

---

EXAMEN STATISTIQUE - 1MF2E

Vendredi 8 mars 2019

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

---

**Exercice 1 : Estimation (8 points)**

On considère  $n$  variables aléatoires indépendantes  $X_1, \dots, X_n$  suivant la même loi normale  $\mathcal{N}(\mu, \sigma_1^2)$  et  $m$  variables aléatoires  $Y_1, \dots, Y_m$  suivant la même loi normale  $\mathcal{N}(\mu, \sigma_2^2)$ , où  $\mu \in \mathbb{R}$  est un paramètre inconnu et  $\sigma_1^2, \sigma_2^2$  sont deux paramètres connus. On supposera de plus que les vecteurs  $(X_1, \dots, X_n)^T$  et  $(Y_1, \dots, Y_m)^T$  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  $(X_1, \dots, X_n)^T$  sont obtenues par un premier capteur dont l'incertitude dépend de la variance  $\sigma_1^2$  et où  $(Y_1, \dots, Y_m)^T$  sont obtenues par un second capteur dont l'incertitude dépend de la variance  $\sigma_2^2$ . L'objectif de cet exercice est d'étudier des estimateurs de  $\mu$  basés sur les vecteurs  $(X_1, \dots, X_n)^T$  et  $(Y_1, \dots, Y_m)^T$ .

1. On appelle vraisemblance conjointe de ces deux ensembles d'observations le produit des vraisemblances des deux échantillons  $(X_1, \dots, X_n)^T$  et  $(Y_1, \dots, Y_m)^T$  notée  $L(\mathbf{x}, \mathbf{y}; \mu)$  avec  $\mathbf{x} = (x_1, \dots, x_n)$  et  $\mathbf{y} = (y_1, \dots, y_m)$ . Montrer que cette vraisemblance admet un unique maximum global pour une valeur de  $\mu$  que l'on déterminera. En déduire l'estimateur du maximum de vraisemblance (conjointe) du paramètre  $\mu$  noté  $\hat{\mu}_{MV}$  en fonction des variables  $X_i$  et  $Y_j$  et des paramètres  $\sigma_1^2$  et  $\sigma_2^2$ .

2. Montrer que

$$\hat{\mu}_{MV} = \alpha \bar{X} + (1 - \alpha) \bar{Y}$$

avec  $\bar{X} = \frac{1}{n} \sum_{i=1}^n X_i$ ,  $\bar{Y} = \frac{1}{m} \sum_{i=1}^m Y_i$ , et où  $\alpha \in ]0, 1[$  est un paramètre qu'on exprimera en fonction de  $n, m, \sigma_1^2$  et  $\sigma_2^2$ . L'estimateur  $\hat{\mu}_{MV}$  est-il sans biais ? Déterminer la variance de  $\hat{\mu}_{MV}$  et montrer qu'elle tend vers 0 lorsque  $n = m$  et que  $n$  tend vers l'infini.

3. Déterminer la borne de Cramér-Rao pour un estimateur non biaisé du paramètre  $\mu$  à partir de l'observation des variables  $(X_1, \dots, X_n)^T$  et  $(Y_1, \dots, Y_m)^T$ . L'estimateur  $\hat{\mu}_{MV}$  est-il l'estimateur efficace du paramètre  $\mu$  ?
4. En comparant les expressions des bornes de Cramér-Rao pour  $\sigma_1^2 = \sigma_2^2 = \sigma^2$  et pour  $\sigma_1^2 = 2\sigma_2^2 = \sigma^2$ , déterminer quelle situation est la plus favorable pour l'estimation du paramètre  $\mu$ .

**Exercice 2 : Test Statistique (7 points)**

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

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

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

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

1. 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.

2. Vérifier 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  $n_Z$  et  $n_T$  degrés de liberté, c'est-à-dire,  $Z \sim \chi_{n_Z}^2$  et  $T \sim \chi_{n_T}^2$ , alors on a  $Z + T \sim \chi_{n_Z+n_T}^2$ .
3. 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  $F_\nu(x)$  la fonction de répartition d'une loi du chi-deux à  $\nu$  degrés de liberté.
4. 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.
5. Déterminer les courbes COR associées à ce test et analyser leur comportement en fonction de  $\theta_0$  et  $\theta_1$ .

### Exercice 3 : Test d'adéquation (5 points)

Pour tester si une variable  $X$  possède la densité

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

où  $\theta > 0$  est un paramètre connu, on considère un échantillon  $(X_1, \dots, X_n)$  de la var  $X$  et teste si la loi de  $Y = \frac{2}{\theta} X^3$  est une loi du chi-deux à deux degrés de liberté. En d'autres termes, on considère le test d'hypothèses suivant :

$$\begin{aligned} H_0 & : Y \sim \chi_2^2 \\ H_1 & : \text{non } H_0 \end{aligned}$$

Malheureusement, on n'a pu obtenir que  $n = 5$  réalisations de la variable aléatoire  $X$  qui donnent les valeurs suivantes de  $Y$  :

$y_1 = 1.1$	$y_2 = 2.3$	$y_3 = 5.4$	$y_4 = 7.8$	$y_5 = 10.2$
-------------	-------------	-------------	-------------	--------------

On décide de faire un test de Kolmogorov. Un logiciel de statistique (comme Matlab) nous a permis de calculer les valeurs de la fonction de répartition aux points  $y_i$  :

$F(y_1) = 0.42$	$F(y_2) = 0.68$	$F(y_3) = 0.93$	$F(y_4) = 0.98$	$F(y_5) = 0.99$
-----------------	-----------------	-----------------	-----------------	-----------------

Effectuer un test de Kolmogorov avec les risques de première espèce  $\alpha = 0.01$  et  $\alpha = 0.05$  (les seuils associés à ces valeurs de  $\alpha$  sont  $S_{0.01} = 0.352$  et  $S_{0.05} = 0.294$ ) et répondre aux questions suivantes

1. Quelle est la statistique du test de Kolmogorov ?
2. Comment conclure au vu des résultats des tests précédents ?
3. Expliquer pourquoi on a  $S_{0.05} < S_{0.01}$ .
4. Peut-on calculer la puissance du test ? Pourquoi ?

## 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 $\Gamma(\theta, \nu)$	$f(x) = \frac{\theta^\nu}{\Gamma(\nu)} e^{-\theta x} x^{\nu-1}$ $\theta > 0, \nu > 0$ $x \geq 0$	$\frac{\nu}{\theta}$	$\frac{\nu}{\theta^2}$	$\frac{1}{(1 - i\frac{t}{\theta})^\nu}$
Inverse gamma IG( $\theta, \nu$ )	$f(x) = \frac{\theta^\nu}{\Gamma(\nu)} e^{-\frac{\theta}{x}} \frac{1}{x^{\nu+1}}$ $\theta > 0, \nu > 0$ $x \geq 0$	$\frac{\theta}{\nu-1}$ si $\nu > 1$	$\frac{\theta^2}{(\nu-1)^2(\nu-2)}$ si $\nu > 2$	(*)
Première loi de Laplace	$f(x) = \frac{1}{2} e^{- x }$	0	2	$\frac{1}{1+t^2}$
Normale $\mathcal{N}(m, \sigma^2)$	$f(x) = \frac{1}{\sigma\sqrt{2\pi}} e^{-\frac{(x-m)^2}{2\sigma^2}}$	m	$\sigma^2$	$e^{imt - \frac{\sigma^2 t^2}{2}}$
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	$f(x) = kx^{a-1} (1-x)^{b-1}$ $k = \frac{\Gamma(a+b)}{\Gamma(a)\Gamma(b)}$ $a > 0, b > 0, x \in ]0, 1[$	$\frac{a}{a+b}$	$\frac{ab}{(a+b)^2(a+b+1)}$	(*)

## 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	$p_k = C_{n+k-1}^{n-1} p^n q^k$ $p \in [0, 1]$ $q = 1 - p$ $k \in \mathbb{N}$	$n \frac{q}{p}$	$n \frac{q}{p^2}$	$\left(\frac{p}{1 - qe^{it}}\right)^n$
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	$p_k = pq^{k-1}$ $p \in [0, 1]$ $q = 1 - p$ $k \in \mathbb{N}^*$	$\frac{1}{p}$	$\frac{q}{p^2}$	$\frac{pe^{it}}{1 - qe^{it}}$