

---

## EXAMEN STATISTIQUE - 1SN

Lundi 16 janvier Novembre 2023 (8h-9h30)

*Partiel sans document (Une feuille A4 recto-verso autorisée)*

---

### Exercice 1 : Estimation (10 points)

On considère  $n$  variables aléatoires indépendantes  $X_1, \dots, X_n$  suivant la même loi de Poisson de paramètre  $\lambda$  et  $m$  variables aléatoires  $Y_1, \dots, Y_m$  suivant la même loi normale  $\mathcal{N}(\lambda, \sigma^2)$ , où  $\lambda > 0$  est un paramètre inconnu et  $\sigma^2$  est un paramètre connu. On suppose de plus que les vecteurs  $\mathbf{X}_n = (X_1, \dots, X_n)^T$  et  $\mathbf{Y}_m = (Y_1, \dots, Y_m)^T$  sont indépendants. Une situation pratique dans laquelle on peut avoir ces deux ensembles d'observations  $(X_1, \dots, X_n)^T$  et  $(Y_1, \dots, Y_m)^T$  correspond par exemple au cas où  $X_1, \dots, X_n$  sont obtenues par un premier capteur qui discrétise les observations de manière à avoir une loi de Poisson et où  $(Y_1, \dots, Y_m)^T$  sont obtenues par un second capteur fournissant des données de loi normale avec une incertitude  $\sigma^2$ . L'objectif de cet exercice est d'étudier des estimateurs de  $\lambda$  basés sur les vecteurs  $\mathbf{X}_n$  et  $\mathbf{Y}_m$  et de déterminer s'il est avantageux de considérer ces deux vecteurs par rapport à utiliser un seul ensemble d'observations  $\mathbf{X}_{n+m}$  ou  $\mathbf{Y}_{n+m}$ .

- (3pts) Déterminer l'estimateur du maximum de vraisemblance du paramètre  $\lambda$  construit à partir de  $\mathbf{X}_n$  noté  $\hat{\lambda}_{MV}$  et montrer qu'il est sans biais et efficace.
- (5pts) Pour profiter des deux ensembles d'observations  $\mathbf{X}_n$  et  $\mathbf{Y}_m$ , on propose d'utiliser l'estimateur

$$\hat{\lambda}_{n,m}(\alpha) = \frac{\alpha}{n} \sum_{i=1}^n X_i + \frac{1-\alpha}{m} \sum_{j=1}^m Y_j, \quad \alpha \in ]0, 1[.$$

- (2pts) Montrer que  $\hat{\lambda}_{n,m}(\alpha)$  est un estimateur sans biais du paramètre  $\lambda$  pour toute valeur de  $\alpha$ . Déterminer la variance de l'estimateur  $\hat{\lambda}_{n,m}(\alpha)$ .
  - (1pt) Déterminer la valeur de  $\alpha$  optimale noté  $\alpha^*$  (dépendant de  $n, m, \sigma^2$  et  $\lambda$ ) permettant de minimiser la variance de l'estimateur  $\hat{\lambda}_{n,m}(\alpha)$ . On notera  $\hat{\lambda}_{opt} = \hat{\lambda}_{n,m}(\alpha^*)$ .  
*Remarque : la valeur de  $\alpha^*$  dépend de  $\lambda$  inconnu et donc n'est pas utilisable en pratique mais elle permet de quantifier le gain maximum de performance obtenu en utilisant les deux ensembles d'observations  $(X_1, \dots, X_n)^T$  et  $(Y_1, \dots, Y_m)^T$ .*
  - (2pts) Montrer que la variance de  $\hat{\lambda}_{MV}$  **obtenue avec  $n+m$  observations**  $x_1, \dots, x_{n+m}$  est inférieure à celle de  $\hat{\lambda}_{opt}$  pour  $\lambda < \sigma^2$ . Comment expliquer ce résultat ?
- (2pts) On définit la vraisemblance conjointe des échantillons  $\mathbf{x}_n$  et  $\mathbf{y}_m$ , notée  $L(\mathbf{x}_n, \mathbf{y}_m; \lambda)$ , par le produit des vraisemblances des deux échantillons  $(X_1, \dots, X_n)^T$  et  $(Y_1, \dots, Y_m)^T$ . Montrer que les extrémums de  $L(\mathbf{x}_n, \mathbf{y}_m; \lambda)$  par rapport à  $\lambda$  sont solution d'une équation du second degré que l'on précisera. Expliquer pourquoi cette équation admet une unique racine positive qu'on ne demande pas de déterminer.

## Exercice 2 : Tests Statistiques (10 points)

On considère  $n$  variables aléatoires  $X_1, \dots, X_n$  indépendantes de densités

$$p(x_i; \theta) = \frac{3}{\theta} x_i^2 \exp\left(-\frac{x_i^3}{\theta}\right) \mathbb{I}_{\mathbb{R}^+}(x)$$

avec  $\theta > 0$  et où  $\mathbb{I}_{\mathbb{R}^+}(x)$  indique la fonction indicatrice sur  $\mathbb{R}^+$ . On veut à l'aide d'observations  $x_1, \dots, x_n$ , de ces variables aléatoires tester les deux hypothèses suivantes

$$H_0 : \theta = \theta_0 \text{ contre } H_1 : \theta = \theta_1 \quad \text{avec } \theta_1 < \theta_0$$

- (2pts) À l'aide du théorème de Neyman-Pearson, calculer la statistique  $T_n$  du test le plus puissant et indiquer la région critique de ce test. On retiendra pour  $T_n$  la fonction seule des observations.
- (2pts) Montrer que la loi de  $Y_i = \frac{2}{\theta} X_i^3$  est une loi du chi-deux à 2 degrés de liberté. Montrer que si  $Z$  et  $T$  sont deux variables aléatoires indépendantes suivant des lois du chi-deux à  $n_1$  et  $n_2$  degrés de liberté (i.e.,  $Z \sim \chi_{n_1}^2$  et  $T \sim \chi_{n_2}^2$ ), alors on a  $Z + T \sim \chi_{n_1+n_2}^2$ . En déduire la loi de  $\frac{2}{\theta} T_n$ .
- (1pt) En utilisant les résultats de la question précédente, exprimer le seuil du test de Neyman-Pearson en fonction du risque de première espèce  $\alpha$  et de l'inverse de la fonction de répartition d'une loi du chi-deux dont on prendra soin de déterminer le nombre de degrés de liberté. On notera  $F_\nu$  la fonction de répartition d'une loi du chi-deux à  $\nu$  degrés de liberté et  $F_\nu^{-1}$  son inverse.
- (1pt) Déterminer la puissance du test en fonction du seuil du test de Neyman-Pearson, de  $\theta_1$  et de  $F_\nu$ , où  $\nu$  est le nombre de degrés de liberté trouvé à la question précédente.
- (2pts) Déterminer les courbes COR associées à ce test et analyser leur comportement en fonction de  $\theta_0$  et  $\theta_1$ .
- (2pts) On désire vérifier que les observations  $x_1, \dots, x_n$  suivent la loi de densité  $p(x_i; \theta)$  avec  $\theta = 1$  à l'aide d'un test d'un Kolmogorov. Rappeler l'expression de la statistique de ce test (en fonction des valeurs de la fonction de répartition de la loi de densité  $p(x; \theta = 1)$  aux points  $x_{(i)}$  notées  $F_\theta(x_{(i)})$ , où  $(x_{(1)}, x_{(2)}, \dots, x_{(n)})$  est la statistique d'ordre de l'échantillon  $(x_1, \dots, x_n)$ ). Quelle est la région critique de ce test ? Qu'appelle-t-on statistique d'ordre de l'échantillon  $(x_1, \dots, x_n)$  ? Comment calculer la valeur du seuil à partir de l'inverse de la fonction de répartition de la loi de Kolmogorov ?

## LOIS DE PROBABILITÉ CONTINUES

m : moyenne       $\sigma^2$  : variance      F. C. : fonction caractéristique

LOI	Densité de probabilité	m	$\sigma^2$	F. C.
Uniforme	$f(x) = \frac{1}{b-a}$ $x \in ]a, b[$	$\frac{a+b}{2}$	$\frac{(b-a)^2}{12}$	$\frac{e^{itb} - e^{ita}}{it(b-a)}$
Gamma $\mathcal{G}(\nu, \theta)$	$f(x) = \frac{\theta^\nu}{\Gamma(\nu)} e^{-\theta x} x^{\nu-1}$ $\theta > 0, \nu > 0$ $x \geq 0$ avec $\Gamma(n+1) = n! \forall n \in \mathbb{N}$	$\frac{\nu}{\theta}$	$\frac{\nu}{\theta^2}$	$\frac{1}{(1 - i\frac{t}{\theta})^\nu}$
Inverse gamma $\mathcal{IG}(\nu, \theta)$	$f(x) = \frac{\theta^\nu}{\Gamma(\nu)} e^{-\frac{\theta}{x}} \frac{1}{x^{\nu+1}}$ $\theta > 0, \nu > 0$ $x \geq 0$ avec $\Gamma(n+1) = n! \forall n \in \mathbb{N}$	$\frac{\theta}{\nu-1}$ si $\nu > 1$	$\frac{\theta^2}{(\nu-1)^2(\nu-2)}$ si $\nu > 2$	(*)
Première loi de Laplace	$f(x) = \frac{1}{2} e^{- x }, \quad x \in \mathbb{R}$	0	2	$\frac{1}{1+t^2}$
Normale univariée $\mathcal{N}(m, \sigma^2)$	$f(x) = \frac{1}{\sigma\sqrt{2\pi}} e^{-\frac{(x-m)^2}{2\sigma^2}}, \quad x \in \mathbb{R}$	m	$\sigma^2$	$e^{imt - \frac{\sigma^2 t^2}{2}}$
Normale multivariée $\mathcal{N}_p(\mathbf{m}, \Sigma)$	$f(x) = K e^{-\frac{1}{2}(\mathbf{x}-\mathbf{m})^T \Sigma^{-1}(\mathbf{x}-\mathbf{m})}$ $K = \frac{1}{\sqrt{(2\pi)^p \det(\Sigma)}}$ $x \in \mathbb{R}^p$	$\mathbf{m}$	$\Sigma$	$e^{i\mathbf{u}^T \mathbf{m} - \frac{1}{2} \mathbf{u}^T \Sigma \mathbf{u}}$
Khi <sub>2</sub> $\chi_\nu^2$ $\Gamma(\frac{1}{2}, \frac{\nu}{2})$	$f(x) = k e^{-\frac{x}{2}} x^{\frac{\nu}{2}-1}$ $k = \frac{1}{2^{\frac{\nu}{2}} \Gamma(\frac{\nu}{2})}$ $\nu \in \mathbb{N}^*, x \geq 0$	$\nu$	$2\nu$	$\frac{1}{(1-2it)^{\frac{\nu}{2}}}$
Cauchy $c_{\lambda, \alpha}$	$f(x) = \frac{1}{\pi\lambda \left(1 + \left(\frac{x-\alpha}{\lambda}\right)^2\right)}$ $\lambda > 0, \alpha \in \mathbb{R}$	(-)	(-)	$e^{i\alpha t - \lambda t }$
Beta $B(a, b)$	$f(x) = k x^{a-1} (1-x)^{b-1}$ $k = \frac{\Gamma(a+b)}{\Gamma(a)\Gamma(b)}$ $a > 0, b > 0$ $x \in ]0, 1[$ avec $\Gamma(n+1) = n! \forall n \in \mathbb{N}$	$\frac{a}{a+b}$	$\frac{ab}{(a+b)^2(a+b+1)}$	(*)

## LOIS DE PROBABILITÉ DISCRÈTES

$m$  : moyenne     $\sigma^2$  : variance    **F. C.** : fonction caractéristique

$p_k = P[X = k]$      $p_{1,\dots,m} = P[X_1 = k_1, \dots, X_m = k_m]$

LOI	Probabilités	$m$	$\sigma^2$	F. C.
Uniforme	$p_k = \frac{1}{n}$ $k \in \{1, \dots, n\}$	$\frac{n+1}{2}$	$\frac{n^2-1}{12}$	$\frac{e^{it}(1 - e^{itn})}{n(1 - e^{it})}$
Bernoulli	$p_1 = P[X = 1] = p$ $p_0 = P[X = 0] = q$ $p \in [0, 1]$ $q = 1 - p$	$p$	$pq$	$pe^{it} + q$
Binomiale $B(n, p)$	$p_k = C_n^k p^k q^{n-k}$ $p \in [0, 1]$ $q = 1 - p$ $k \in \{0, 1, \dots, n\}$	$np$	$npq$	$(pe^{it} + q)^n$
Binomiale négative	$p_k = C_{n+k-1}^{k-1} p^{n-k} q^k$ $p \in [0, 1]$ $q = 1 - p$ $k \in \mathbb{N}$	$n \frac{q}{p}$	$n \frac{q}{p^2}$	$\left(\frac{p}{1 - qe^{it}}\right)^n$
Multinomiale	$p_{1,\dots,m} = \frac{n!}{k_1! \dots k_m!} p_1^{k_1} \dots p_m^{k_m}$ $p_j \in [0, 1]$ $q_j = 1 - p_j$ $k_j \in \{0, 1, \dots, n\}$ $\sum_{j=1}^m k_j = n$ $\sum_{j=1}^m p_j = 1$	$np_j$	Variance : $np_j q_j$ Covariance : $-np_j p_k$	$\left(\sum_{j=1}^m p_j e^{it}\right)^n$
Poisson $P(\lambda)$	$p_k = e^{-\lambda} \frac{\lambda^k}{k!}$ $\lambda > 0$ $k \in \mathbb{N}$	$\lambda$	$\lambda$	$\exp[\lambda(e^{it} - 1)]$
Géométrique	$p_k = pq^{k-1}$ $p \in [0, 1]$ $q = 1 - p$ $k \in \mathbb{N}^*$	$\frac{1}{p}$	$\frac{q}{p^2}$	$\frac{pe^{it}}{1 - qe^{it}}$