

## Troisième Année Licence M.I.A.S.H.S. 2023 – 2024

## Statistique 2

Contrôle Continu 2, Avril 2024

Examen de 1h30. Tout document ou calculatrice est interdit.

## Exercice 1 (Sur 12 points)

 Dans la suite, pour un vecteur  $U = (U_1, \dots, U_n) \in \mathbf{R}^n$  on note  $\|U\|^2 = \sum_{k=1}^n U_k^2$ .

- Soit  $Z_1 \stackrel{\mathcal{L}}{\sim} \mathcal{N}(0, 1)$  et soit  $g$  une fonction de classe  $\mathcal{C}^1$  sur  $\mathbf{R}$  et  $C > 0$  tel que  $|xg(x)| + |g'(x)| \leq C(1+x^2)^{-1}e^{x^2/2}$  pour tout  $x \in \mathbf{R}$ . Montrer que  $\mathbb{E}[|g'(Z_1)| + |Z_1g(Z_1)|] < \infty$  (1pt), puis que  $\mathbb{E}[g'(Z_1)] = \mathbb{E}[Z_1g(Z_1)]$  (1.5pts). En déduire que  $\mathbb{E}[Z_1^4] = 3$  (1pt).
- Soit  $X_1 \stackrel{\mathcal{L}}{\sim} \mathcal{N}(\mu_1, \sigma^2)$  avec  $\mu_1 \in \mathbf{R}$  et  $\sigma^2 > 0$ . Démontrer que  $\mathbb{E}[g'(X_1)] = \frac{1}{\sigma^2} \mathbb{E}[(X_1 - \mu_1)g(X_1)]$  (1.5pts).
- Soit  $(Z_k)_{k \in \mathbf{N}^*}$  une suite de v.a.i.i.d. de même loi  $\mathcal{N}(0, 1)$ . Déterminer la loi de  $Z = (Z_1, \dots, Z_n)$  où  $n \geq 1$  (0.5pts). Si  $h : \mathbf{R}^n \rightarrow \mathbf{R}$  est une fonction de classe  $\mathcal{C}^1$  sur  $\mathbf{R}^n$  telle que  $\mathbb{E}[\|\nabla h(Z)\| + \|Zh(Z)\|] < \infty$  avec  $\nabla h(x) = \left(\frac{\partial}{\partial x_i} h(x)\right)_{1 \leq i \leq n}$ , démontrer que  $\mathbb{E}[\nabla h(Z)] = \mathbb{E}[Zh(Z)]$  (3pts).
- Soit  $(X_k)_{k \in \mathbf{N}^*}$  une suite de v.a. indépendantes, telle que  $X_k \stackrel{\mathcal{L}}{\sim} \mathcal{N}(\mu_k, \sigma^2)$  avec  $\mu_k \in \mathbf{R}$  pour tout  $k \in \mathbf{N}^*$ . Déterminer la loi de  $X = (X_1, \dots, X_n)$  où  $n \geq 1$  (0.5pts). Soit  $h : \mathbf{R}^n \rightarrow \mathbf{R}$  une fonction de classe  $\mathcal{C}^1$  sur  $\mathbf{R}^n$  telle que  $\mathbb{E}[\|\nabla h(X)\| + \|Xh(X)\|] < \infty$ . Démontrer que  $\sigma^2 \mathbb{E}[\nabla h(X)] = \mathbb{E}[(X - \mu)h(X)]$  en spécifiant  $\mu$  (1.5pts). En déduire que si  $h : (x_1, \dots, x_n) \in \mathbf{R}^n \mapsto (h_1(x_1, \dots, x_n), \dots, h_n(x_1, \dots, x_n))$  une fonction de classe  $\mathcal{C}^1$  sur  $\mathbf{R}^n$  telle que  $\mathbb{E}[\|\nabla h_i(X)\| + \|X_i h_i(X)\|] < \infty$  pour tout  $i$ , alors

$$\frac{1}{\sigma^2} \sum_{i=1}^n \text{cov}(X_i, h_i(X)) = \sum_{i=1}^n \mathbb{E}\left[\frac{\partial}{\partial x_i} h_i(X)\right] \quad (1.5pts). \quad (1)$$

## Exercice 2 (Sur 13 points)

On considère  $(X_k)_{k \in \mathbf{N}^*}$  une suite de v.a. indépendantes, telle que  $X_k \stackrel{\mathcal{L}}{\sim} \mathcal{N}(m_k, 1)$  avec  $m_k \in \mathbf{R}$  pour tout  $k \in \mathbf{N}^*$ . On suppose que  $(X_1, \dots, X_n)$  a été observé et  $m = (m_1, \dots, m_n)$  est un vecteur inconnu (avec  $n \geq 2$ ).

- Déterminer la vraisemblance du modèle statistique, après avoir précisé ce dernier (1pt).
- Prouver qu'il existe un unique estimateur  $\hat{m}$  de  $m$  par maximum de vraisemblance et  $\hat{m} = (X_1, \dots, X_n)$  (1pt).
- Déterminer le biais de  $\hat{m}$  (0.5pts) et montrer que son risque quadratique est  $R(\hat{m}) = n$  (1pt).
- Soit maintenant l'estimateur  $\tilde{m} = (\tilde{m}_1, \dots, \tilde{m}_n)$  tel que

$$\tilde{m}_k = \tilde{m}_k(X_1, \dots, X_n) = X_k \left(1 - \frac{n-2}{\sum_{i=1}^n X_i^2}\right) \quad \text{pour tout } k \in \{1, \dots, n\}.$$

On suppose  $(m_k)_{k \in \mathbf{N}}$  telle que  $\frac{1}{n} \sum_{k=1}^n m_k^2 \xrightarrow[n \rightarrow \infty]{} M$ . Déterminer la limite en loi de  $\tilde{m}_k$  quand  $n \rightarrow \infty$  (2pts).

- Démontrer que  $R(\tilde{m}) = -n + \mathbb{E}[\|\tilde{m} - X\|^2] + 2 \sum_{i=1}^n \text{cov}(X_i, \tilde{m}_i)$  (2.5pts). En utilisant (1), en déduire que

$$R(\tilde{m}) = -n + \mathbb{E}[\|\tilde{m} - X\|^2] + 2 \sum_{i=1}^n \mathbb{E}\left[\frac{\partial}{\partial x_i} \tilde{m}_i(X)\right] \quad (1pt).$$

6. Montrer que  $\mathbb{E}[\|\tilde{m} - X\|^2] = \mathbb{E}\left[\frac{(n-2)^2}{\sum_{i=1}^n X_i^2}\right]$  (**1pt**) et  $\sum_{i=1}^n \frac{\partial}{\partial x_i} \tilde{m}_i(X) = n - \frac{(n-2)^2}{\sum_{i=1}^n X_i^2}$  (**1.5pts**). En déduire que

$$R(\tilde{m}) = n - (n-2)^2 \mathbb{E}\left[\frac{1}{\sum_{i=1}^n X_i^2}\right] \quad (\mathbf{1pt}).$$

Comment expliquer que  $R(\tilde{m}) < R(\hat{m})$  pour  $n \geq 3$  (**0.5pts**)?