

Simulation stochastique et Méthode de Monte Carlo.

Pierre Del Moral – Caroline Hillairet – Benjamin Jourdain

Map 564 - PC 1 - 6 Janvier 2012

EXERCICE 1 - : vitesse de convergence de la moyenne empirique

Soit $(Z_j)_{j \geq 1}$ une suite de variables aléatoires i.i.d. suivant la loi de Pareto symétrique de paramètre $\alpha > 0$ de densité $\frac{\alpha}{2|z|^{\alpha+1}} \mathbf{1}_{\{|z| \geq 1\}}$.

1. Lorsque $\alpha > 1$, que peut-on dire de la suite $\bar{Z}_n = \frac{1}{n} \sum_{j=1}^n Z_j$ lorsque $n \rightarrow +\infty$?
2. Dans le cas où $\alpha > 2$, montrer que $\sqrt{n} \bar{Z}_n$ converge en loi vers une limite à préciser.
3. Vérifier que la fonction caractéristique Φ commune aux Z_j est telle que

$$\Phi(u) - 1 = \alpha |u|^\alpha \int_{|u|}^{+\infty} \frac{\cos(t) - 1}{t^{\alpha+1}} dt$$

4. Dans le cas où $0 < \alpha < 2$, donner un équivalent de $\Phi(u) - 1$ pour u au voisinage de 0. En déduire que $n^{\frac{\alpha-1}{\alpha}} \bar{Z}_n$ converge en loi. À quelle vitesse la moyenne empirique \bar{Z}_n converge-t-elle vers 0 lorsque $1 < \alpha < 2$.
5. Dans le cas où $\alpha = 2$, montrer que $\Phi(u) - 1 - u^2 \ln |u| \sim_{u \rightarrow 0} C u^2$. En déduire que $\sqrt{\frac{n}{\ln n}} \bar{Z}_n$ converge en loi vers une limite à préciser. On se place dans le cas $\alpha = 1$ et on pose $\zeta_j = |Z_j|$ et $\bar{\zeta}_n = \frac{1}{n} \sum_{j=1}^n \zeta_j$.

(a) Vérifier que pour $n \geq 2$, $\mathbb{E} \left(\frac{1}{n \ln n} \sum_{j=1}^n \zeta_j \mathbf{1}_{\{\zeta_j \leq n \ln n\}} \right) = 1 + \frac{\ln \ln n}{\ln n}$.

(b) Calculer $\mathbb{E} \left(\zeta_1^2 \mathbf{1}_{\{\zeta_1 \leq n \ln n\}} \right)$ et vérifier que $\text{Var} \left(\frac{1}{n \ln n} \sum_{j=1}^n \zeta_j \mathbf{1}_{\{\zeta_j \leq n \ln n\}} \right) \leq \frac{1}{\ln n}$. En déduire que $\frac{1}{n \ln n} \sum_{j=1}^n \zeta_j \mathbf{1}_{\{\zeta_j \leq n \ln n\}}$ converge dans L^2 vers 1.

(c) Vérifier que $\mathbb{P}(\zeta_1 > n \ln n) = \frac{1}{n \ln n}$ et conclure que $\frac{\bar{\zeta}_n}{\ln n}$ converge en probabilité vers 1.

EXERCICE 2 - Approximation de quantiles par méthode de Monte Carlo.

Soit X une variable aléatoire réelle à densité continue strictement positive partout. Pour tout $0 < a < 1$ on note $\rho(a)$ son quantile d'ordre a : $F(\rho(a)) = a$, où F est la fonction de répartition de X .

On considère N réalisations indépendantes de la loi de X et on les range par ordre croissant :

$$X_1 \leq X_2 \leq \dots \leq X_N.$$

On suppose que le nombre Na est non entier. On note μ la partie entière de Na et $\rho_N(a) := X_{\mu+1}$.

1. Pour tout x dans \mathbb{R} et ϵ tendant vers 0 calculer $\mathbb{P}(\rho_N(a) \in [x, x + \epsilon])$. En déduire que la loi de $\rho_N(a)$ a pour densité

$$g_N(x) = C_N^\mu (N - \mu) (F(x))^\mu (1 - F(x))^{N-\mu-1} F'(x).$$

2. On pose

$$Y := \frac{\sqrt{N}}{\sqrt{a(1-a)}} F'(\rho(a)) (\rho_N(a) - \rho(a)).$$

Montrer que la densité q_N de Y est

$$q_N(x) := \frac{\sqrt{a(1-a)}}{\sqrt{N}} \frac{1}{F'(\rho(a))} g_N(\rho(a)) + \frac{\sqrt{a(1-a)}}{\sqrt{N}} \frac{x}{F'(\rho(a))}.$$

3. On rappelle :

$$\lim_{N \rightarrow +\infty} \frac{\sqrt{a(1-a)}}{\sqrt{N}} C_N^\mu a^\mu (1-a)^{N-\mu} \frac{N-\mu}{1-a} = \frac{1}{\sqrt{2\pi}}.$$

Montrer que, quand N tend vers l'infini, la loi de $\rho_N(a)$ est proche d'une gaussienne centrée en $\rho(a)$ et d'écart type

$$\frac{\sqrt{a(1-a)}}{\sqrt{N}} \frac{1}{F'(\rho(a))}.$$

Qu'en concluez vous pour l'approximation de quantiles par méthode de Monte-Carlo ?

EXERCICE 3 - : stratification

On veut calculer $\mathbb{E}(f(X))$ où X est un vecteur aléatoire à valeurs dans \mathbb{R}^d et $f : \mathbb{R}^d \rightarrow \mathbb{R}$ est une fonction telle que $f(X)$ est de carré intégrable. On suppose qu'il existe une partition D_1, \dots, D_I de \mathbb{R}^d telle que pour tout $i \in \{1, \dots, I\}$, $p_i = \mathbb{P}(X \in D_i)$ est strictement positif et connu et on sait simuler des variables aléatoires $(X_k^i)_{k \geq 1}$ suivant la loi conditionnelle de X sachant $X \in D_i$ avec les variables $(X_k^i)_{1 \leq i \leq I, k \geq 1}$ indépendantes.

1. Pour $(n_1, \dots, n_I) \in \mathbb{N}^{*I}$, on pose $Y_{n_1, \dots, n_I} = \sum_{i=1}^I \frac{p_i}{n_i} \sum_{k=1}^{n_i} f(X_k^i)$. Calculer $\mathbb{E}(Y_{n_1, \dots, n_I})$. Quel est le comportement de Y_{n_1, \dots, n_I} lorsque $\min_{1 \leq i \leq I} n_i \rightarrow +\infty$?
2. On note $\sigma_i^2 = \text{Var}(f(X_1^i))$. Montrer que $\text{Var}(Y_{n_1, \dots, n_I}) = \frac{1}{\sum_{i=1}^I n_i} v\left(\frac{n_1}{\sum_{i=1}^I n_i}, \dots, \frac{n_I}{\sum_{i=1}^I n_i}\right)$ où $v(q_1, \dots, q_I) = \sum_{i=1}^I \frac{(p_i \sigma_i)^2}{q_i}$.
3. Montrer que $\forall q = (q_1, \dots, q_I)$ probabilité sur $\{1, \dots, I\}$, $v(q) \geq \left(\sum_{i=1}^I p_i \sigma_i\right)^2$ où le minimum est atteint pour $q^* = \left(\frac{p_1 \sigma_1}{\sum_{i=1}^I p_i \sigma_i}, \dots, \frac{p_I \sigma_I}{\sum_{i=1}^I p_i \sigma_i}\right)$. Pourquoi la clé de répartition optimale q^* des tirages dans les strates est-elle en général inconnue ?
En remarquant que $\sigma_i^2 = \mathbb{E}(f^2(X)|X \in D_i) - (\mathbb{E}(f(X)|X \in D_i))^2$, vérifier que $v(p_1, \dots, p_I) \leq \text{Var}(f(X))$ et interpréter ce résultat.

On suppose désormais que $X \sim \mathcal{N}_d(0, I_d)$ et que $D_i = \{y_{i-1} \leq u.X \leq y_i\}$ où $-\infty = y_0 < y_1 < \dots < y_{I-1} < y_I = +\infty$ et $u \in \mathbb{R}^d$ est tel que $|u| = 1$. On note $N(y) = \int_{-\infty}^y e^{-\frac{z^2}{2}} \frac{dz}{\sqrt{2\pi}}$.

1. Quelle est la loi de $u.X$? Exprimer p_i à l'aide de la fonction N .
2. Montrer que $u.X$ et $X - (u.X)u$ sont indépendants.
3. Soit U une variable aléatoire uniforme sur $[0, 1]$ indépendante de X . Vérifier que $Z_i = N^{-1}[N(y_{i-1})(1-U) + N(y_i)U]$ suit la loi conditionnelle de $u.X$ sachant $X \in D_i$. Conclure que $X + (Z_i - u.X)u$ suit la loi conditionnelle de X sachant $X \in D_i$.

EXERCICE 4 - : Inégalité de Hoeffding et concentration

1. Sur $(\Omega, \mathcal{F}, \mathbb{P})$, soit X une variable aléatoire réelle à valeurs dans $[a, b]$ avec $-\infty < a < b < +\infty$. Pour $t \in \mathbb{R}$, on note \mathbb{P}_t la probabilité de densité $\frac{d\mathbb{P}_t}{d\mathbb{P}} = \frac{e^{tX}}{\mathbb{E}(e^{tX})}$ et \mathbb{E}_t l'espérance correspondantes.
 - (a) Que vaut $\sup_{x \in [a, b]} (x - \frac{a+b}{2})^2$?
En déduire que $\forall t \in \mathbb{R}$, $\mathbb{E}_t((X - \mathbb{E}_t(X))^2) \leq \frac{(b-a)^2}{4}$.
 - (b) Soit $f(t) = \ln(\mathbb{E}(e^{t(X - \mathbb{E}(X))}))$. Calculer $f''(t)$ et en déduire que

$$\forall t \in \mathbb{R}, \mathbb{E}(e^{t(X - \mathbb{E}(X))}) \leq e^{\frac{(b-a)^2 t^2}{8}}.$$

- (c) Dans le cas où $\mathbb{P}(X = 1) = \mathbb{P}(X = -1) = \frac{1}{2}$, calculer $\lim_{t \rightarrow 0} \frac{1}{t^2} (\mathbb{E}(e^{tX}) - 1)$ et en déduire que la constante $\frac{1}{8}$ dans l'inégalité précédente est optimale.
2. On suppose que les $(X_i)_{1 \leq i \leq n}$ sont des variables aléatoires indépendantes à valeurs respectives dans $[a_i, b_i]$ avec $-\infty < a_i < b_i < +\infty$. Soit $\varphi : \mathbb{R} \rightarrow \mathbb{R}$ une fonction lipschitzienne de constante de Lipschitz C .

(a) Montrer que

$$\forall r > 0, \mathbb{P} \left(\sum_{i=1}^n (\varphi(X_i) - \mathbb{E}(\varphi(X_i))) \geq r \right) \leq e^{-\frac{2r^2}{C^2 \sum_{i=1}^n (b_i - a_i)^2}}.$$

(b) Dans le cas où les X_i sont i.i.d. suivant la loi de X , conclure que

$$\forall \varepsilon > 0, \mathbb{P} \left(\left| \frac{1}{n} \sum_{i=1}^n \varphi(X_i) - \mathbb{E}(\varphi(X)) \right| \geq \varepsilon \right) \leq 2e^{-\frac{2n\varepsilon^2}{C^2(b-a)^2}}.$$

Quel est l'intérêt de cet intervalle de confiance par rapport à celui obtenu avec l'inégalité de Bienaimé-Chebychev ? et celui obtenu par le théorème de la limite centrale ?

3. On suppose maintenant que $(M_k)_{0 \leq k \leq n}$ est une \mathcal{F}_k -martingale t.q. M_0 est constante égale à m et pour tout $k \in \{1, \dots, n\}$, l'accroissement $M_k - M_{k-1}$ prend ses valeurs dans un intervalle borné $[a_k, b_k]$.

(a) Soit $k \in \{1, \dots, n\}$ et $A \in \mathcal{F}_{k-1}$ tel que $\mathbb{P}(A) > 0$. En étudiant $f(t) \stackrel{\text{def}}{=} \ln(\mathbb{E}(e^{t(M_k - M_{k-1})} 1_A))$ montrer que $\mathbb{E}(e^{t(M_k - M_{k-1})} 1_A) \leq e^{\frac{(b_k - a_k)^2 t^2}{8}} \times \mathbb{P}(A)$ pour tout $t \in \mathbb{R}$. En déduire que $\mathbb{P} \left(\mathbb{E}(e^{t(M_k - M_{k-1})} | \mathcal{F}_{k-1}) \leq e^{\frac{(b_k - a_k)^2 t^2}{8}} \right) = 1$.

(b) Montrer que $\mathbb{E}(e^{t(M_n - m)}) \leq e^{\frac{t^2 \sum_{k=1}^n (b_k - a_k)^2}{8}}$. Comparer avec l'inégalité obtenue en appliquant directement le résultat de la question 1b à la variable aléatoire $M_n - m$.

(c) En déduire que pour $r > 0$, $\mathbb{P}(|M_n - m| \geq r) \leq 2e^{-\frac{2r^2}{\sum_{k=1}^n (b_k - a_k)^2}}$