

Université d'Orléans - Licence Economie et Gestion Statistique

C. Hurlin. Correction de l'Examen de Décembre 2008

Exercice 1 Barème : 15 points. Test Paramétrique et Lemme de Neyman Pearson

Partie I : Test d'hypothèses simples (8 points)

Question 1 (1 point) C'est l'hypothèse dans laquelle le fabricant a le plus confiance et qu'il lui importe le plus.

Question 2 (1 point) On sait que, pour $N = 10$:

$$L(X_1, \dots, X_{10}, m_0) = \left(\frac{1}{\sigma\sqrt{2\pi}}\right)^N \exp\left[-\frac{1}{2}\sum_{i=1}^N\left(\frac{X_i - m_0}{\sigma}\right)^2\right] \quad 0.5 \text{ point} \quad (1)$$

$$L(X_1, \dots, X_{10}, m_1) = \left(\frac{1}{\sigma\sqrt{2\pi}}\right)^N \exp\left[-\frac{1}{2}\sum_{i=1}^N\left(\frac{X_i - m_1}{\sigma}\right)^2\right] \quad (2)$$

Il s'ensuit immédiatement que :

$$\frac{L(X_1, \dots, X_{10}, m_0)}{L(X_1, \dots, X_{10}, m_1)} = \exp\left[\frac{1}{2\sigma^2}\left(\sum_{i=1}^{10}(X_i - m_1)^2 - \sum_{i=1}^{10}(X_i - m_0)^2\right)\right] \quad 0.5 \text{ point} \quad (3)$$

Question 3 (1 point) On sait que selon le lemme de Neyman Pearson, la région critique du test UPP de niveau α est telle que :

$$W = \left\{ X_1, \dots, X_{10} \mid \frac{L(X_1, \dots, X_{10}, m_0)}{L(X_1, \dots, X_{10}, m_1)} < K \right\} \quad (4)$$

où K désigne une constante déterminée par le risque de première espèce α . Or, :

$$\frac{L(X_1, \dots, X_{10}, m_0)}{L(X_1, \dots, X_{10}, m_1)} < K \quad (5)$$

$$\iff \exp\left[\frac{1}{2}\left(\sum_{i=1}^N(X_i - m_1)^2 - \sum_{i=1}^N(X_i - m_0)^2\right)\right] < K \quad 0.5 \text{ point} \quad (6)$$

$$\iff \sum_{i=1}^N X_i^2 - 2m_1 X_i + m_1^2 - X_i^2 + 2m_0 X_i - m_0^2 < 2 \log(K) \quad (7)$$

$$\iff 2 \sum_{i=1}^N (m_0 - m_1) X_i < 2 \log(K) + N(m_0^2 - m_1^2) \quad (8)$$

Ici, on a $m_0 - m_1 = 300 - 290 > 0$, dès lors on obtient au final :

$$\sum_{i=1}^N X_i < B \quad (9)$$

avec $B = [2 \log(K) + N(m_0^2 - m_1^2)] / [2(m_0 - m_1)]$ ou encore

$$\bar{X}_N < A \quad 0.5 \text{ point} \quad (10)$$

où $A = B/N$. La région critique W du test UPP au sens de Neyman Pearson est de la forme

$$W = \{X_1, \dots, X_{10} \mid \bar{X}_N < A\} \quad (11)$$

Remarque : attribuer les points même si les termes de droite des inégalités ne sont pas spécifiés.

Question 4 (1 point) Par définition du risque de première espèce :

$$\alpha = \Pr[W \mid H_0] \quad (12)$$

Ou encore :

$$\alpha = \Pr[\bar{X}_N < A \mid m = m_0] \quad (13)$$

On sait que sous H_0 , la moyenne empirique suit une loi normale centrée sur m_0 :

$$\bar{X}_N \sim N\left(m_0, \frac{\sigma^2}{N}\right) \quad (14)$$

Par conséquent :

$$\alpha = \Pr\left[\frac{\bar{X}_N - m_0}{\sigma/\sqrt{N}} < \frac{A - m_0}{\sigma/\sqrt{N}} \mid \frac{\bar{X}_N - m_0}{\sigma/\sqrt{N}} \sim N(0, 1)\right] \quad (15)$$

ce qui implique que :

$$\alpha = \Phi\left(\frac{A - m_0}{\sigma/\sqrt{N}}\right) \quad (16)$$

où $\Phi(\cdot)$ désigne la fonction de répartition de loi normale centrée réduite. On en déduit donc au final que :

$$A = m_0 + \Phi^{-1}(\alpha) \frac{\sigma}{\sqrt{N}} \quad 0.5 \text{ point} \quad (17)$$

AN :

$$A = 300 - 1.64 * \frac{5}{\sqrt{10}} = 297.39 \quad 0.5 \text{ point} \quad (18)$$

Question 5 (1 point) La région critique du test UPP au seuil de 5% est définie par :

$$W = \{X_1, \dots, X_{10} \mid \bar{X}_N < 297.39\} \quad (19)$$

Dans le cas de ce lot, la moyenne empirique égale à 296 grammes figure dans la région critique. Donc pour un seuil de risque de première espèce de 5% on rejette l'hypothèse nulle que $m = 300$ grammes. La marchandise est donc non conforme et doit être détruite.

Question 6 (1.5 point) La puissance du test est :

$$\text{Puissance} = 1 - \beta = \Pr[W \mid H_1] \quad (20)$$

D'où l'on tire que :

$$\text{Puissance} = \Pr\left[\frac{\bar{X}_N - m_1}{\sigma/\sqrt{N}} < \frac{A - m_1}{\sigma/\sqrt{N}} \mid \frac{\bar{X}_N - m_1}{\sigma/\sqrt{N}} \sim N(0, 1)\right] \quad (21)$$

$$\Leftrightarrow \text{Puissance} = \Phi \left(\frac{A - m_1}{\sigma/\sqrt{N}} \right) \quad 0.5 \text{ point} \quad (22)$$

AN :

$$\text{Puissance} = \Phi \left(\frac{297.39 - 295}{5/\sqrt{10}} \right) = \Phi(1.51) = 0.93 \quad 0.5 \text{ point} \quad (23)$$

Ce qui signifie que sur 100 lots défectueux, ce test permet de rejeter l'hypothèse nulle de validité du lot dans 93 cas (0.5 point).

Question 7 (1.5 points) On a donc :

$$\text{Puissance} = \Phi \left(\frac{A - m_1}{\sigma/\sqrt{N}} \right) = 0.95 \quad (24)$$

$$\Leftrightarrow \frac{A - m_1}{\sigma/\sqrt{N}} = \Phi^{-1}(0.95) \quad (25)$$

$$\Leftrightarrow N = \left[\frac{\Phi^{-1}(0.95) \sigma}{(A - m_1)} \right]^2 \quad 1 \text{ point} \quad (26)$$

AN :

$$N = \left[\frac{\Phi^{-1}(0.95) * 5}{(297.39 - 295)} \right]^2 = 11.75 \quad (27)$$

Donc N doit être supérieure à 12 unités (0.5 point).

Partie II : Test d'hypothèse simple contre hypothèse multiple (7 points)

Question 1 (1 point) Nous avons montré que la région critique du test UPP d'hypothèse simple contre hypothèse simple $H_0 : m = 300$ contre $H_1 : m = 295$ ne dépendait pas de la valeur explicite de m_1 . Par conséquent, il existe un test UPP pour $H_0 : m = 300$ contre $H_1 : m < 300$ et la région critique de ce test est identique à celle du test d'hypothèse simple :

$$W = \{ X_1, \dots, X_{10} \mid \bar{X}_N < 297.39 \} \quad (28)$$

Question 2 (2 points) Dans le cas de ce test unilatéral, la puissance est une fonction de la valeur de m sous H_1 :

$$P(m) = \Phi \left(\frac{A - m}{\sigma/\sqrt{N}} \right) \quad m < 300 \quad (29)$$

Pour $m = m_0 = 300$, par définition on retrouve le niveau de risque I :

$$P(300) = \alpha = 0.05 \quad 0.5 \text{ point} \quad (30)$$

Pour $m = 295$, nous avons montré que :

$$P(295) = 0.93 \quad (31)$$

Enfin, on montre que :

$$P(298) = \Phi \left(\frac{297.39 - 298}{5/\sqrt{10}} \right) = \Phi(-0.37) = 0.35 \quad 0.5 \text{ point} \quad (32)$$

$$P(290) = \Phi \left(\frac{297.39 - 290}{5/\sqrt{10}} \right) = \Phi(4.67) = 1 \quad 0.5 \text{ point} \quad (33)$$

plus 0.5 point pour le graphique de la courbe de puissance.

Question 3 (2 point) La région d'acceptation du test bilatéral de niveau α correspond à l'intersection des régions d'acceptation des tests unilatéraux de niveau $\alpha/2$ (0.5 point). Donc on a :

$$\overline{W} = \{X_1, \dots, X_{10} \mid A < \overline{X}_N < B\} \quad (34)$$

où les constantes A et B vérifient (0.5 point) :

$$A = m_0 + \Phi^{-1}\left(\frac{\alpha}{2}\right) \frac{\sigma}{\sqrt{N}} \quad (35)$$

$$B = m_0 + \Phi^{-1}\left(1 - \frac{\alpha}{2}\right) \frac{\sigma}{\sqrt{N}} \quad (36)$$

AN (0.5 point) :

$$A = 300 + \Phi^{-1}\left(\frac{0.05}{2}\right) \frac{5}{\sqrt{10}} = 296.90 \quad (37)$$

$$B = 300 + \Phi^{-1}\left(1 - \frac{0.05}{2}\right) \frac{5}{\sqrt{10}} = 303.09 \quad (38)$$

Donc la région critique du test bilatéral est :

$$W = \{X_1, \dots, X_{10} \mid \overline{X}_N < 296.90 \text{ ou } \overline{X}_N > 303.09\} \quad 0.5 \text{ point} \quad (39)$$

Si on observe une moyenne empirique de 296 grammes pour un lot, pour un risque de première espèce de 5%, on rejette l'hypothèse nulle de validité de la production.

Question 4 (1 point) La puissance est définie par :

$$\begin{aligned} P(m) &= \Pr[W \mid H_1] \\ &= 1 - \Pr[296.90 < \overline{X}_N < 303.09 \mid H_1] \quad 0.5 \text{ point} \end{aligned} \quad (40)$$

D'où l'on tire que :

$$P(m) = 1 - \Phi\left(\frac{303.09 - m}{\sigma/\sqrt{N}}\right) + \Phi\left(\frac{296.90 - m}{\sigma/\sqrt{N}}\right) \quad 0.5 \text{ point} \quad (41)$$

Exercice 2 Test d'Indépendance : Relation Salaire / Diplôme (à partir d'un examen de Mme Bessec, Université Paris IX Dauphine). Barème : 4 points. (1 point pour tableau effectif théorique + 1 statistique + 1 seuil et conclusion)

- Tableau des effectifs théoriques

Si les 2 variables sont indépendantes, $p_{ij} = p_i \times p_j = \frac{n_{i.}}{n} \times \frac{n_{.j}}{n} \Leftrightarrow T_{ij} = np_{ij} = \frac{n_{i.} \times n_{.j}}{n}$. D'où :

X \ Y	Bac	BEP-CAP	Sixième	Total
600-750	137	266	26	429
750-900	59	115	11	185
900-1650	29	56	5	91
Total	226	437	42	705

Tous les effectifs théoriques sont supérieurs à 4. On peut donc utiliser la loi du chi-deux pour effectuer un test d'indépendance entre les 2 variables.

- Hypothèse : H_0 : indépendance des variables X et Y
- Statistique et loi sous H_0 :

$$\Delta = \sum_i \sum_j \frac{(n_{ij} - np_{ij})^2}{np_{ij}} \xrightarrow{H_0} \chi_{(i-1)(j-1)}^2 = \chi_4^2 \text{ car } T_{ij} \geq 4 \quad \forall i, j \text{ (voir ci-dessus)}$$

- Règle de décision :

W tel que $\Delta > c$

C : CPE $\rightarrow c = \chi_{4, \alpha}^2 = 9.49$ au seuil $\alpha = 5\%$ et 7.78 au seuil $\alpha = 10\%$.

- Conclusion :

$$\text{Ici, } \Delta_{\text{obs}} = \frac{(77 - 115.01)^2}{115.01} + \dots + \frac{(2 - 5.22)^2}{5.22} = 20.02 > c \quad \forall \alpha$$

On rejette donc H_0 aux deux seuils. Les deux variables ne sont pas indépendantes. On

Exercice 3 *Test d'Adéquation : Barème : 4 points.*

Effectifs théoriques (1 point) sous $H_0 : X_i \sim P(2)$

X_i	0	1	2	3	4	5	4	7 et +	Total
$N * p_i$	13.53	27.06	27.06	18.04	9.02	3.60	1.20	0.45	100

On doit regrouper les classes 4, 5 et 7. Après regroupement, les effectifs théoriques et empiriques (1 point) sont les suivants :

X_i	0	1	2	3	4	5 et +	Total
N_i	15	25	25	12	10	13	100
$N * p_i$	13.53	27.06	27.06	18.04	9.02	5.16	100

Par conséquent la statistique du chi-deux vaut :

$$D_{(F_N, F)} = \sum_{i=1}^N \frac{(N_i - N * p_i)^2}{N * p_i} = 14.54 \quad (0.5 \text{ point})$$

Sous H_0 , on a :

$$D_{(F_N, F)} \sim \chi^2(6) \quad (0.5 \text{ point}) \quad (42)$$

Le seuil critique à 95% étant égal à 12.59, pour un risque de première espèce de 5%, on rejette l'hypothèse nulle selon laquelle la loi de X est une loi de poisson de paramètre 2 (0.5 point).