

### Correction de l'examen d'avril 2013

Les documents ne sont pas autorisés. Durée de l'épreuve : 3 heures.

**Seulement les réponses qui ne sont pas des questions de cours sont développées**  
**Questions de cours**

1. Donner la définition d'un modèle statistique régulier.
2. Donner l'énoncé et la preuve du théorème de Cramer-Rao.
3. Soit  $X_1, \dots, X_n$  un  $n$ -échantillon de la loi de Bernoulli  $B(\vartheta)$ .
  - (a) Calculer l'information de Fisher et montrer que  $\bar{X}_n$  est efficace.
  - (b) Rappeler l'inégalité de Hoeffding pour des variables aléatoires qui suivent une loi de Bernoulli et en donner la preuve.
  - (c) Utiliser l'inégalité de Hoeffding pour construire un intervalle de confiance au niveau de confiance  $\alpha$  pour  $\vartheta$ .

#### Exercice 1

Soit  $X_1, \dots, X_n$  un  $n$ -échantillon de la loi de  $\vartheta + Y$  où  $Y$  suit une loi exponentielle de paramètre 1,  $\vartheta \in \Theta = ]0, \infty[$ .

1. Montrer que la variable  $X_1$  admet une densité de probabilité qui est donnée par

$$f_{\vartheta}(x) = e^{-(x-\vartheta)} 1_{x>\vartheta}.$$

**Solution :** Soit  $g$  une fonction test (borelienne, positive), alors

$$E_{\vartheta}(g(X_1)) = E(g(\vartheta + Y)) = \int_0^{\infty} e^{-t} g(\vartheta + t) dt = \int_{\vartheta}^{\infty} e^{-(x-\vartheta)} g(x) dx = \int_0^{\infty} g(x) f_{\vartheta}(x) dx,$$

ou nous avons fait un changement de variables  $x = t + \vartheta$ .

2. Soit  $\bar{X}_n$  la moyenne empirique. Déterminer la constante  $c$  telle que

$$\bar{X}_n - c \text{ est un estimateur sans biais de } \vartheta.$$

**Nous avons que**  $E_{\vartheta}(\bar{X}_n) = E_{\vartheta}(X_1) = E(\vartheta + Y) = \vartheta + E(Y) = \vartheta + 1$ , **donc il faut prendre**  $c = 1$ .

3. Un autre estimateur possible est  $\hat{\vartheta}_n = \min\{X_1, \dots, X_n\}$ . (Pourquoi ?) Montrer, **sans faire le calcul**, que  $\hat{\vartheta}_n$  est un estimateur qui est biaisé.

**Solution :**  $X_i \stackrel{\mathcal{L}}{=} \vartheta + Y > \vartheta$  **p.s. (car  $Y$  suit une loi exponentielle).** Cela implique que  $\hat{\vartheta}_n > \vartheta$  **p.s., autrement dit :**

$$\hat{\vartheta}_n - \vartheta > 0.$$

Supposons maintenant que l'estimateur soit sans biais, donc

$$E_{\vartheta}(\hat{\vartheta}_n - \vartheta) = 0,$$

alors cela implique que

$$\hat{\vartheta}_n - \vartheta = 0 \quad p.s.$$

(une variable positive qui a espérance nulle doit elle même être nulle p.s.), ce qui est une contradiction.

4. Montrer que  $\hat{\vartheta}_n$  converge en probabilité vers  $\vartheta$  lorsque  $n \rightarrow \infty$ .

**Solution : Comme  $\hat{\vartheta}_n \geq \vartheta$ ,**

$$P_{\vartheta}(|\hat{\vartheta}_n - \vartheta| \geq \epsilon) = P_{\vartheta}(\hat{\vartheta}_n \geq \vartheta + \epsilon) = P_{\vartheta}(\forall i = 1, \dots, n : X_i \geq \vartheta + \epsilon) = (P_{\vartheta}(X_1 \geq \vartheta + \epsilon))^n.$$

**Or,**

$$P_{\vartheta}(X_1 \geq \vartheta + \epsilon) = P(Y \geq \epsilon) = e^{-\epsilon}.$$

**Donc**

$$P_{\vartheta}(|\hat{\vartheta}_n - \vartheta| \geq \epsilon) = e^{-\epsilon n} \rightarrow 0$$

**lorsque  $n \rightarrow \infty$ .**

5. On veut maintenant construire un intervalle de confiance en utilisant l'estimateur  $\hat{\vartheta}_n$ . Lequel des intervalles suivants est préférable (donnez une justification de votre réponse)?

$$I_1 = [\hat{\vartheta}_n - \delta, \hat{\vartheta}_n + \delta]$$

ou

$$I_2 = [\hat{\vartheta}_n - \delta, \hat{\vartheta}_n]$$

ou

$$I_3 = [\hat{\vartheta}_n, \hat{\vartheta}_n + \delta],$$

pour un  $\delta > 0$  à choisir.

**Solution : Le deuxième : car  $\hat{\vartheta}_n$  est toujours plus grand que le vrai paramètre, donc ce n'est pas la peine de considérer des valeurs plus grandes que  $\hat{\vartheta}_n$ .**

6. Choisir un des intervalles et construire un intervalle de confiance (théorique) au niveau  $\alpha$ , en se basant sur l'estimation du point 4 (c'est-à-dire déterminer  $\delta$  en fonction de  $n$  et de  $\alpha$ ).

**Solution : On choisit  $I_2$ . Donc nous voulons contrôler**

$$1 - \alpha = P_{\vartheta}(\vartheta \notin I_2) = P_{\vartheta}(\vartheta < \hat{\vartheta}_n - \delta) = P_{\vartheta}(\hat{\vartheta}_n > \vartheta + \delta) = e^{-\delta n},$$

**ou nous avons utilisé point 4. Donc il faut choisir**

$$\delta = -\frac{1}{n} \log(1 - \alpha).$$

## Exercice 2

Un appareil de guidage radar récolte des informations dans une direction de l'espace. Celles-ci se présentent sous la forme d'un vecteur d'observation  $(Z_1, \dots, Z_n)$  où les  $Z_i$  sont *i.i.d* et de loi  $\mathcal{N}(0, \sigma^2)$  s'il n'y a pas d'obstacle et de loi  $\mathcal{N}(m, \sigma^2)$  s'il y en a un, où  $\sigma^2$  est connu. Si le radar détecte un obstacle, on recalcule la trajectoire, sinon on ne change rien. On souhaite tester

$H_0$  : “ $m \neq 0$ ” contre  $H_1$  : “ $m = 0$ ”. Comment interpréter dans ce cas les risques de première et de deuxième espèce ?

**Solution : Erreur de première espèce: en réalité il y a un obstacle, mais on ne le découvre pas.**

**Erreur de deuxième espèce : en réalité il n’y a pas d’obstacle, mais le test en découvre un, et donc on recalcule la trajectoire inutilement.**

### Exercice 3

Une société d’assurances a comptabilisé parmi ses 500 assurés ceux qui ont déclaré un ou plusieurs sinistres au cours de l’année écoulée. Cela a donné le tableau suivant :

- 0 sinistre : 171 assurés,
- 1 sinistre : 202 assurés,
- 2 sinistres : 80 assurés,
- 3 sinistres : 36 assurés,
- $\geq 4$  sinistres : 11 assurés.

Nous souhaitons tester l’hypothèse  $H_0$  : “la répartition des assurés suit une loi de Poisson de paramètre 1” en utilisant un test du  $\chi^2$  d’adéquation.

1. Rappeler le cadre général du test du  $\chi^2$  d’adéquation et expliquer intuitivement pourquoi il doit “marcher”.

**Solution : On observe un  $n$ -échantillon d’une loi inconnue à valeurs dans un espace  $E$ . On partitionne**

$$E = E_1 \cup \dots \cup E_q$$

**et on compte le nombre d’observations qui tombent dans chaque  $E_i : N_n^i$ . On voudrait tester si la loi du  $n$ -échantillon est une loi précise  $\mu_0$  ou pas. Pour ce faire on introduit**

$$p_i = \mu_0(E_i), 1 \leq i \leq q$$

et

$$D_n = \sum_{i=1}^q \frac{(N_n^i - np_i)^2}{np_i}.$$

Sous la loi  $\mu_0$ , par le TCL,  $D_n$  va converger en loi vers une variable aléatoire limite qui est finie (et en fait : qui suit une loi du chi-deux à  $q - 1$  ddl). Par contre, si ce n’est pas la loi  $\mu_0$  qui a engendré les données, en général,  $D_n$  va exploser (converger vers  $\infty$ ) - car les  $p_i$  ne sont pas les bonnes quantités pour centraliser, c’est-à-dire ce ne sont pas les bonnes espérances. Donc le test va se décider pour  $H_1 =$  “la loi n’est pas  $\mu_0$ ” si et seulement si  $D_n > K$ . On choisit  $K$  tel que

$$P(U > K) = \alpha,$$

avec  $U \sim \chi^2(q - 1)$ .

2. Donner  $q$  et la partition  $E_1, \dots, E_q$  dans le cadre du présent exercice, ainsi que les valeurs  $p_1, \dots, p_q$ .

**Solution :**  $E = \{0, 1, \dots\}$ ,  $E_1 = \{0\}$ ,  $E_2 = \{1\}$ ,  $\dots$ ,  $E_4 = \{3\}$ ,  $E_5 = \{n : n \geq 4\}$ . **Donc**  $q = 5$ . **Les valeurs  $p_1, \dots, p_5$  sont données par la loi de Poisson avec paramètre 1 :**

$$p_1 = e^{-1}, p_2 = e^{-1}, p_3 = e^{-1} \times \frac{1}{2}, p_4 = e^{-1} \times \frac{1}{6}, p_5 = 1 - (p_1 + \dots + p_4) = 1 - e^{-1} \times 2, \bar{6}.$$

3. Calculer la statistique du test et conclure.

**La statistique du test est donnée par**

$$D_n = \frac{(171 - 500 \cdot e^{-1})^2}{500e^{-1}} + \frac{(202 - 500 \cdot e^{-1})^2}{500e^{-1}} + \frac{(80 - 250 \cdot e^{-1})^2}{250e^{-1}} + \frac{(36 - 250 \cdot \frac{1}{3} \cdot e^{-1})^2}{250 \cdot \frac{1}{3} e^{-1}} + \frac{(11 - 500 \cdot (1 - 2, \bar{6}e^{-1}))^2}{500(1 - 2, \bar{6}e^{-1})}.$$

**Un calcul pénible donne**

$$D_n \approx 5,41.$$

**Nous avons  $q - 1 = 4$  et donc  $K = 9,4877$ . Donc :  $D_n \leq K$ , le test ne se décide donc pas pour  $H_1$  : la répartition des assurés est donnée par une loi de Poisson de paramètre 1.**