

Université d'Orléans - Licence Economie et Gestion

Statistique Mathématique

C. Hurlin. Correction de l'Examen Terminal Janvier 2008

Exercice 1 *Scoring Bancaire et Tests UPP. Barème : 13 points.*

Question 1 (1.5 point) Cette idée se traduirait sous la forme :

$$H_0 : p = p_0 \quad (0.5 \text{ point}) \quad (1)$$

$$H_1 : p = p_1 > p_0 \quad (2)$$

ou sous la forme :

$$H_0 : p = p_0 \quad (0.5 \text{ point}) \quad (3)$$

$$H_1 : p > p_0 \quad (4)$$

L'hypothèse nulle correspond à l'hypothèse selon laquelle les clients de cette catégorie ont une faible probabilité de défaut, c'est à dire qu'ils correspondent à de "bons" clients auxquels on peut accorder un prêt. L'hypothèse alternative correspond donc à l'hypothèse de "mauvais" client. L'hypothèse nulle est donc l'hypothèse pour lequel on a le plus fort coût à la renonciation (0.5 point).

Question 2 (1 point) Le risque de première espèce, noté α , correspond la probabilité de rejeter l'hypothèse de "bon" client alors que le client est bon :

$$\alpha = \Pr(\text{Rejet } p = p_0 \mid p = p_0) \quad (5)$$

La puissance correspond la probabilité de rejeter l'hypothèse de "bon" client alors que le client est effectivement un mauvais client :

$$\text{Puissance} = \Pr(\text{Rejet } p = p_0 \mid p = p_1) \quad (6)$$

Question 3 (2.5 points) Soit $Z_N = (1/N) \sum_{i=1}^N Y_i$ la fréquence empirique de défauts associé au N -échantillon $\{Y_1, \dots, Y_N\}$. On sait que les variables Y_i sont *i.i.d.* (0.5 point) avec

$$E(Y_i) = p \text{ et } V(Y_i) = p(1-p) \quad (0.5 \text{ point})$$

D'après le théorème central limite, on a :

$$\frac{Z_N - E(Z_N)}{\sqrt{V(Z_N)}} \xrightarrow[N \rightarrow \infty]{d} N(0,1) \quad (7)$$

Or, sait ici que :

$$E(Z_N) = (1/N) \sum_{i=1}^N E(Y_i) = p \quad (8)$$

$$V(Z_N) = (1/N^2) \sum_{i=1}^N V(Y_i) = \frac{p(1-p)}{N} \quad (9)$$

Donc, on a :

$$\frac{Z_N - p}{\sqrt{\frac{p(1-p)}{N}}} \xrightarrow[N \rightarrow \infty]{d} N(0,1) \quad 0.5 \text{ point} \quad (10)$$

Dès lors, le seuil critique vérifie :

$$\alpha = \Pr \left[Z_N > C \mid \frac{Z_N - p_0}{\sqrt{\frac{p_0(1-p_0)}{N}}} \xrightarrow[N \rightarrow \infty]{d} N(0, 1) \right] \quad 0.5 \text{ point} \quad (11)$$

ou encore

$$1 - \alpha = \Pr \left[\frac{Z_N - p_0}{\sqrt{\frac{p_0(1-p_0)}{N}}} < \frac{C - p_0}{\sqrt{\frac{p_0(1-p_0)}{N}}} \mid \frac{Z_N - p_0}{\sqrt{\frac{p_0(1-p_0)}{N}}} \xrightarrow[N \rightarrow \infty]{d} N(0, 1) \right] \quad (12)$$

Ainsi, si N tend vers l'infini :

$$\Phi^{-1}(1 - \alpha) = \frac{C - p_0}{\sqrt{\frac{p_0(1-p_0)}{N}}} \quad (13)$$

et donc finalement :

$$C = p_0 + \Phi^{-1}(1 - \alpha) \sqrt{\frac{p_0(1-p_0)}{N}} \quad 0.5 \text{ point} \quad (14)$$

où $\Phi(\cdot)$ désigne la fonction de répartition de la loi normale centrée réduite.

Question 4 (1 point) A partir des éléments fournis, on déduit que le seuil critique du test est égal à :

$$\begin{aligned} C &= 0.2 + \Phi^{-1}(0.9) \sqrt{\frac{0.2(1-0.2)}{100}} \\ &= 0.2 + 1.2816 * \sqrt{\frac{0.2(1-0.2)}{100}} \\ &= 0.251 \end{aligned}$$

Si l'on admet que la pertinence de la distribution asymptotique pour cet échantillon, la région critique du test est donc la suivante :

$$W = \{Y_1, \dots, Y_N \mid Z_N > 0.251\} \quad 0.5 \text{ point} \quad (15)$$

Or dans le cas de l'échantillon considéré, la réalisation de la fréquence de défaut est :

$$Z_N = \frac{1}{100} \sum_{i=1}^{100} Y_i = \frac{23}{100} = 0.23 \quad (16)$$

Donc pour un risque de première espèce de 10%, on ne peut pas rejeter H_0 . Donc on ne peut pas rejeter l'hypothèse que les individus de cette catégorie sont des bons clients : on accepte donc de leur accorder le prêt. (0.5 point).

Question 5 (1 point) La puissance du test est :

$$\begin{aligned} \text{Puissance} &= \Pr(W \mid H_1 \text{ vraie}) \\ &= \Pr \left(Z_N > C \mid \frac{Z_N - p_1}{\sqrt{\frac{p_1(1-p_1)}{N}}} \xrightarrow[N \rightarrow \infty]{d} N(0, 1) \right) \end{aligned} \quad (17)$$

Par conséquent, on a :

$$Puissance = 1 - \Phi \left(\frac{C - p_1}{\sqrt{\frac{p_1(1-p_1)}{N}}} \right) \quad 0.5 \text{ point} \quad (18)$$

AN : $C = 0.251$, $p_1 = 0.3$, $N = 100$:

$$\begin{aligned} Puissance &= 1 - \Phi(-1.0635) \\ &= 1 - 0.1438 \\ &= 0.856 \end{aligned} \quad (19)$$

Cette procédure permettrait ainsi de détecter 85,6% de "mauvais" clients. Plus précisément si les individus de la catégorie sont effectivement de "mauvais" clients, pour 100 échantillons, la procédure conduirait dans 85,6% des cas où rejet de l'hypothèse nulle de "bons" clients (0.5 point).

Question 6 (2 points) Le responsable du département des risques souhaite que la règle de décision permette d'atteindre un niveau donné de puissance, noté γ , pour un niveau donné de risque de première espèce α . Dès lors, par définition on a :

$$\gamma = 1 - \Phi \left(\frac{C - p_1}{\sqrt{\frac{p_1(1-p_1)}{N}}} \right) \quad (20)$$

ou encore :

$$1 - \gamma = \Phi \left(\frac{p_0 + \Phi^{-1}(1 - \alpha) \sqrt{\frac{p_0(1-p_0)}{N}} - p_1}{\sqrt{\frac{p_1(1-p_1)}{N}}} \right) \quad 0.5 \text{ point} \quad (21)$$

$$\Leftrightarrow \Phi^{-1}(1 - \gamma) \sqrt{\frac{p_1(1-p_1)}{N}} = p_0 - p_1 + \Phi^{-1}(1 - \alpha) \sqrt{\frac{p_0(1-p_0)}{N}} \quad (22)$$

$$\Leftrightarrow \frac{1}{\sqrt{N}} \left[\Phi^{-1}(1 - \gamma) \sqrt{p_1(1-p_1)} - \Phi^{-1}(1 - \alpha) \sqrt{p_0(1-p_0)} \right] = p_0 - p_1 \quad (23)$$

D'où finalement

$$N = \left[\frac{\Phi^{-1}(1 - \gamma) \sqrt{p_1(1-p_1)} - \Phi^{-1}(1 - \alpha) \sqrt{p_0(1-p_0)}}{p_0 - p_1} \right]^2 \quad 1 \text{ point} \quad (24)$$

Pour garantir 90% de puissance pour un niveau de risque de première espèce de 10%, il faut :

$$N = \left[\frac{\Phi^{-1}(1 - 0.9) \sqrt{0.3(1-0.3)} - \Phi^{-1}(1 - 0.1) \sqrt{0.2(1-0.2)}}{0.2 - 0.3} \right]^2 \simeq 121 \quad 0.5 \text{ point} \quad (25)$$

Question 7 (1 point) On considère à présent un test d'hypothèse simple contre hypothèse multiple unilatéral :

$$H_0 : p = 0.2 \quad (26)$$

$$H_1 : p > 0.2 \quad (27)$$

La région critique du test UPP de niveau α d'hypothèse simple $H_0 : p = p_0$ contre hypothèse simple $H_0 : p = p_1$ avec $p_1 > p_0$ ne dépend pas de la valeur explicite de p_1 . Dès lors la région critique du test UPP d'hypothèse simple $H_0 : p = p_0 = 0.2$ contre hypothèse multiple $H_0 : p > p_0$ est identique à la région critique du test simple contre simple. (0.5 point). Donc la région critique est :

$$W = \left\{ Y_1, \dots, Y_N \mid Z_N > p_0 + \Phi^{-1}(1 - \alpha) \sqrt{\frac{p_0(1 - p_0)}{N}} \right\} \quad (28)$$

AN : $N = 100$, $p_0 = 0.2$ et $\alpha = 10\%$:

$$W = \{ Y_1, \dots, Y_N \mid Z_N > 0.251 \} \quad 0.5 \text{ point} \quad (29)$$

Question 8 (1 point) La fonction puissance, notée $G(p)$, est définie par :

$$G(p) = 1 - \Phi \left(\frac{C - p}{\sqrt{\frac{p(1-p)}{N}}} \right) \quad (30)$$

ou encore :

$$G(p) = 1 - \Phi \left(\frac{p_0 + \Phi^{-1}(1 - \alpha) \sqrt{\frac{p_0(1-p_0)}{N}} - p}{\sqrt{\frac{p(1-p)}{N}}} \right) \quad 0.5 \text{ point} \quad (31)$$

Dès lors pour $p_0 = 0.2$, $N = 100$ et $\alpha = 10\%$, si la vraie valeur de la probabilité de défaut de paiement est égale à 28%, la puissance du test vaut :

$$G(0.28) = 1 - \Phi \left(\frac{0.2 + \Phi^{-1}(0.9) \sqrt{\frac{0.2(1-0.2)}{100}} - 0.28}{\sqrt{\frac{0.28(1-0.28)}{100}}} \right) = 0.738 \quad 0.5 \text{ point} \quad (32)$$

On vérifie au passage que naturellement la valeur de la puissance pour $p_1 = 0.28$ (73,8%) est inférieure à celle obtenue pour l'hypothèse alternative $p_1 = 0.3$ (85%) à la question 5.

Question 9 (2 points) On souhaite tester la valeur de la probabilité de défaut comme suit :

$$H_0 : p = 0.2 \quad (33)$$

$$H_1 : p \neq 0.2 \quad (34)$$

La région d'acceptation du test bilatéral correspond à l'intersection des régions d'acceptation des deux tests unilatéraux associés $H_0 : p = 0.2$ contre $H_1 : p > 0.2$ et $H_0 : p = 0.2$ contre $H_1 : p < 0.2$ définies pour des risque de première espèce de $\alpha/2 = 2.5\%$. Soient K_1 et K_2 les deux seuils critiques correspondant (0.5 point) :

$$K_1 = p_0 + \Phi^{-1} \left(\frac{\alpha}{2} \right) \sqrt{\frac{p_0(1 - p_0)}{N}} = 0.1216 \quad (35)$$

$$K_2 = p_0 + \Phi^{-1} \left(1 - \frac{\alpha}{2} \right) \sqrt{\frac{p_0(1 - p_0)}{N}} = 0.2784 \quad (36)$$

Donc la RC du test bilatéral s'écrit (1 point) :

$$W = \{ Y_1, \dots, Y_N \mid Z_N \notin [0.134; 0.265] \} \quad 1 \text{ point} \quad (37)$$

Dès lors, $\sum_{i=1}^{100} Y_i = 23$, on a $Z_N = 0.23$ et donc la réalisation de Z_N appartient à la région d'acceptation. Pour un risque de première espèce de 5%, on ne peut pas rejeter l'hypothèse nulle selon laquelle $p = 0.2$ (0.5 point).

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, $p_i = p_i \times p_j = \frac{n_{i.}}{n} \times \frac{n_{.j}}{n} \Leftrightarrow T_{ij} = np_{ij} = \frac{n_{i.} \times n_{.j}}{n}$. 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 Question 1 :

$$\begin{aligned} L &= \prod_{i=1}^N f(x_i) = \left(\frac{1}{\theta \cdot c^{\frac{1}{\theta}}}\right)^N \cdot \prod_{i=1}^N x_i^{\frac{1}{\theta}-1} \text{ si tous les } x_i \text{ vérifient } 0 \leq x_i \leq c \quad (38) \\ &= 0 \text{ sinon (1 point)} \end{aligned}$$

Question 2 : supposons que tous les x_i sont tels que $0 \leq x_i \leq c$, alors

$$\begin{aligned} \frac{\partial \log L}{\partial \theta} &= \frac{\partial}{\partial \theta} \left[-N \log(\theta) - \frac{N}{\theta} \log(c) + \left(\frac{1}{\theta} - 1\right) \sum \log(x_i) \right] \quad 0.5 \text{ point} \\ &= -\frac{N}{\theta} + \frac{N}{\theta^2} \log(c) - \frac{1}{\theta^2} \sum \log(x_i) = 0 \quad 0.5 \text{ point} \end{aligned}$$

D'où l'on tire

$$\hat{\Theta}_n = \ln(c) - \frac{1}{n} \sum_{i=1}^n \ln(X_i) \quad (39)$$

Question 3. On pose $Y = \ln(c) - \ln(X)$ et l'on admet que $E(Y) = \theta$ et $V(Y) = \theta^2$. On alors :

$$\begin{aligned} E(\hat{\Theta}_n) &= \ln(c) - \frac{1}{n} \sum_{i=1}^n E[\ln(X_i)] \\ &= \ln(c) - \frac{1}{n} \sum_{i=1}^n E[\ln(c) - \ln(Y_i)] \\ &= \frac{1}{n} \sum_{i=1}^n E[\ln(Y_i)] \\ &= \frac{1}{n} \sum_{i=1}^n \theta = \theta \quad 1 \text{ point sans biais} \end{aligned}$$

$$\begin{aligned} V(\hat{\Theta}_n) &= \ln(c) - \frac{1}{n^2} \sum_{i=1}^n V[\ln(X_i)] \\ &= \ln(c) - \frac{1}{n^2} \sum_{i=1}^n V[\ln(c) - \ln(Y_i)] \\ &= \frac{1}{n^2} \sum_{i=1}^n V[\ln(Y_i)] \\ &= \frac{1}{n^2} \sum_{i=1}^n \theta^2 \\ &= \frac{\theta^2}{n}, \text{ convergent 1point} \end{aligned}$$