

Exercice 1 : Comparaison des réussites de trois écoles (4pts)

Trois écoles ont relevé le nombre d'admis et d'ajournés au brevet dans le tableau suivant

	École 1	École 2	École 3	N_k
Admis	50	35	85	170
Ajournés	30	15	35	80
N_l	80	50	120	250

On désire tester si les résultats de ces trois écoles sont significativement différents à l'aide d'un test du χ^2 d'homogénéité

1. Exprimer la valeur de la statistique du test du χ^2 d'homogénéité notée I_n en fonction des données du problème (sans chercher à la calculer).

Le test du χ^2 d'homogénéité rejette l'hypothèse H_0 si

$$I_n = \sum_{k=1}^K \sum_{l=1}^L \frac{\left(N_{k,l} - \frac{N_{k,\cdot} N_{\cdot,l}}{n}\right)^2}{\frac{N_{k,\cdot} N_{\cdot,l}}{n}} > S_{K,L,\alpha}$$

avec $S_{K,L,\alpha} = F_{(K-1)(L-1)}^{-1}(\alpha)$ qui est la fonction de répartition inverse d'une loi du χ^2 à $(K-1)(L-1)$ degrés de liberté. Dans notre exemple, on a

$$I_n = \frac{\left(50 - \frac{170 \times 80}{250}\right)^2}{\frac{170 \times 80}{250}} + \frac{\left(35 - \frac{170 \times 50}{250}\right)^2}{\frac{170 \times 50}{250}} + \frac{\left(85 - \frac{170 \times 120}{250}\right)^2}{\frac{170 \times 120}{250}} + \frac{\left(30 - \frac{80 \times 80}{250}\right)^2}{\frac{80 \times 80}{250}} + \frac{\left(15 - \frac{80 \times 50}{250}\right)^2}{\frac{80 \times 50}{250}} + \frac{\left(35 - \frac{80 \times 120}{250}\right)^2}{\frac{80 \times 120}{250}}$$

2. Déterminer la loi asymptotique de I_n et en déduire le seuil du test en fonction du risque de première espèce α et de l'inverse de la fonction de répartition d'une loi du χ_K^2 notée F_K^{-1} pour une valeur de K que l'on déterminera.

La loi asymptotique de I_n est une loi du χ^2 à $(K-1)(L-1)$ degrés de liberté, i.e., $I_n \sim \chi_2^2$. On en déduit

$$\alpha = P[\text{Rejeter } H_0 | H_0 \text{ vraie}] = P[I_n > S_\alpha | I_n \sim \chi_2^2] = 1 - F_2(S_\alpha),$$

d'où

$$S_\alpha = F_2^{-1}(1 - \alpha).$$

3. Exprimer la p-valeur de ce test en fonction de I_n et de la fonction de répartition d'une loi du χ_K^2 notée F_K pour une valeur de K que l'on précisera.

La p-valeur est la plus petite valeur de α pour laquelle on rejette H_0 , soit

$$p\text{-val} = 1 - F_2(I_n).$$

4. Expliquer comment déterminer si les résultats de ces trois écoles sont significativement différents ou pas. Le principe du test du χ^2 d'homogénéité est de rejeter l'hypothèse H_0 (et donc de décider que les trois écoles ont des résultats significativement différents) si $I_n > S_\alpha$.

Exercice 2 : Comparaison du prix de deux produits (4pts)

Les prix en euros d'un même produit dans deux régions Françaises sont indiqués dans le tableau ci-dessous

R 1	$x_1 = 14$	$x_2 = 15.5$	$x_3 = 16.5$	$x_4 = 17$	$x_5 = 18$	$x_6 = 15$	$x_7 = 19.5$	$x_8 = 20.5$	$x_9 = 21$	$x_{10} = 24$
R 2	$y_1 = 17.5$	$y_2 = 16$	$y_3 = 18.5$	$y_4 = 22.5$	$y_5 = 22$	$y_6 = 18$	$y_7 = 20$	$y_8 = 25$	$y_9 = 24$	$y_{10} = 41$

On aimerait déterminer si le prix du produit dans les deux régions sont différents ou pas.

1. Déterminer la valeur de la statistique du test de Wilcoxon W_m associée à ce problème.

Le test de Wilcoxon rejette l'hypothèse H_0 si $W_m < S_{1,\alpha}$ ou $W_m > S_{2,\alpha}$ où $W_m = \sum_{j=1}^m S_j$ et S_j est le rang de Y_j parmi les $n + m$ données réunies $(X_1, \dots, X_n, Y_1, \dots, Y_m)$. Dans cet exemple, on a les résultats suivants

— Suite ordonnée

$$(14, 15, 15.5, 16, 16.5, 17, 17.5, 18, 18, 18.5, 19.5, 20, 20.5, 21, 22, 22.5, 24, 24, 25, 21).$$

— Données associées

$$x_1, x_6, x_2, y_2, x_3, x_4, y_1, x_5 = y_6, y_3, x_7, y_7, x_8, x_9, y_5, y_4, x_{10} = y_9, y_8, y_{10}$$

— rangs du groupe 2

$$r_2 = 4, r_1 = 7, r_6 = 8.5, r_3 = 10, r_7 = 12, r_5 = 15, r_4 = 16, r_9 = 17.5, r_8 = 19, r_{10} = 20.$$

— Statistique de Wilcoxon

La somme des rangs s'écrit

$$W_m = \sum_{i=1}^{10} r_i = 129.$$

2. Quelle est la loi asymptotique de W_m ? En utilisant cette loi asymptotique, exprimer la p -valeur du test de Wilcoxon en fonction de la fonction de répartition de la loi normale $\mathcal{N}(0, 1)$ notée F .

La loi asymptotique de W_m est une loi normale de moyenne $E[W_m] = \frac{nm}{2} + \frac{m(m+1)}{2} = 105$ et de variance $\text{var}[W_m] = \frac{nm(n+m+1)}{12} = 175$. La p -valeur de ce test est définie par

$$p\text{-val} = 2 \left[1 - F \left(\frac{|W_m - E[W_m]| - 0.5}{\sqrt{\text{var}[W_m]}} \right) \right].$$

3. Expliquer le principe de la correction de continuité.
Sans correction de continuité, la p -valeur serait égale à

$$p\text{-val} = 2 \left[1 - F \left(\frac{|W_m - E[W_m]|}{\sqrt{\text{var}[W_m]}} \right) \right].$$

Le fait de retrancher 0.5 au numérateur permet de compenser le fait qu'on approche une loi discrète par une loi continue.

4. Expliquer comment procéder à l'aide de cette p -valeur pour décider si les deux ensembles de prix sont significativement différents avec un risque $\alpha = 0.05$.

La p -valeur est la plus petite valeur de α pour laquelle on rejette H_0 . Donc si la p -valeur est inférieure à 0.05, on rejette l'hypothèse H_0 avec le risque $\alpha = 0.05$ et donc on décide que si les prix du produit dans les deux régions sont différents. Si la p -valeur est supérieure à 0.05, on accepte l'hypothèse H_0 avec le risque $\alpha = 0.05$ et donc on décide que les prix du produit dans les deux régions sont les mêmes.

Exercice 3 : Droite de Henry (2pts)

1. Rappeler ce que représente une droite de Henry pour tester la loi normale.

Soit $(x_{(1)}, \dots, x_{(n)})$ avec $x_{(1)} \leq x_{(2)} \leq \dots \leq x_{(n)}$ la statistique d'ordre de (x_1, \dots, x_n) . La droite de Henry utilisée pour tester si (x_1, \dots, x_n) est issu d'une loi normale représente les n points $(x_{(i)}, t_{(i)})$ avec $t_{(i)} = \Phi^{-1} \left(\frac{i}{n} \right)$.

2. Comment reconnaît-on que (x_1, \dots, x_n) est issu d'une loi normale à l'aide de la droite de Henry?

Lorsque (x_1, \dots, x_n) est issu d'une loi normale, les n points $(x_{(i)}, t_{(i)})$ sont presque alignés, contrairement au cas où (x_1, \dots, x_n) n'est pas issu d'une loi normale.