

Exercice 1 M-estimateurs convexes (8 points)

Soit  $\mathcal{X}$  un espace mesurable, muni d'une probabilité  $P$ , et soit  $X_1, X_2, \dots$  une suite de variables aléatoires i.i.d. sur  $\mathcal{X}$  de loi  $P$ . Soit  $\Theta$  un ouvert convexe de  $\mathbb{R}^d$  ( $d \geq 1$ ) et  $\phi : \mathcal{X} \times \Theta \rightarrow \mathbb{R}$  une fonction telle que:

- Pour tout  $\theta \in \Theta$ ,  $\phi(\cdot, \theta)$  est mesurable et intégrable par-rapport à  $P$ ;
- Pour tout  $x \in \mathcal{X}$ ,  $\phi(x, \cdot)$  est convexe.

Pour tout entier  $n \geq 1$ , on définit

$$\begin{aligned}\Phi_n : \Theta &\rightarrow \mathbb{R} \\ \theta &\mapsto \frac{1}{n} \sum_{i=1}^n \phi(X_i, \theta)\end{aligned}$$

et on définit aussi la fonction

$$\begin{aligned}\Phi : \Theta &\rightarrow \mathbb{R} \\ \theta &\mapsto \mathbb{E}\phi(X_1, \theta).\end{aligned}$$

On suppose que  $\Phi$  est minorée et qu'elle atteint son minimum. On note  $\Theta^* = \{\theta^* \in \Theta : \forall \theta \in \Theta, \Phi(\theta) \geq \Phi(\theta^*)\}$  et on suppose que  $\Theta^*$  est un compact.

1. Montrer qu'avec probabilité 1,  $\hat{\Phi}_n$  est aussi minorée et atteint son minimum, pour  $n$  assez grand.
2. (question facultative) Pouvez-vous trouver un exemple de fonction  $\phi$ , de loi  $P$  et d'ensemble  $\Theta$  tels que  $\Phi$  est minorée, mais  $\Theta^*$  n'est pas compact et  $\Phi_n$  est presque sûrement non minorée ?
3. (question facultative) Montrer qu'il existe une suite de variables aléatoires  $(\hat{\theta}_n)_{n \geq 1}$  telle qu'avec probabilité 1,  $\hat{\theta}_n$  est un minimiseur de  $\Phi_n$  pour  $n$  assez grand.
4. Montrer que  $d(\hat{\theta}_n, \Theta^*) \xrightarrow[n \rightarrow \infty]{\text{p.s.}} 0$ .

Exercice 2 Une inégalité de concentration (12 points)

Soit  $n \geq 1$  et  $\mathcal{X}_1, \dots, \mathcal{X}_n$  des espaces mesurables. Pour tout  $i \in \{1, \dots, n\}$ , soit  $X_i$  une variable aléatoire à valeurs dans  $\mathcal{X}_i$ . On suppose que  $X_1, \dots, X_n$  sont définies sur un même espace de probabilité et qu'elles sont indépendantes.

Soit  $f : \mathcal{X}_1 \times \dots \times \mathcal{X}_n \rightarrow \mathbb{R}$  une fonction mesurable. On suppose l'existence de réels strictement positifs  $c_1, \dots, c_n$  tels que pour tout  $i \in \{1, \dots, n\}$ , pour tout  $(x_1, \dots, x_n) \in \mathcal{X}_1 \times \dots \times \mathcal{X}_n$ , et pour tout  $s, t \in \mathcal{X}_i$ ,

$$f(x_1, \dots, x_{i-1}, t, x_{i+1}, \dots, x_n) - f(x_1, \dots, x_{i-1}, s, x_{i+1}, \dots, x_n) \leq c_i.$$

On cherche alors à démontrer une inégalité de concentration pour la variable aléatoire  $Y = f(X_1, \dots, X_n)$ .

1. Montrer que  $Y$  est intégrable.
2. Pour  $i = 1, \dots, n$ , on pose  $Y_i = \mathbb{E}[Y | X_1, \dots, X_i]$ .
  - a) Vérifier que  $Y - \mathbb{E}Y = \sum_{i=1}^n (Y_i - Y_{i-1})$ , après avoir préalablement défini  $Y_0$ .
  - b) Vérifier que pour tout  $i = 1, \dots, n$ ,  $Y_{i-1} = \mathbb{E}[Y_i | X_1, \dots, X_{i-1}]$  (où l'espérance conditionnelle sachant aucune variable sera comprise comme l'espérance au sens usuel).
3. Pour tout  $i = 1, \dots, n$ , on pose

$$\begin{aligned} g_i : \mathcal{X}_1 \times \dots \times \mathcal{X}_i &\rightarrow \mathbb{R} \\ (x_1, \dots, x_i) &\mapsto \mathbb{E}f(x_1, \dots, x_i, X_{i+1}, \dots, X_n). \end{aligned}$$

Vérifier que pour tout  $i = 1, \dots, n$ ,  $Y_i = g_i(X_1, \dots, X_i)$ .

4. Soit  $i \geq 1$ . Fixons  $(x_1, \dots, x_{i-1}) \in \mathcal{X}_1 \times \dots \times \mathcal{X}_{i-1}$  et posons  $Z_i = g_i(x_1, \dots, x_{i-1}, X_i)$ .
  - a) Montrer que  $Z_i$  est sous-Gaussienne, de paramètre d'échelle  $c_i^2/4$  (si vous ne parvenez qu'à majorer le paramètre d'échelle par  $c_i^2$ , admettez le résultat).
  - b) En déduire que pour tout  $\lambda > 0$ , avec probabilité 1,

$$\mathbb{E} [e^{\lambda(Y_i - Y_{i-1})} | X_1, \dots, X_{i-1}] \leq e^{\lambda^2 c_i^2 / 8}$$

5. Conclure que pour tout  $\lambda > 0$ ,

$$\mathbb{E} [e^{\lambda(Y - \mathbb{E}Y)}] \leq e^{\frac{\lambda^2 \sum_{i=1}^n c_i^2}{8}}.$$

(On montrera d'abord que  $\mathbb{E} [e^{\lambda(Y - \mathbb{E}Y)}] \leq e^{\lambda^2 c_n^2 / 8} \mathbb{E} [e^{\lambda \sum_{i=1}^{n-1} (Y_i - Y_{i-1})}]$  puis on procèdera par récurrence)

6. Montrer que pour tout  $t \geq 0$ ,

$$\mathbb{P}[|f(X_1, \dots, X_n) - \mathbb{E}f(X_1, \dots, X_n)| \geq t] \leq 2 \exp \left( \frac{-2t^2}{\sum_{i=1}^n c_i^2} \right).$$

7. A l'aide du résultat précédent, retrouver:
  - a) l'inégalité de Hoeffding;
  - b) l'inégalité de concentration pour les fonctions Lipschitziennes appliquées aux variables aléatoires bornées.

8. Applications:

- a) Triangles dans des graphes aléatoires: soit  $G_n$  un graphe aléatoire d'Erdős-Rényi, de taille  $n \geq 3$  et de paramètre  $p \in (0, 1)$ , et soit  $T_n$  le nombre de triangles dans  $G_n$ . Vérifier que  $\mathbb{E}[T_n] = \frac{n(n-1)(n-2)}{6}p^3$  et montrer que

$$T_n = \frac{n^3 p^3}{6} + O_{\mathbb{P}}(n^2).$$

- b) Profondeur statistique de Tukey: soient  $X_1, \dots, X_n$  des vecteurs aléatoires i.i.d. dans  $\mathbb{R}^d$  ( $n, d \geq 1$ ). Pour tout  $x \in \mathbb{R}^d$ , on définit la profondeur de  $x$ , dans le nuage de points  $X_1, \dots, X_n$ , de la manière suivante:

$$D_n(x) = \inf \left\{ \frac{\#\{i = 1, \dots, n : X_i \in H\}}{n} : H \in \mathcal{H}, x \in H \right\},$$

où  $\mathcal{H}$  est l'ensemble des demi-espaces affines fermés de  $\mathbb{R}^d$ . Autrement dit,  $D_n(x)$  est le nombre minimal de points de l'échantillon étant inclus dans un demi-espace fermé contenant  $x$ .

- i – D'après vous, pourquoi  $D_n(x)$  est-elle appelée *la profondeur* du point  $x$  dans le nuage ?  
ii – Soit  $x \in \mathbb{R}^d$  quelconque. Montrer que pour tout  $\delta \in (0, 1)$ ,

$$\mathbb{E}D_n(x) - \sqrt{\frac{\log(2/\delta)}{2n}} \leq D_n(x) \leq \mathbb{E}D_n(x) + \sqrt{\frac{\log(2/\delta)}{2n}}$$

avec probabilité au moins  $1 - \delta$ .

**Exercice 3      Une inégalité de concentration uniforme en  $n$  (7+∞ points)**

Soit  $(X_n)_{n \geq 1}$  une suite de variables aléatoires i.i.d., centrées et sous-Gaussiennes, de paramètre d'échelle  $\sigma^2 > 0$ .

1. Rappeler pourquoi pour tout  $\delta \in (0, 1)$ , et pour tout  $n \geq 1$ ,

$$\mathbb{P} \left[ |\bar{X}_n| \leq \sigma \sqrt{\frac{2 \log(2/\delta)}{n}} \right] \geq 1 - \delta.$$

2. En utilisant une borne d'union, montrer que pour tout  $\delta \in (0, 1)$ ,

$$\mathbb{P} \left[ \forall n \geq 1, |\bar{X}_n| \leq \sigma \sqrt{\frac{2 \log(\pi^2 n^2 / (3\delta))}{n}} \right] \geq 1 - \delta.$$

3. Une telle borne, uniforme en  $n$ , peut être intéressante en apprentissage en ligne. Par exemple, dans le problème de bandit, à partir de chaque nouvelle observation, on peut mettre à jour des intervalles de confiance, et on souhaite que tous ces intervalles soient valides, i.e., que chacun contienne le paramètre d'intérêt avec la bonne probabilité. En revanche, pour un niveau  $\delta$  fixé, la taille des intervalles de confiance donnés par la borne précédente est de l'ordre de  $\sqrt{(\log n)/n}$ , et on peut se demander si ces intervalles ne sont pas conservateurs. Nous allons montrer, dans cette question, qu'on peut en fait obtenir des intervalles de taille de l'ordre de  $\sqrt{(\log \log n)/n}$ , en appliquant un outil plus fin que la borne d'union. Fixons une suite  $(t_n)_{n \geq 1}$  décroissante de réels strictement positifs.

a) Pour tout entier  $k \geq 0$ , soit  $E_k = \{2^k, 2^k + 1, \dots, 2^{k+1} - 1\}$ . Pour  $n \geq 1$ , on note  $S_n = X_1 + \dots + X_n$ . Montrer que

$$\mathbb{P}[\exists n \geq 1, |\bar{X}_n| > t_n] \leq \sum_{k=0}^{\infty} \mathbb{P}[\max_{n \in E_k} |S_n| > 2^k t_{2^{k+1}}].$$

b) On admettra l'inégalité de Doob pour les martingales suivante:

$$\forall m \geq 1, \forall t \geq 0, \mathbb{P}[\max_{1 \leq i \leq m} |S_i| > t] \leq 2e^{-\frac{t^2}{2\sigma^2 m}}.$$

En déduire que, pour tout  $k \in \mathbb{N}$ ,

$$\mathbb{P}[\max_{n \in E_k} |S_n - S_{2^k}| > 2^{k-1} t_{2^{k+1}}] \leq 2e^{-\frac{2^k t_{2^{k+1}}^2}{8\sigma^2}}.$$

c) Vérifier que, pour tout  $k \in \mathbb{N}$ ,

$$\mathbb{P}[|S_{2^k}| > 2^{k-1} t_{2^{k+1}}] \leq 2e^{-\frac{2^k t_{2^{k+1}}^2}{8\sigma^2}}.$$

d) En utilisant le fait que, pour tout  $k \geq 0$ ,

$$\max_{n \in E_k} |S_n| \leq |S_{2^k}| + \max_{n \in E_k} |S_n - S_{2^k}|,$$

déduire que

$$\mathbb{P}[\max_{n \in E_k} |S_n| > 2^k t_{2^{k+1}}] \leq 4e^{-\frac{2^k t_{2^{k+1}}^2}{8\sigma^2}}.$$

e) On choisit  $t_n = 4\sigma \sqrt{\frac{\log \left( \frac{2\pi^2 (\log_2 n)^2}{3\delta} \right)}{n}}$ , pour tout  $n \geq 1$ , où  $\delta \in (0, 1)$  et  $\log_2$  est le logarithme en base 2. Vérifier que la suite  $(t_n)_{n \geq 2}$  est bien définie et qu'elle est décroissante.

f) En déduire qu'avec probabilité au moins  $1 - \delta$ ,

$$\forall n \geq 2, \quad |\bar{X}_n| \leq 4\sigma \sqrt{\frac{\log\left(\frac{2\pi^2(\log_2 n)^2}{3\delta}\right)}{n}}.$$

Ce résultat peut s'interpréter comme une loi du logarithme itéré uniforme, non asymptotique. La taille des intervalles de confiances obtenus est, cette fois-ci, de l'ordre de  $\sqrt{(\log \log n)/n}$ , qui est la vitesse qu'on retrouve dans la loi du logarithme itéré standard, ce qui prouve que cette taille, asymptotiquement, ne peut être améliorée.

4. ( $\infty$  points) Supposons que  $X_1, X_2, \dots$  sont i.i.d., Gaussiennes, de moyenne  $\mu \in \mathbb{R}$  et de variance  $\sigma^2 > 0$ . Proposer une suite d'estimateurs  $(\hat{\mu}_n)_{n \geq 1}$  telle que, quelle que soit la valeur de  $\mu$ , on a, pour tout  $\delta \in (0, 1)$ ,

$$\mathbb{P} [\forall n \geq 1, |\hat{\mu}_n - \mu| \geq t(n, \delta)] \geq 1 - \delta,$$

où, pour tout  $\delta \in (0, 1)$ ,  $t(n, \delta)$  est une suite de réels positifs tendant vers zéro strictement plus vite que  $\sqrt{(\log \log n)/n}$ .