

DM 1

Exercice 1 Réordonnement

1. (a) p.s., $Y_k^{(n)} \leq x \iff \#\{i \in \llbracket 1; n \rrbracket : X_i \leq x\} \geq k \iff \sum_{i=1}^n \mathbf{1}_{\{X_i \leq x\}} \geq k$.
- (b) Remarquons que pour tout $x \in \mathbb{R}$, les variables aléatoires $(\mathbf{1}_{\{X_i \leq x\}})_i$ sont des variables aléatoires i.i.d. \mathcal{L}^1 de loi de Bernoulli de paramètre $\mathbb{P}(X_i \leq x) = F_X(x)$. D'où d'après la loi forte des grands nombres,

$$\frac{1}{n} \sum_{i=1}^n \mathbf{1}_{\{X_i \leq x\}} \xrightarrow{n \rightarrow \infty} F_X(x) \quad \text{p.s.}$$

Soit $t \in]0; 1[$, soit $\varepsilon > 0$,

$$\frac{1}{n} \sum_{i=1}^n \mathbf{1}_{\{X_i \leq G_X(t) + \varepsilon\}} \xrightarrow{n \rightarrow \infty} F_X(G_X(t) + \varepsilon) = F_X(\inf\{x : F_X(x) \geq t\} + \varepsilon) > t \quad \text{p.s.}$$

l'inégalité stricte venant de la stricte croissance de F_X sur \mathbb{R} , et de la continuité à droite de F_X . Ainsi presque sûrement pour n assez grand, on a $\sum_{i=1}^n \mathbf{1}_{\{X_i \leq G_X(t) + \varepsilon\}} > tn$, et la somme étant entière ceci implique p.s. pour n assez grand, $\sum_{i=1}^n \mathbf{1}_{\{X_i \leq G_X(t) - \varepsilon\}} \geq [tn]$. D'après la question (a), p.s. pour n assez grand on a $Y_{[tn]}^{(n)} \leq G_X(t) + \varepsilon$, et donc p.s. $\limsup_n Y_{[tn]}^{(n)} \leq G_X(t) + \varepsilon$. Le réel ε étant arbitraire, et en considérant une suite dénombrable de ε tendant vers 0, on obtient

$$\limsup_{n \rightarrow \infty} Y_{[tn]}^{(n)} \leq G_X(t) \quad \text{p.s.}$$

En considérant $\frac{1}{n} \sum_{i=1}^n \mathbf{1}_{\{X_i \leq G_X(t) - \varepsilon\}}$, on montre par le même raisonnement que $\liminf_n Y_{[tn]}^{(n)} \geq G_X(t)$ p.s. d'où la conclusion de la question.

Si $t = 0$ ou $t = 1$, il suffit de remarquer que de toute façon p.s., pour tout $k \in \llbracket 1; n \rrbracket$ on a $Y_k^{(n)} \geq G_X(0)$ et $Y_k^{(n)} \leq G_X(1)$ et d'utiliser l'une ou l'autre des conclusions précédentes sur la limsup ou la liminf de la suite.

2. (a) On a en utilisant la borne d'union puis le théorème de transfert (la loi jointe de (X_i, X_j) étant $\text{Leb}_{[0,1]} \otimes \text{Leb}_{[0,1]}$)

$$\begin{aligned} \mathbb{P}(\exists i, j \in \llbracket 1; n \rrbracket : Y_i^{(n)} = Y_j^{(n)}) &= \mathbb{P}\left(\bigcup_{1 \leq i < j \leq n} \{X_i = X_j\}\right) \\ &\leq \sum_{1 \leq i < j \leq n} \mathbb{P}(X_i = X_j) = \frac{n(n-1)}{2} \int_{\mathbb{R}^2} \mathbf{1}_{\{x=y\}} dx dy = 0, \end{aligned}$$

le borélien $\{(x, y) \in \mathbb{R}^2 : x = y\}$ étant de mesure nulle.

- (b) On a

$$\begin{aligned} \mathbb{P}((Y_1^{(n)}, \dots, Y_n^{(n)}) = (X_{\sigma(1)}, \dots, X_{\sigma(n)})) \\ = \mathbb{P}(X_{\sigma(1)} < \dots < X_{\sigma(n)}) = \int_0^1 \mathbf{1}_{\{x_{\sigma(1)} < \dots < x_{\sigma(n)}\}} dx_1 \dots dx_n = \int_0^1 \mathbf{1}_{\{x_1 < \dots < x_n\}} dx_1 \dots dx_n. \end{aligned}$$

Pour justifier cette dernière égalité, on peut soit faire un changement de variable $y_i = x_{\sigma(i)}$, soit utiliser Fubini dans l'ordre qui nous arrange, obtenir

$$\int_0^1 \mathbf{1}_{\{x_{\sigma(1)} < \dots < x_{\sigma(n)}\}} dx_1 \dots dx_n = \int_0^1 \mathbf{1}_{\{x_{\sigma(1)} < \dots < x_{\sigma(n)}\}} dx_{\sigma(1)} \dots dx_{\sigma(n)}$$

puis réétiqueter les variables muettes. Bref, la proba ne dépend pas de σ .

Maintenant, les événements $((Y_1^{(n)}, \dots, Y_n^{(n)}) = (X_{\sigma(1)}, \dots, X_{\sigma(n)}))_{\sigma \in \mathfrak{S}_n}$ étant tous disjoints à un événement de probabilité nulle près (d'après la question 2.(a)), et leur réunion étant un événement presque sûr, on a

$$\begin{aligned} 1 &= \mathbb{P}\left(\bigcup_{\sigma \in \mathfrak{S}_n} (Y_1^{(n)}, \dots, Y_n^{(n)}) = (X_{\sigma(1)}, \dots, X_{\sigma(n)})\right) \\ &= \sum_{\sigma \in \mathfrak{S}_n} \mathbb{P}((Y_1^{(n)}, \dots, Y_n^{(n)}) = (X_{\sigma(1)}, \dots, X_{\sigma(n)})). \end{aligned}$$

Comme il y a $n!$ termes dans la somme, tous égaux, on a que chacun vaut $\frac{1}{n!}$.

(c)

$$\begin{aligned} \mathbb{E}[h(Y_1^{(n)}, \dots, Y_n^{(n)})] &= \mathbb{E}[h(Y_1^{(n)}, \dots, Y_n^{(n)}) \sum_{\sigma \in \mathfrak{S}_n} \mathbf{1}_{\{X_{\sigma(1)} \leq \dots \leq X_{\sigma(n)}\}}] \\ &= \sum_{\sigma \in \mathfrak{S}_n} \mathbb{E}[h(X_{\sigma(1)}, \dots, X_{\sigma(n)}) \mathbf{1}_{\{X_{\sigma(1)} \leq \dots \leq X_{\sigma(n)}\}}] \\ &= \sum_{\sigma \in \mathfrak{S}_n} \int_0^1 h(x_{\sigma(1)}, \dots, x_{\sigma(n)}) \mathbf{1}_{\{0 \leq x_{\sigma(1)} < \dots < x_{\sigma(n)} \leq 1\}} dx_1 \dots dx_n, \end{aligned}$$

par théorème de transfert. On obtient le résultat encore une fois par changement de variable ou Fubini.

(d) Soit $k \in \llbracket 1; n \rrbracket$, f une fonction borélienne positive, posons $h : (y_1, \dots, y_n) \mapsto f(y_k)$. Alors on a d'après Fubini,

$$\begin{aligned} \mathbb{E}[f(Y_k^{(n)})] &= \mathbb{E}[h(Y_1^{(n)}, \dots, Y_n^{(n)})] = n! \int_0^1 f(y_k) \mathbf{1}_{\{0 \leq y_1 < \dots < y_n \leq 1\}} dy_1 \dots dy_n \\ &= n! \int_{\mathbb{R}} f(y) \mathbf{1}_{\{0 \leq y \leq 1\}} \left(\int_{\mathbb{R}^{k-1}} \mathbf{1}_{\{0 \leq y_1 \leq \dots \leq y_{k-1} \leq y\}} dy_1 \dots dy_{k-1} \right) \left(\int_{\mathbb{R}^{n-k}} \mathbf{1}_{\{y \leq y_{k+1} \leq \dots \leq y_n \leq 1\}} dy_{k+1} \dots dy_n \right) dy. \end{aligned}$$

Maintenant, par le changement de variable $y'_j = y_j/y$ et la question (b), on obtient

$$\begin{aligned} \int_{\mathbb{R}^{k-1}} \mathbf{1}_{\{0 \leq y_1 \leq \dots \leq y_{k-1} \leq y\}} dy_1 \dots dy_{k-1} &= y^{k-1} \int_{\mathbb{R}^{k-1}} \mathbf{1}_{\{0 \leq y'_1 \leq \dots \leq y'_{k-1} \leq 1\}} dy'_1 \dots dy'_{k-1} \\ &= y^{k-1} \mathbb{P}(X_1 \leq \dots \leq X_{k-1}) = \frac{y^{k-1}}{(k-1)!}. \end{aligned}$$

De la même manière, on obtient par le changement de variable $y'_j = (1 - y_j)/(1 - y)$

$$\int_{\mathbb{R}^{n-k}} \mathbf{1}_{\{y \leq y_{k+1} \leq \dots \leq y_n \leq 1\}} dy_{k+1} \dots dy_n = \frac{(1-y)^{n-k}}{(n-k)!}.$$

En concaténant ces trois derniers résultats, on conclut que

$$\mathbb{E}[f(Y_k^{(n)})] = n! \int_{\mathbb{R}} f(y) \mathbf{1}_{\{0 \leq y \leq 1\}} n! \frac{y^{k-1}}{(k-1)!} \frac{(1-y)^{n-k}}{(n-k)!} dy,$$

et donc $Y_k^{(n)}$ admet la densité suivante (qui est celle de la loi Bêta de paramètres k et $n - k + 1$)

$$n! \mathbf{1}_{\{0 \leq y \leq 1\}} \frac{y^{k-1}}{(k-1)!} \frac{(1-y)^{n-k}}{(n-k)!} = \mathbf{1}_{\{0 \leq y \leq 1\}} k \binom{n}{k} y^{k-1} (1-y)^{n-k}.$$

Exercice 2 *Estimation*

1. $\mathbb{P}(|\mu_n - m| > x) \leq \frac{\text{Var}(\mu_n)^2}{x^2} = \frac{\sigma^2}{nx^2}$. On voit que $\delta(\alpha, n) = \sigma\sqrt{\frac{1}{\alpha n}}$ convient.
2. (a) Considérons d'abord le cas où X est centrée. Par convexité d'exponentielle et comme $X \in [a, b]$ presque sûrement, on a p.s. l'inégalité suivante :

$$e^{\lambda X} \leq \frac{X - a}{b - a} e^{\lambda b} + \frac{b - X}{b - a} e^{\lambda a}.$$

En prenant l'espérance puis en posant $\theta = \frac{-a}{b-a}$ et $u = \lambda(b - a)$ on obtient

$$\mathbb{E}[e^{\lambda X}] \leq \frac{-a}{b-a} e^{\lambda b} + \frac{b}{b-a} e^{\lambda a} = \theta e^{-(1-\theta)u} + (1-\theta) e^{\theta u} \leq e^{u^2/8} = e^{\lambda^2(b-a)^2/8}.$$

Quand X n'est plus centrée on applique à $X - m$ (qui appartient à $[a - m, b - m]$ p.s.) et on a toujours $\mathbb{E}[e^{\lambda(X-m)}] \leq e^{\lambda^2(b-a)^2/8}$.

On utilise ensuite l'inégalité de Chernoff. Soit $\lambda > 0, x > 0$.

$$\mathbb{P}((\mu_n - m) \geq x) \leq \mathbb{E}[e^{\lambda(\mu_n - m)}] e^{-\lambda x} = (\mathbb{E}[e^{\lambda(X_1 - m)/n}])^n e^{-\lambda x} \leq \exp\left(\frac{\lambda^2(b-a)^2}{8n} - \lambda x\right).$$

On optimise en $\lambda = 4xn/(b-a)^2$ qui est bien positif car $x > 0$, ce qui donne

$$\mathbb{P}((\mu_n - m) \geq x) \leq \exp(-2x^2/(b-a)^2).$$

C'est l'inégalité de Hoeffding. Le cas $x \leq 0$ est trivial car un événement est toujours de probabilité plus petite que 1.

- (b) En appliquant l'inégalité précédente à $-X$, on obtient

$$\mathbb{P}((\mu_n - m) \leq -x) \leq \exp(-2x^2/(b-a)^2).$$

Par union on a l'inégalité bilatère

$$\mathbb{P}(|\mu_n - m| \geq x) \leq \mathbb{P}((\mu_n - m) \leq -x) + \mathbb{P}((\mu_n - m) \geq x) \leq 2 \exp(-2nx^2/(b-a)^2).$$

On voit alors que $\delta(\alpha, n) = (b-a)\sqrt{\frac{\log(2/\alpha)}{2n}}$ donne un intervalle de confiance au niveau α .

3. Pour des Bernoulli de paramètre inconnu on peut prendre $\sigma = 1/2$ dans 1. et $(b-a) = 1$ dans 2. On compare alors $\delta(\alpha, n) = \frac{1}{2\sqrt{\alpha n}}$ à $\delta(\alpha, n) = \sqrt{\frac{\log(2/\alpha)}{2n}}$. Pour $\alpha = 0.05$ on obtient $\approx 2, 2/\sqrt{n}$ contre $\approx 1.4/\sqrt{n}$. L'inégalité de Hoeffding est déjà meilleure. Quand $\alpha \rightarrow 0$, l'écart se creuse et l'inégalité de Hoeffding est infiniment meilleure.
4. (a)
- (b) D'après la question précédente,

$$\#\{i, 1 \leq i \leq k \text{ t.q. } \mu^{(i)} \geq \nu_n\} = \#\{i, 1 \leq i \leq k \text{ t.q. } \mu^{(i)} \leq \nu_n\} = k/2.$$

Si $|\nu_n - m| > x$, alors soit $\nu_n > m + x$ et on a au moins $k/2$ indices i où $\mu^{(i)} > m + x$, soit $\nu_n < m - x$ et on a au moins $k/2$ indices i où $\mu^{(i)} < m - x$. Dans les deux cas on a au moins $k/2$ indices i tels que $|\mu^{(i)} - m| > x$.

(c) De la question suivante on déduit

$$\begin{aligned}\mathbb{P}(|\nu_n - m| > x) &\leq \mathbb{P}(\#\{i, |\mu^{(i)} - m| > x\} \geq k/2) \\ &= \mathbb{P}\left(\sum_{i=1}^k \mathbf{1}_{|\mu^{(i)} - m| > x} \geq k/2\right).\end{aligned}$$

Posons $M = \mathbb{E}[\mathbf{1}_{|\mu^{(i)} - m| > x}]$. Introduisant M des deux côtés et divisant par k , on obtient

$$\begin{aligned}\mathbb{P}(|\nu_n - m| > x) &\leq \mathbb{P}\left(\frac{1}{k} \sum_{i=1}^k \mathbf{1}_{|\mu^{(i)} - m| > x} - M \geq 1/2 - M\right) \\ &\leq \begin{cases} \exp(-2k(1/2 - M)^2) & \text{si } (1/2 - M) \geq 0 \text{ (Hoeffding)} \\ 1 & \text{sinon (c'est une proba!)} \end{cases} \\ &= \exp(-2k(1/2 - M)_+^2)\end{aligned}$$

On peut maintenant utiliser Bienaymé-Tchébychev pour borner $M = \mathbb{P}(|\mu^{(i)} - m| > x) \leq \frac{\text{Var}(\mu^{(i)})}{x^2} = \frac{\sigma^2}{\ell x^2}$.

On en déduit

$$\mathbb{P}(|\nu_n - m| > x) \leq \exp\left(-2\left(1/2 - \frac{\sigma^2}{\ell x^2}\right)_+^2\right)$$

(d) On a

$$\mathbb{P}\left(|\nu_n - m| > \sigma \sqrt{\frac{C \log(1/\alpha)}{n}}\right) \leq \exp\left(-2k\left(1/2 - \frac{n}{\ell C \log(1/\alpha)}\right)_+^2\right) \leq \alpha$$

Il faut donc choisir k et C tels que

$$k\left(1/2 - \frac{n}{\ell C \log(1/\alpha)}\right)_+^2 \geq \frac{\log(1/\alpha)}{2}.$$

Comme $n/\ell \approx k$ on voit que si $k \approx \log(1/\alpha)$ le contenu de la parenthèse est d'ordre constant, ce qui nous donne une chance. Posons $k = \lceil B \log(1/\alpha) \rceil$. On a

$$k\left(1/2 - \frac{n}{\ell C \log(1/\alpha)}\right)_+^2 \geq B \log(1/\alpha) \left(\frac{1}{2} - \frac{Bn}{C \ell k}\right)_+^2 \geq B \log(1/\alpha) \left(\frac{1}{2} - \frac{2B}{C}\right)^2.$$

Ceci est bien $\geq \frac{\log(1/\alpha)}{2}$ pour par exemple $B = 9$ et $C = 108$.

5. Si on veut estimer un million de paramètres à la fois (possible quand on fait du *machine learning*), qu'on n'a pas d'hypothèses sur les variables en dehors de la variance finie (possible quand on fait de la *finance*) et qu'on veut que tous soient bien estimés simultanément, alors par union, il faut estimer chaque paramètre au niveau $\alpha' = 5 \cdot 10^{-8}$. On a alors des intervalles de largeur $\leq \sigma \sqrt{\frac{2000}{n}}$ et 200000 observations suffisent à faire ramener la largeur des intervalles à un dixième d'écart-type (possible quand on a du *big data*). Pour l'estimateur usuel, trop sensible aux valeurs extrêmes, il faudrait un milliard d'observations.