

# Probabilités

Licence 2 - Semestre 3

Exercices d'entraînement

Test du  $\chi^2$

Corrigés

## Correction 1

Population : les employés.

Deux caractères  $X$  : sites, à  $r = 3$  modalités, et  $Y$  : postes, à  $s = 3$  modalités.

Echantillon de taille  $n = 300$ .

$H_0$  :  $X$  et  $Y$  sont indépendantes

$H_1$  :  $X$  et  $Y$  ne sont pas indépendantes

Test de  $H_0$  contre  $H_1$ .

Ce test s'appuie sur la distance  $D$  entre les effectifs observés et théoriques :  $D = \sum_{i=1}^r \sum_{j=1}^s \frac{(N_{i,j} - \tilde{n}_{i,j})^2}{\tilde{n}_{i,j}}$ .

Sous l'hypothèse  $H_0$  d'indépendance de  $X$  et  $Y$ , les effectifs théoriques sont  $\tilde{n}_{i,j} = \frac{n_{i,*} \times n_{*,j}}{n}$ .

|        | Techniciens | Cadres moyens | Cadres supérieurs | Total |
|--------|-------------|---------------|-------------------|-------|
| Site 1 | 105         | 18            | 12                | 135   |
| Site 2 | 40          | 7             | 6                 | 53    |
| Site 3 | 77          | 20            | 15                | 112   |
| Total  | 222         | 45            | 33                | 300   |

| $\tilde{n}_{i,j}$ | Techniciens | Cadres moyens | Cadres supérieurs | $n_{i,*}$ |
|-------------------|-------------|---------------|-------------------|-----------|
| Site 1            | 99,9        | 20,25         | 14,85             | 135       |
| Site 2            | 39,22       | 7,95          | 5,83              | 53        |
| Site 3            | 82,88       | 16,8          | 12,32             | 112       |
| $n_{*,j}$         | 222         | 45            | 33                | 300       |

La condition  $\tilde{n}_{i,j} \geq 5$  est vérifiée.

| $d_i = \frac{(n_{i,j} - \tilde{n}_{i,j})^2}{\tilde{n}_{i,j}}$ | Techniciens | Cadres moyens | Cadres supérieurs |
|---|-------------|---------------|-------------------|
| Site 1  | 0,2604      | 0,25          | 0,547             |
| Site 2  | 0,0155      | 0,1135        | 0,005             |
| Site 3  | 0,4172      | 0,6095        | 0,583             |

On obtient :  $d = \sum_{i=1}^3 \sum_{j=1}^3 d_i = 2,8$ .

On sait que sous l'hypothèse  $H_0$ ,  $D$  suit approximativement la loi de  $\chi^2$  à  $(r-1)(s-1) = (3-1) \times (3-1) = 4$  degrés de liberté. D'après la table du  $\chi^2$ , pour  $\alpha = 0,05$ , on trouve  $b_{\max} = 9,488$ .

Comme  $d < b_{\max}$ , on ne rejette pas l'hypothèse  $H_0$  d'indépendance de  $X$  et  $Y$  à un niveau de

confiance de 95%. On peut donc considérer que les sites ont la même répartition en terme de personnel.

**Correction 2**

On dispose de  $r = 2$  échantillons provenant de la population des produits vendus dans les deux villes

On étudie la variable  $X$  des différents produits vendus pouvant prendre  $s = 5$  modalités.

Question : les deux populations présentent-elles les mêmes résultats?

Test de  $H_0$  : les échantillons sont issus de la même population contre  $H_1 = \overline{H_0}$ .

Ce test s'appuie sur la distance  $D$  entre les effectifs observés et théoriques :  $D = \sum_{i=1}^r \sum_{j=1}^s \frac{(N_{i,j} - \tilde{n}_{i,j})^2}{\tilde{n}_{i,j}}$

Sous l'hypothèse  $H_0$  d'homogénéité des échantillons, les effectifs théoriques sont  $\tilde{n}_{i,j} = \frac{n_{i*} n_{*,j}}{n}$ .

|           |           |           |           |           |           |           |
|-----------|-----------|-----------|-----------|-----------|-----------|-----------|
| $n_{i,j}$ | Produit 1 | Produit 2 | Produit 3 | Produit 4 | Produit 5 | $n_{i,*}$ |
| Ville A   | 32        | 16        | 32        | 8         | 8         | 96        |
| Ville B   | 16        | 8         | 24        | 8         | 8         | 64        |
| $n_{*,j}$ | 48        | 24        | 56        | 16        | 16        | 160       |

Les effectifs théoriques sont :

|                   |           |           |           |           |           |           |
|-------------------|-----------|-----------|-----------|-----------|-----------|-----------|
| $\tilde{n}_{i,j}$ | Produit 1 | Produit 2 | Produit 3 | Produit 4 | Produit 5 | $n_{i,*}$ |
| Ville A           | 28,8      | 14,4      | 33,6      | 9,6       | 9,6       | 96        |
| Ville B           | 19,2      | 9,6       | 22,4      | 6,4       | 6,4       | 64        |
| $n_{*,j}$         | 48        | 24        | 56        | 16        | 16        | 160       |

|           |           |           |           |           |           |
|-----------|-----------|-----------|-----------|-----------|-----------|
| $d_{i,j}$ | Produit 1 | Produit 2 | Produit 3 | Produit 4 | Produit 5 |
| Ville A   | 0,3556    | 0,1778    | 0,0762    | 0,2667    | 0,2667    |
| Ville B   | 0,5333    | 0,2667    | 0,1143    | 0,4       | 0,4       |

On obtient :  $d = \sum_{i=1}^r \sum_{j=1}^s \frac{(n_{ij} - \tilde{n}_{i,j})^2}{\tilde{n}_{i,j}} = 2,86$ .

On sait que sous l'hypothèse  $H_0$ ,  $D$  suit approximativement la loi de  $\chi^2$  à  $(r - 1)(s - 1) = (2 - 1) \times (5 - 1) = 4$  degrés de liberté. D'après la table du  $\chi^2$ , pour  $\alpha = 0,05$ , on trouve  $b_{\max} = 9,488$ .

Comme  $d \leq b_{\max}$ , on ne peut pas rejeter l'hypothèse  $H_0$  d'homogénéité des échantillons à un niveau de confiance de 95% : on peut donc considérer que les deux populations présentent les mêmes répartitions de vente.

**Correction 3**

Population : les véhicules.

Caractère  $X$  : le nombre de pannes à  $r = 4$  modalités.

Echantillon  $(X_1, \dots, X_n)$  de taille  $n = 23 + 17 + 11 + 9 = 60$ .

1. Le nombre moyen de pannes dans l'échantillon est :

$$\bar{x} = \frac{0 \times 23 + 1 \times 17 + 2 \times 11 + 3 \times 9}{60} = \frac{66}{60} = 1,1,$$

$$\overline{x^2} = \frac{0^2 \times 23 + 1^2 \times 17 + 2^2 \times 11 + 3^2 \times 9}{60} = \frac{142}{60} \approx 2,3666667,$$

$$s^2 \approx 2,3666667 - 1,1^2 \approx 1,157 \text{ et } s_c^2 \approx 1,177.$$

2. On teste  $H_0$  contre  $H_1$  où  $H_0$  est "X suit une loi de Poisson" et  $H_1 = \overline{H_0}$  est "X ne suit pas une loi de Poisson".

Comme  $\bar{x}$  et  $s_c^2$  sont très proches, on pouvait effectivement penser à une loi de Poisson.

On peut alors estimer le paramètre  $\lambda$  à  $1,1 (= \bar{x})$ .

Les  $p_i$  devant être calculés à l'aide la loi de Poisson, il y a un paramètre à estimer :  $k = 1$ .

Les  $p_i$  sont obtenus grâce à la table :

$$p_0 = 0,3329, p_1 = 0,699 - 0,3329 = 0,3661, p_2 = 0,9004 - 0,699 = 0,2014.$$

Pour que le total des probabilités soit bien égal à 1, on considère que l'effectif de la classe "3 pannes" correspond à la classe "3 pannes et plus".

Et on a  $p_3 = 1 - 0,9004 = 0,0996$ .

| Valeurs   | Effectifs observés |        | Effectifs théoriques |   |
|-----------|--------------------|--------|----------------------|---|
| $x_i$     | $n_i$              | $p_i$  | $n \times p_i$       | $d_i = \frac{(n_i - n \times p_i)^2}{n \times p_i}$ |
| 0         | 23                 | 0,3329 | 19,974               | 0,458   |
| 1         | 17                 | 0,3661 | 21,996               | 1,222   |
| 2         | 11                 | 0,2014 | 12,084               | 0,097   |
| 3 et plus | 9                  | 0,0996 | 5,976                | 1,530   |
| Total     | 60                 | 1      |                      | 3,207   |

On sait que sous l'hypothèse  $H_0$ ,  $D$  suit approximativement la loi de  $\chi^2$  à  $r - k - 1 = 4 - 1 - 1 = 2$  degré de liberté.

On a  $d = \sum_{i=1}^3 d_i \simeq 3,207$ . Et, d'après la table du  $\chi^2$ , pour  $\alpha = 0,05$ , on trouve  $b_{\max} = 5,991$ .

Comme  $d \leq b_{\max}$ , on ne peut rejeter l'hypothèse  $H_0$ , i.e., la conformité à la loi théorique de Poisson : la répartition des pannes annuelles est conforme à une loi de Poisson. En prenant cette décision de non-rejet de  $H_0$ , on ne connaît pas la probabilité de se tromper (erreur de deuxième espèce).

#### Correction 4

On teste  $H_0$  contre  $H_1$  où  $H_0$  est "X suit une loi normale" et  $H_1 = \overline{H_0}$  est "X ne suit pas une loi normale".

Les  $p_i$  devant être calculés à l'aide la loi normale, il y a deux paramètres à estimer ( $\mu$  et  $\sigma$ ) c'est-à-dire  $k = 2$ .

$$\text{On a } \bar{x} = \frac{6 \times 1,5 + 32 \times 2,5 + 44 \times 4 + 18 \times 7,5}{6 + 31 + 44 + 18} = \frac{400}{100} = 4$$

$$\overline{x^2} = \frac{6 \times 1,5^2 + 32 \times 2,5^2 + 44 \times 4^2 + 18 \times 7,5^2}{6 + 31 + 44 + 18} = \frac{1930}{100} = 19,3$$

$$s^2 = 19,3 - 4^2 = 3,3, s_c^2 = \frac{100}{99} s^2 \approx 3,33 \text{ et } s_c \approx 1,83.$$

On peut alors estimer les paramètres  $\mu$  et  $\sigma$  par 4 et 1,83.

Il s'agira donc de tester si  $X$  suit la loi normale  $\mathcal{N}(4; 1,83)$ , i.e., si  $Z = \frac{X - 4}{1,83}$  suit la loi normale  $\mathcal{N}(0; 1)$ .

Puisque la loi normale est définie sur  $\mathbb{R}$ , on change la première borne des intervalles en  $-\infty$  et la dernière en  $+\infty$ .

$$p(] - \infty; 2]) = \varphi\left(\frac{2-4}{1,83}\right) \approx \varphi(-1,09) = 1 - \varphi(1,09) \approx 1 - 0,8621 = 0,1379$$

$$p([2; 3[) = \varphi\left(\frac{3-4}{1,83}\right) - \varphi\left(\frac{2-4}{1,83}\right) \approx \varphi(-0,55) - \varphi(-0,9)$$

$$= 1 - \varphi(0,55) - 0,1379 \approx 1 - 0,7088 - 0,1379 = 0,2912 - 0,1379 = 0,1533$$

$$p([3; 5[) = \varphi\left(\frac{5-4}{1,83}\right) - \varphi\left(\frac{3-4}{1,83}\right) \approx \varphi(0,55) - \varphi(-0,55) \approx 0,7088 - 0,2912 = 0,4176$$

$$p([5; +\infty[) = 1 - \varphi\left(\frac{5-4}{1,83}\right) \approx 1 - \varphi(0,55) \approx 1 - 0,7088 = 0,2912$$

| Autonomie (en heures)     | ] - \infty; 2[ | [2, 3[ | [3, 5[ | [5; +\infty[ | Total |
|---------------------------|----------------|--------|--------|--------------|-------|
| Nombre de vélos ( $n_i$ ) | 6              | 32     | 44     | 18           | 100   |
| $p_i$                     | 0,1379         | 0,1533 | 0,4176 | 0,2912       | 1     |
| $n \times p_i$            | 13,79          | 15,33  | 41,76  | 29,12        | 100   |
| $d_i$                     | 4,4            | 18,13  | 0,12   | 4,25         | 26,9  |

La condition  $n \times p_i \geq 5$  est vérifiée.

On a donc  $d = \sum_{i=1}^5 d_i \approx 26,9$ .

Pour  $\alpha = 0,05$  et  $d.d.l. = 4 - 2 - 1 = 1$ , on trouve  $b_{\max} = 3,841$ .

Comme  $d > b_{\max}$ , on rejette l'hypothèse  $H_0$ , i.e., la variable ne suit pas une loi normale.

### Correction 5

*Méthode 1 : Test de comparaison de proportions (voir feuille d'exercice sur le sujet)*

On suppose  $X_1 \sim \mathcal{B}(p_1)$  et  $X_2 \sim \mathcal{B}(p_2)$

On a bien que  $n_1 f_1 = 16$ ,  $n_1(1 - f_1) = 109$ ,  $n_2 f_2 = 18$  et  $n_2(1 - f_2) = 197$  sont tous plus grand que 5.

On a  $f_1 = \frac{16}{125} = 0,128 = 12,8\%$  et  $f_2 = \frac{18}{215} \approx 0,084 = 8,4\%$

On pose  $f = \frac{n_1 f_1 + n_2 f_2}{n_1 + n_2} = \frac{16 + 18}{125 + 215} = \frac{34}{340} = 0,1 = 10\%$ .

Et  $z_{calcul} = \frac{f_1 - f_2}{\sqrt{f(1-f)\left(\frac{1}{n_1} + \frac{1}{n_2}\right)}} \approx 1,3122$ .

De plus,  $z_{critique} = 2,58$

Puisque  $|z_{calcul}| < z_{critique}$ , on ne rejette pas l'hypothèse  $H_0 : p_1 = p_2$  au risque d'erreur  $\alpha$ .

*Méthode 2 : Test du  $\chi^2$*

On peut également traiter cette question par un test d'indépendance des deux variables  $X$  : modèle de disque dur, à  $r = 2$  modalités et  $Y$  : Nombre de pannes, à  $s = 2$  modalités (pas de panne et au moins une panne).

Echantillon de taille  $n = 340$ .

$H_0$  :  $X$  et  $Y$  sont indépendantes

$H_1$  :  $X$  et  $Y$  ne sont pas indépendantes

Test de  $H_0$  contre  $H_1$ .

Ce test s'appuie sur la distance  $D$  entre les effectifs observés et théoriques :  $D = \sum_{i=1}^r \sum_{j=1}^s \frac{(N_{i,j} - \tilde{\mathbf{n}}_{i,j})^2}{\tilde{\mathbf{n}}_{i,j}}$

Sous l'hypothèse  $H_0$  d'indépendance de  $X$  et  $Y$ , les effectifs théoriques sont  $\tilde{\mathbf{n}}_{i,j} = \frac{n_{i,\star} \times n_{\star,j}}{n}$ .

| $n_{i,j}$     | pannes | pas de panne | $n_{i,\star}$ |
|---------------|--------|--------------|---------------|
| Modèle A      | 16     | 109          | 125           |
| Modèle B      | 18     | 197          | 215           |
| $n_{\star,j}$ | 34     | 306          | 340           |

| $\tilde{\mathbf{n}}_{i,j}$ | pannes | pas de panne | $n_{i,\star}$ |
|----------------------------|--------|--------------|---------------|
| Modèle A                   | 12,5   | 112,5        | 125           |
| Modèle B                   | 21,5   | 193,5        | 215           |
| $n_{\star,j}$              | 34     | 306          | 340           |

La condition  $\tilde{\mathbf{n}}_{i,j} \geq 5$  est vérifiée.

| $d_{i,j} = \frac{(n_{i,j} - \tilde{\mathbf{n}}_{i,j})^2}{\tilde{\mathbf{n}}_{i,j}}$ | pannes | pas de panne |
|---|--------|--------------|
| Modèle A  | 0,98   | 0,1089       |
| Modèle B  | 0,5698 | 0,0633       |

On a  $d = \sum_{i=1}^2 \sum_{j=1}^2 d_{i,j} = 1,72$ .

On sait que sous l'hypothèse  $H_0$ ,  $D$  suit approximativement la loi de  $\chi^2$  à  $(r-1)(s-1) = (2-1) \times (2-1) = 1$  degré de liberté. D'après la table du  $\chi^2$ , pour  $\alpha = 0,01$ , on trouve  $b_{\max} = 6,635$ .

Comme  $d \leq b_{\max}$ , on ne rejette pas l'hypothèse  $H_0$  d'indépendance de  $X$  et  $Y$ .