \alpha = 3 \text{ et } \theta = 2.$$

- $Y$  suit la loi de densité par rapport à la mesure de Lebesgue sur  $\mathbb{R}$

$$g(y) = \frac{y - \mu + 2b}{4b^2} \mathbb{1}_{\{y \in [\mu - 2b, \mu]\}} + \frac{1}{2b} \exp\left(-\frac{y - \mu}{b}\right) \mathbb{1}_{\{y > \mu\}}, \quad \text{avec } \mu = -13 \text{ et } b = 2.$$

L'objectif de cet exercice est d'estimer

$$\delta = \mathbb{P}[X + Y > t], \quad \text{avec } t = 0.$$

### Méthode Monte Carlo n°1.

1. (♠) Décrire une méthode pour simuler suivant la loi de  $(X, Y)$  et écrire le code R associé. Vous préciserez les différents calculs effectués.
2. (♠) Vérifier graphiquement que votre méthode et votre code sont corrects.
3. Écrire l'estimateur Monte Carlo  $\hat{p}_n$  de  $\delta$  utilisant une suite de  $n$  variables aléatoires  $(X_k, Y_k)_{k \geq 1}$  *i.i.d.* suivant la loi de  $(X, Y)$ .

4. (♠) Implémenter un code R qui fournit, pour  $n = 1000$ , une estimation de  $\delta$ , de l'erreur quadratique moyenne de  $\hat{p}_n$  et un intervalle de confiance asymptotique bilatère pour  $\delta$  au niveau 95%.
5. (♠) Vérifier empiriquement si l'hypothèse du régime asymptotique  $\hat{p}_n$  est satisfaite.
6. On note  $F$  la fonction de répartition de  $X$ . Montrer que

$$\delta = \mathbb{E}[1 - F(t - Y)],$$

et en déduire un estimateur  $\hat{\delta}_n$  de  $\delta$  utilisant une suite de  $n$  variables aléatoires  $(U_k)_{k \geq 1}$  *i.i.d.* suivant la loi uniforme sur  $[0, 1]$ .

7. (♠) Implémenter un code R qui fournit, pour  $n = 1000$ , l'estimation  $\hat{\delta}_n$ , l'erreur quadratique moyenne de  $\hat{\delta}_n$  et un intervalle de confiance asymptotique bilatère pour  $\delta$  au niveau 95%.
8. Selon ces résultats, l'estimateur  $\hat{\delta}_n$  est-il plus performant en terme de variance que l'estimateur  $\hat{p}_n$ ? Si oui, montrer qu'on a toujours  $\text{Var}[\hat{\delta}_n] \leq \text{Var}[\hat{p}_n]$ .

### Méthode Monte Carlo n°2.

9. En utilisant la méthode de la variable antithétique, proposer un estimateur  $\hat{\delta}_n^A$  de  $\delta$ . Montrer que  $\text{Var}[\hat{\delta}_n^A] \leq \text{Var}[\hat{\delta}_n]$ .
10. (♠) Implémenter un code R qui fournit, pour  $n = 1000$ , l'estimation  $\hat{\delta}_n^A$ , l'erreur quadratique moyenne de  $\hat{\delta}_n^A$  et un intervalle de confiance asymptotique bilatère pour  $\delta$  au niveau 95%.

**Méthode Monte Carlo n°3.** On note  $q_\varepsilon$  le quantile d'ordre  $\varepsilon$  de la loi de  $X$  et on définit les fonctions :

$$h_{0,1} : \mathbb{R} \rightarrow \mathbb{R} \quad \text{et} \quad h_{0,2} : \mathbb{R} \rightarrow \mathbb{R}$$

$$y \mapsto y \quad \quad \quad y \mapsto \mathbb{1}_{\{y \geq t - q_\varepsilon\}}.$$

Dans la suite on prend  $\varepsilon = 0.6$ .

11. (♠) Entre  $h_{0,1}$  et  $h_{0,2}$ , quelle fonction utiliseriez-vous pour réduire la variance de  $\hat{\delta}_n$  à l'aide de la méthode de la variable de contrôle? Écrire l'estimateur  $\hat{\delta}_n^{\text{cont}}$  associé.
12. (♠) Implémenter un code R qui fournit, pour  $n = 1000$ , l'estimation  $\hat{\delta}_n^{\text{cont}}$ , l'erreur quadratique moyenne de  $\hat{\delta}_n^{\text{cont}}$  et un intervalle de confiance asymptotique bilatère pour  $\delta$  au niveau 95%.

Pour  $(Y_k)_{k \geq 1}$ , une suite de variables aléatoires *i.i.d.* suivant  $g$ , on veut construire le meilleur estimateur de la forme

$$\hat{\delta}_n(\beta) = 1 - \frac{1}{n} \sum_{k=1}^n F(t - Y_k) - \langle \beta, \begin{pmatrix} Y_k - \mathbb{E}[Y] \\ \mathbb{1}_{\{Y_k \geq t - q_\varepsilon\}} - \mathbb{P}[Y \geq t - q_\varepsilon] \end{pmatrix} \rangle, \quad \text{avec} \quad \beta = \begin{pmatrix} \beta_1 \\ \beta_2 \end{pmatrix} \in \mathbb{R}^2.$$

$\langle \cdot, \cdot \rangle$  désigne le produit scalaire usuel de  $\mathbb{R}^2$ , *i.e.*,  $\langle U, V \rangle = U^T V$ .

13. Montrer que

$$\text{Var}[\hat{\delta}_n(\beta)] = \text{Var}[\hat{\delta}_n] - \frac{1}{n} (2 \langle \beta, C \rangle - \langle \beta, \Sigma \beta \rangle), \quad \text{avec}$$

$$C = \begin{pmatrix} \text{Cov}[F(t - Y), Y] \\ \text{Cov}[F(t - Y), \mathbb{1}_{\{Y \geq t - q_\varepsilon\}}] \end{pmatrix} \quad \text{et} \quad \Sigma = \begin{pmatrix} \text{Var}[Y] & \text{Cov}[Y, \mathbb{1}_{\{Y \geq t - q_\varepsilon\}}] \\ \text{Cov}[Y, \mathbb{1}_{\{Y \geq t - q_\varepsilon\}}] & \text{Var}[\mathbb{1}_{\{Y \geq t - q_\varepsilon\}}] \end{pmatrix}.$$

14. Calculer explicitement  $\Sigma$  et vérifier qu'elle est inversible.

15. Montrer que

$$\beta^* = \underset{\beta \in \mathbb{R}^2}{\operatorname{argmin}} \operatorname{Var}[\widehat{\delta}_n(\beta)] = \Sigma^{-1}C \quad \text{et} \quad \operatorname{Var}[\widehat{\delta}_n(\beta^*)] \leq \operatorname{Var}[\widehat{\delta}_n].$$

16. L'estimateur  $\widehat{\delta}_n(\beta^*)$  est-il préférable en terme de variance à un estimateur basé sur la méthode de la variable de contrôle utilisant  $h_0 : y \mapsto h_{0,1}(y) + h_{0,2}(y)$ ? Justifier rigoureusement votre réponse.

17. (♠) Implémenter un code R qui fournit, pour  $n = 1000$ , l'estimation  $\widehat{\delta}_n(\beta^*)$ , l'erreur quadratique moyenne de  $\widehat{\delta}_n(\beta^*)$  et un intervalle de confiance asymptotique bilatère pour  $\delta$  au niveau 95%.

#### Méthode Monte Carlo n°4.

18. Soit  $h \in L^2([0, 1])$ . Montrer que pour une suite  $(U_k)_{k \geq 1}$  de variables aléatoires *i.i.d.* de loi uniforme sur  $[0, 1]$ , on a

$$\operatorname{Var} \left[ \frac{1}{n} \sum_{k=1}^n h \left( \frac{k-1+U_k}{n} \right) \right] \leq \operatorname{Var} \left[ \frac{1}{n} \sum_{k=1}^n h(U_k) \right].$$

19. En déduire un nouvel estimateur  $\widehat{\Delta}_n$  de  $\delta$ . Comment peut-on interpréter cet estimateur?

20. (♠) Implémenter un code R qui fournit, pour  $n = 1000$ , l'estimation  $\widehat{\Delta}_n$ , l'erreur quadratique moyenne de  $\widehat{\Delta}_n$  et un intervalle de confiance asymptotique bilatère pour  $\delta$  au niveau 95%.

21. (♠) Comparer l'efficacité relative des différents estimateurs de  $\delta$  que vous avez proposés.

**Exercice 2 (Bonus).** Soient  $m \in \mathbb{N}^*$  et  $k \in \llbracket 2, m-1 \rrbracket$ . Avec la densité  $g$  définie à l'Exercice 1 et  $G$  la fonction de répartition associée à  $g$ , on définit

$$\Psi(x) = \frac{m!}{(k-1)!(m-k)!} G(x)^{k-1} [1-G(x)]^{m-k} g(x).$$

1. (♠) Implémenter un algorithme du rejet qui simule  $n$  réalisations suivant la densité  $\Psi$ .

2. (♠) Vérifier graphiquement que votre code est valide pour  $m = 15$  et  $k = 7$ .