

## Chapitre 7

### Tests d'adéquation et d'indépendance

**1) Test d'adéquation** Dans cette section, nous présentons une méthode pour tester l'hypothèse que les fréquences observées pour les différentes catégories (classes) sont en adéquation avec une distribution donnée.

#### Notations

$no_i$  représente les fréquences observés de résultats.

$nt_i$  représente les fréquences attendu de résultats.

$k$  représente le nombre de classes.

$n$  représente le nombre total d'essais.

#### Conditions d'application

- Les données sélectionnées aléatoirement
- Pour chaque catégorie, la fréquence attendu est au moins 5 ( $nt_i \geq 5$ ).

#### Les hypothèses à tester

$H_0$  : les observations suivent la distribution  $p_i$ .

$H_1$  : les observations ne suivent pas la distribution  $p_i$ .

#### Statistique de test


$$\chi^2_c = \sum \frac{(noi - nti)^2}{nti}$$

## Valeurs critiques

Les valeurs critiques sont les dans a table de khi deux avec  $ddl=k-1$

Les tests d'hypothèses d'adéquation sont toujours unilatéraux à droite.

## Représentation graphique



## Interprétation

Le non rejet de  $H_0$  signifie que les valeurs  $n_{oi}$  et  $n_{ti}$  sont proches.

Le rejet de  $H_0$  signifie que les valeurs  $n_{oi}$  et  $n_{ti}$  sont éloignées.

### Exemple

A partir du génotype des parents, on s'attend à ce que les enfants aient des génotypes répartis comme suit : 25% de génotype AA, 50% de génotype Aa et 25% de génotype aa. Pour une maladie particulière, AA représente un enfant sain, Aa un enfant porteur et aa un enfant malade.

Le tableau suivant donne les fréquences des génotypes pour 90 malades sélectionnés aléatoirement.

génotype	AA	Aa	aa
Fréquences observées (noi)	22	55	13

Tester au niveau de significativité  $\alpha = 0.01$  l'hypothèse que ces fréquences observées correspondent aux fréquences attendues.

### Solution

Les données ont été sélectionnées aléatoirement.

Il reste à vérifier que les fréquences attendues sont toutes d'au moins 5 et cela en calculant les nti.

$H_0$  : la distribution des génotypes des enfants est  $p_1=0.25(AA)$ ,  $p_2=0.5(Aa)$ ,  $p_3= 0.25 (aa)$ .

$H_1$  : au moins une des proportions ci-dessus est différente des valeurs supposées.

Calcul des nti.

génotype	AA	Aa	aa
Fréquences observées (noi)	22	55	13
nti = $n \cdot p_i$	$90 \cdot 0.25 = 22.5$	$90 \cdot 0.5 = 45$	$90 \cdot 0.25 = 22.5$
noi-nti	-0.5	10	-9.5
$(\text{noi} - \text{nti})^2$	0.25	100	90.25
$\frac{(\text{noi} - \text{nti})^2}{\text{nti}}$	0.0111	2.2222	4.0111


$$X^2_c = 0.111 + 0.2222 + 4.0111 = 6.2444.$$

La valeur critique est lu dans la table de khi deux ddl=3-1=2 et  $\alpha=0.01$  on a alors 9.210.

**Décision** :  $X^2_c$  ne tombe pas dans la région critique, il n'y a pas suffisamment de preuves pour garantir le rejet de  $H_0$ .

On ne peut pas rejeter l'hypothèse que la distribution est  $p_1=0.25$ ,  $p_2=0.5$ ,  $p_3=0.25$

## test d'adéquation



## 2) Test d'indépendance

### Tableaux de contingence : indépendance et homogénéité

Un tableau de contingence est un tableau dans lequel les fréquences correspondent à deux variables : une variable est utilisée en ligne et l'autre en colonne.

Un test d'indépendance teste l'hypothèse nulle qu'il n'y a pas d'association entre la variable en ligne et celle en colonne dans un tableau de contingence.

## Conditions requises.

- Les données d'échantillon ont été sélectionnées aléatoirement.
- $H_0$  est l'affirmation que les variables de ligne et de colonne sont indépendantes,  $H_1$  est l'affirmation que les variables de ligne et de colonne sont dépendantes.
- Pour chaque case du tableau de contingence, la fréquence attendue  $n_{ti}$  est au moins 5.

## Statistique de test

$$\chi_c^2 = \sum \frac{(n_{oi}j - n_{tij})^2}{n_{tij}}$$

## Valeurs critiques

la valeur est lue dans la table de khi deux et le degrés de liberté  $ddl = (r-1)(k-1)$

où  $r$  est le nombre de lignes et  $k$  le nombre de colonnes.

Dans un test d'indépendance la région critique est située à droite de la valeur critique.

## La fréquence attendue pour un tableau de contingence

$$n_{t_{ij}} = \frac{(\text{some de la ligne } i)(\text{somme de la colonne } j)}{n},$$

fréquence attendue pour la case  $ij$

**Exemple :** « test de l'efficacité de vaccin de Salk »

Dans une expérience, on a donné à des enfants le vaccin de Salk contre la polyométrie et à d'autres enfants un placebo. Les résultats de l'expérience sont résumés dans le tableau suivant

	Oui	non
Groupe traitement vaccin	33	200712
Groupe placebo	115	201114

Utiliser un niveau de significativité de 0.05 pour tester l'hypothèse d'indépendance entre les groupes et le traitement.

### Solution

Les données sont des comptages de fréquences indépendants.

Il reste à vérifier la 2<sup>ème</sup> condition ;  $nt_{ij} \geq 5$ .

On teste les hypothèses suivantes :

$H_0$  : recevoir le vaccin Salk est indépendant d'avoir la polio

$H_1$  : recevoir le vaccin Salk et avoir la polio sont dépendants.


Calcul des  $nt_{ij}$

	Oui	non
Groupe traitement vaccin	33 (73.911)	200712(200671.089)
Groupe placebo	115(74.089)	201114 (201154.911)

$$\chi_c^2 = \frac{(33-73.911)^2}{73.911} + \frac{(200712-200671.089)^2}{200671.089} + \frac{(115-74.089)^2}{74.089} + \frac{(201114-201154.911)^2}{201154.911}$$

$$= 22.645 + 0.008 + 22.591 + 0.008 = 45.252$$

La valeur critique est  $\chi^2 = 3.841$  trouvée dans la table de khi deux (ligne ddl=(r-1)(k-1)=(2-1)(2-1)=1 et colonne 0.05)



**Interprétation** comme la statistique de test tombe dans la région critique, on rejette  $H_0$  qui est « recevoir le vaccin Salk est indépendant d'avoir la polio ». il apparaît que les variables sont dépendantes.

