

Examen

1. Échauffement

Les questions de cet exercice sont complètement indépendantes.

- (1) Montrer que si X est une variable aléatoire réelle positive avec $\mathbf{E}X^2 < \infty$, alors pour tout $\lambda \geq 0$,

$$\log \mathbf{E}e^{-\lambda(X-\mathbf{E}X)} \leq \frac{\lambda^2 \mathbf{E}X^2}{2},$$

et en déduire que pour tout $t \geq 0$, $\mathbf{P}(X - \mathbf{E}X \leq -t) \leq e^{-\frac{t^2}{2\mathbf{E}X^2}}$.

- (2) Soient X_1, \dots, X_n des variables aléatoires réelles indépendantes symétriques (i.e. X_i et $-X_i$ ont la même loi, ou encore $X_i = \varepsilon_i |X_i|$ avec $\varepsilon_i = \text{signe}(X_i)$ valant $+1$ ou -1 avec probabilité $1/2$ et ε_i indépendante de $|X_i|$). On suppose de plus que pour tout $i = 1, \dots, n$, $\mathbf{P}(X_i = 0) = 0$. Montrer que pour tout $t \geq 0$,

$$\mathbf{P}\left(\frac{X_1 + \dots + X_n}{\sqrt{X_1^2 + \dots + X_n^2}} \geq t\right) \leq \exp\left\{-\frac{t^2}{2}\right\}.$$

- (3) On effectue des tirages indépendants X_1, X_2, \dots uniformément distribués dans $\{1, \dots, n\}$. On s'intéresse à la variable T_n égale au premier temps où tous les éléments ont été tirés au moins une fois, soit

$$T_n = \inf\{t \geq 1, \{X_1, \dots, X_t\} = \{1, \dots, n\}\}.$$

- (a) Écrire T_n comme une somme de variables aléatoires géométriques indépendantes dont on précisera les paramètres.
 (b) Donner un équivalent asymptotique (quand $n \rightarrow +\infty$) de l'espérance et de la variance de T_n .
 (c) Soit $X \sim \text{Geom}(p)$, pour $p \in]0, 1[$. Montrer que pour tout $\lambda < \log\left(\frac{1}{1-p}\right)$,

$$\log \mathbf{E}e^{\lambda(X-\mathbf{E}X)} = \log\left(\frac{p}{e^{-\lambda} - 1 + p}\right) - \frac{\lambda}{p},$$

et en déduire que X est sous-Gamma à droite avec facteur variance $\frac{1}{p^2}$ et facteur d'échelle $\frac{1}{p}$ (on pourra utiliser $e^{-\lambda} \geq 1 - \lambda$, et que pour tout $u \in [0, 1[$, $-u - \log(1-u) \leq \frac{u^2}{2(1-u)}$), et sous-gaussienne à gauche avec facteur d'échelle $\frac{1}{p^2}$.

- (d) Montrer que pour tout $\lambda \in [0, 1/n[$,

$$\log \mathbf{E}e^{\lambda(T_n - \mathbf{E}T_n)} \leq \frac{\pi^2 n^2 \lambda^2}{12(1 - n\lambda)},$$

et que pour tout $\lambda \leq 0$,

$$\log \mathbf{E}e^{\lambda(T_n - \mathbf{E}T_n)} \leq \frac{\pi^2 n^2 \lambda^2}{12}.$$

2. Estimateur à noyau

Soient X_1, \dots, X_n des variables aléatoires réelles indépendantes, de densité φ par rapport à la mesure de Lebesgue. Pour $x \in \mathbb{R}$, l'estimateur à noyau de $\varphi(x)$ est défini comme

$$\varphi_n(x, X_1, \dots, X_n) = \frac{1}{nh_n} \sum_{i=1}^n K\left(\frac{x - X_i}{h_n}\right),$$

avec $h_n > 0$ et K une fonction positive telle que $\int_{\mathbb{R}} K(u)du = 1$. On s'intéresse à l'erreur L^1 :

$$Z = f(X_1, \dots, X_n) = \int_{\mathbb{R}} |\varphi_n(x, X_1, \dots, X_n) - \varphi(x)| dx.$$

(1) Montrer que pour tous $x_1, \dots, x_i, x'_i, \dots, x_n$, on a

$$|f(x_1, \dots, x_{i-1}, x_i, x_{i+1}, \dots, x_n) - f(x_1, \dots, x_{i-1}, x'_i, x_{i+1}, \dots, x_n)| \leq \frac{2}{n}.$$

(2) En déduire que $\mathbf{Var}(Z) \leq \frac{1}{n}$ et que pour tout $t \geq 0$,

$$\mathbf{P}(Z - \mathbf{E}Z \geq t) \leq \exp\left\{-\frac{nt^2}{2}\right\}.$$

3. Moyenne de Rademacher conditionnelle

Soient X_1, \dots, X_n des variables aléatoires indépendantes à valeurs dans la sphère $\mathbb{S}^{d-1} = \{x \in \mathbb{R}^d, \|x\| \leq 1\}$ (où $\|\cdot\|$ est la norme euclidienne), et $\varepsilon_1, \dots, \varepsilon_n$ des variables aléatoires i.i.d. de loi de Rademacher (i.e. égales à -1 ou 1 avec probabilité $1/2$), indépendantes de (X_1, \dots, X_n) . On s'intéresse à la variable

$$Z = \mathbf{E} \left[\left\| \sum_{i=1}^n \varepsilon_i X_i \right\| \mid X_1, \dots, X_n \right].$$

On écrit $Z = f(X_1, \dots, X_n)$ avec, pour $x_1, \dots, x_n \in \mathbb{S}^{d-1}$, $f(x_1, \dots, x_n) = \mathbf{E} [\|\sum_{i=1}^n \varepsilon_i x_i\|]$.

(1) Montrer que la fonction f est auto-bornée. On pourra considérer les fonctions f_i données par

$$f_i(x_1, \dots, x_{i-1}, x_{i+1}, \dots, x_n) = \mathbf{E} \left[\left\| \sum_{\substack{j=1 \\ j \neq i}}^n \varepsilon_j x_j \right\| \right],$$

et utiliser le fait que pour $y \in \mathbb{R}^d$, $\|y\| = \sup_{\alpha \in \mathbb{R}^d, \|\alpha\| \leq 1} \langle \alpha, y \rangle$.

(2) En déduire que pour tout $t \geq 0$,

$$\mathbf{P}(Z - \mathbf{E}Z \geq t) \leq \exp\left\{-\frac{t^2}{2(\mathbf{E}Z + \frac{t}{3})}\right\} \quad \text{et} \quad \mathbf{P}(Z - \mathbf{E}Z \leq -t) \leq \exp\left\{-\frac{t^2}{2\mathbf{E}Z}\right\}.$$

4. Une amélioration de l'inégalité de McDiarmid

Soit $f : \mathcal{X}^n \rightarrow \mathbb{R}$ une fonction mesurable et $Z = f(X_1, \dots, X_n)$ avec X_1, \dots, X_n des variables aléatoires indépendantes à valeurs dans \mathcal{X} .

(1) En utilisant la sous-additivité de l'entropie, montrer que pour tout $\lambda \in \mathbb{R}$,

$$\mathbf{Ent} \left[e^{\lambda Z} \right] \leq \sum_{i=1}^n \mathbf{E} \left[e^{\lambda Z} \phi(-\lambda(Z - Z'_i)) \right],$$

avec $Z'_i = f(X_1, \dots, X_{i-1}, X'_i, X_{i+1}, \dots, X_n)$ où X'_i est une copie indépendante de X_i , et $\phi(z) = e^z - z - 1$.

(2) En écrivant $Z - Z'_i = (Z - Z'_i)_+ - (Z'_i - Z)_+$ et le fait que Z et Z'_i sont échangeables, montrer que pour tout $\lambda \in \mathbb{R}$,

$$\mathbf{E} \left[e^{\lambda Z} \phi(-\lambda(Z - Z'_i)) \right] = \mathbf{E} \left[e^{\lambda Z} \tau(-\lambda(Z - Z'_i)_+) \right],$$

où $\tau(z) = z(e^z - 1)$.

(3) En déduire que pour tout $\lambda \geq 0$, $\mathbf{Ent} [e^{\lambda Z}] \leq \sum_{i=1}^n \mathbf{E} [\lambda^2 e^{\lambda Z} (Z - Z'_i)_+^2]$.

(4) Montrer que s'il existe $v > 0$ tel que

$$\mathbf{E} \left[\sum_{i=1}^n (Z - Z'_i)_+^2 \mid X_1, \dots, X_n \right] \leq v,$$

alors pour tout $t \geq 0$, $\mathbf{P}(Z - \mathbf{E}Z \geq t) \leq \exp\left\{-\frac{t^2}{4v}\right\}$.