

# Correction exercices 1 à 3

Tests relevant de la statistique du  $X^2$

# 1. Je suis malaaddeeee...

Les résultats de l'évolution d'une maladie M, à la suite de l'emploi de l'un ou l'autre des traitements A et B, figurent dans le tableau d'effectifs ci-dessous:



	Guérison	Amélioration	Etat stationnaire
A	280	210	110
B	220	90	90

Peut on dire que les traitements A et B sont différents (au seuil  $\alpha = 0.05$ ) ?

# 1. Je suis malaaddeeee...

**Solution :**

$H_0$  : Homogénéité des effectifs entre échantillons

$H_1$  : Hétérogénéité des effectifs entre échantillons



	Guérison	Amélioration	Etat stationnaire	Marge colonne
A	280 300	210 180	110 120	600
B	220 200	90 120	90 80	400
Marge ligne	500	300	200	1000

$$\chi_{obs}^2 = \frac{(280 - 300)^2}{300} + \frac{(210 - 180)^2}{180} + \frac{(110 - 120)^2}{120} + \dots + \frac{(90 - 80)^2}{80} = 17.9$$

Pour  $\alpha = 0.05$  et ddl = 2  $\Rightarrow \chi_{théo}^2 = 5.99$  (13.82 pour  $\alpha = 0.01$ )

$\chi_{obs}^2 > \chi_{théo}^2$ , **on rejette  $H_0$**  et on accepte  $H_1$  : les traitements ont des effets différents

## Effectuer ce test sous R

**Code :** On utilisera la fonction « **chisq.test** », dans laquelle on renseignera :

Tableau de type « matrix » (2 L \* 3 C)      Les effectifs observés      Comparaison par lignes (échantillons)

```
chisq.test(matrix(c(280,210,110,220,90,90), ncol=3, byrow=TRUE))
```

**Sortie :**

Pearson's Chi-squared test

```
data: matrix(c(280, 210, 110, 220, 90, 90), ncol = 3, byrow = TRUE)
X-squared = 17.917, df = 2, p-value = 0.0001287
```

$\chi^2_{obs}$

ddl

p-value hautement significative (< 0.001) → rejet de H0

## Effectuer ce test sous R

NB: On peut également utiliser le test exact de Fisher (petits échantillons)

→ Fonction « `fisher.test` », syntaxe similaire :

```
> fisher.test(matrix(c(280,210,110,220,90,90), ncol=3, byrow=TRUE))
```

Fisher's Exact Test for Count Data

```
data: matrix(c(280, 210, 110, 220, 90, 90), ncol = 3, byrow = TRUE)
```

```
p-value = 0.0001086
```

```
alternative hypothesis: two.sided
```

p-value hautement significative ( $< 0.001$ ), rejet de  $H_0$

## 2. Les cheveux dans les yeux...

Sur un échantillon de 6800 individus, on a relevé la couleur des yeux et cheveux de chaque personnes. Les effectifs sont :



	Blonds	Bruns	Roux	Noirs	Marge C
Marrons	115	438	16	288	857
Bleus	1768	807	47	189	2811
Gris ou Verts	946	1387	53	746	3132
Marge L	2829	2632	116	1223	6800

**La distribution de la couleur des cheveux varie elle en fonction de la couleur des yeux ?**

## 2. Les cheveux dans les yeux...

Sur un échantillon de 6800 individus, on a relevé la couleur des yeux et cheveux de chaque personnes. Les effectifs sont :



	Blonds	Bruns	Roux	Noirs	Marge C
Marrons	115	438	16	288	857
Bleus	1768	807	47	189	2811
Gris ou Verts	946	1387	53	746	3132
Marge L	2829	2632	116	1223	6800

**La distribution de la couleur des cheveux varie elle en fonction de la couleur des yeux ?**

*2 VA qualitatives nominales (non contrôlées par l'investigateur), mesurées simultanément sur 1 seul échantillon d'individus → test d'indépendance*

## 2. Les chveux dans les yeux...

### *Solution :*

$H_0$  : le fait de connaître la couleur des cheveux ne permet pas d'aider à deviner la couleur des yeux et inversement

$H_1$  : il y a un lien entre couleur des cheveux et des yeux

	Blonds	Bruns	Roux	Noirs	Marge C
Marrons	115 356.53	438 331.71	16 14.62	288 154.13	857
Bleus	1768 1169.46	807 1088.02	47 47.95	189 505.57	2811
Gris ou Verts	946 1303.00	1387 1212.27	53 53.43	746 563.30	3132
Marge L	2829	2632	116	1223	6800

$$X_{obs}^2 = 1073,89 \quad X_{Théo}^2 = 12.592 \quad (\alpha = 0.05, \text{ddl} = (4-1)*(3-1) = 6)$$

$$X_{obs}^2 \gg X_{Théo}^2, \text{ et } p\text{-value} \ll 0.001$$

➔ *Ces deux variables sont liées (indépendance rejetée)*



## Effectuer ce test sous R

**Code :**

```
mat_ChevYeux<-matrix(c(115,438,16,288,  
                        1768,807,47,189,  
                        946,1387,53,746),  
                      ncol = 4, byrow = T)  
# rajouter noms lignes et colonnes  
colnames(mat_ChevYeux)<-c("Blond","Brun","Roux","Noir")  
row.names(mat_ChevYeux)<-c("Marron","Bleu","Gris/Vert")  
# rajouter les marges L et C  
addmargins(mat_ChevYeux)  
  
## le test  
Khi2_chevYeux<-chisq.test(mat_ChevYeux)  
Khi2_chevYeux  
#résultats attendus/théoriques  
round(Khi2_chevYeux$expected,2)
```

**Sortie :**

Pearson's Chi-squared test

```
data:  matrix(c(115, 438, 16, 288, 1768, 807, 47, 189,  
                946, 1387, 53,      746), ncol = 4, byrow = T)  
X-squared = 1073.5, df = 6, p-value < 2.2e-16
```

### 3. Qui vole un boeuf...

Le bœuf musqué (*Ovibos moscatus*) est infecté par des nématodes dont on connaît trois variétés différentes. Pour vérifier si l'importance relative de ces trois variétés varie d'une région à l'autre on a dénombré des individus appartenant aux trois variétés dans les excréments de bœufs musqués de trois régions différentes :

	Variété I	Variété II	Variété III
Alaska	7	42	40
T NW	12	54	16
Iles B	6	33	33



*L'importance relative des trois variétés de nématodes varie-t-elle entre les trois régions ?*

### 3. Qui vole un boeuf...

Le bœuf musqué (*Ovibos moscatus*) est infecté par des nématodes dont on connaît trois variétés différentes. Pour vérifier si l'importance relative de ces trois variétés varie d'une région à l'autre on a dénombré des individus appartenant aux trois variétés dans les excréments de bœufs musqués de trois régions différentes :

	Variété I	Variété II	Variété III
Alaska	7	42	40
T NW	12	54	16
Iles B	6	33	33



L'importance relative des trois variétés de nématodes varie-t-elle entre les trois régions ?

3 échantillons indépendants (facteur qualitatif contrôlé/fixé = localité)

3 modalités (facteur qualitatif aléatoire = variétés nématodes)

Comparaison d'effectifs entre échantillons →  $\chi^2$  homogénéité avec H1 bilatéral

## Effectuer ce test sous R

```
chisq.test(matrix(c(7,42, 40, 12, 54, 16, 6,33,33), ncol=3, byrow = TRUE))
```

Pearson's Chi-squared test

```
data:  matrix(c(7, 42, 40, 12, 54, 16, 6, 33, 33), ncol = 3, byrow = TRUE)  
X-squared = 16, df = 4, p-value = 0.003019
```

$$ddl = (3-1) * (3-1) = 4$$

P-value < 0.01, les **différences observées sont très significatives** et ne sont pas dues seulement aux fluctuations d'échantillonnage (lien avec localité des groupes comparés)