

# Test du Chi2 ( $\chi^2$ )

Dr Oumar Bassoum  
FMPO-ISED/UCAD

# Objectifs éducationnels

- Différencier un test de conformité d'un test d'indépendance
- Dessiner un tableau de contingence
- **Lire la table du  $X^2$  et calculer le nombre de degré de liberté**
- Réaliser un test de conformité
- Réaliser un test d'indépendance

# Plan du cours

- I. Généralités sur le Chi<sup>2</sup>**
- II. Test de conformité entre une distribution théorique et une distribution expérimentale**
- III. Indépendance de variables aléatoires. Tableau de contingence**
- IV. Test de Fischer**
- V. Les limites du Chi<sup>2</sup>**

# Généralités sur le test du Chi2 ( $\chi^2$ )

- C'est un test utilisé pour:
  - comparer une distribution théorique avec une distribution expérimentale ;
  - tester l'indépendance de deux variables aléatoires.

# Test de conformité entre une distribution théorique et une distribution expérimentale

## 2. Mesure de l'ampleur de l'écart entre les 2 distributions :

- Soit une distribution constituée de  $n$  observations classées en  $k$  classes : dans une classe  $i$  nous aurons :
  - $O_i$  : l'effectif observé dans la classe  $k_i$
  - $E_i$  : l'effectif espéré dans la classe  $k_i$  ;
- Pour mesurer l'écart entre la distribution théorique et la distribution observée, on calcule pour chaque classe  $\frac{(O_i - E_i)^2}{E_i}$  c'est-à-dire l'Écart Quadratique relatif.

# Test de conformité entre une distribution théorique et une distribution expérimentale

## 2. Mesure de l'ampleur de l'écart entre les 2 distributions :

- Pour l'ensemble des cases, on aura :

- $$\chi^2 = \sum_{i=1}^k \frac{(O_i - E_i)^2}{E_i}$$

Le  $\chi^2$  sera faible si les écarts entre les valeurs observées et les valeurs théoriques sont petits.  
Le  $\chi^2$  sera grand dans le cas contraire.

- PEARSON a montré que  $\chi^2 = \sum_{i=1}^k \frac{(O_i - E_i)^2}{E_i}$  suit une loi du  $\chi^2$  sous l'hypothèse  $H_0$ .

# Test de conformité entre une distribution théorique et une distribution expérimentale

## 3. Nombre de degrés de liberté (ddl):

- Le nombre de degrés de liberté associé au calcul du  $\chi^2$  prend la valeur  $\nu = k - 1$ , si la distribution théorique est entièrement spécifiée.

# Test de conformité entre une distribution théorique et une distribution expérimentale

## 4. Hypothèses statistiques :

**Soit :**

**$H_0$  : les observations suivent une distribution théorique spécifiée ;**

**$H_1$  : les observations ne suivent pas la distribution théorique spécifiée.**

# Test de conformité entre une distribution théorique et une distribution expérimentale

## 6. Exemple 1 :

On jette 120 fois un dé. On a observé les fréquences suivantes :

1	2	3	4	5	6
14	16	28	30	18	14

Peut-on en conclure au seuil de  $\alpha = 0.05$  que le dé est bien équilibré ?

# Test de conformité entre une distribution théorique et une distribution expérimentale

## 6. Exemple 1 : Solution

- Si le dé est bien équilibré, on doit théoriquement obtenir :
  - $120 \times 1/6 = 20$  fois 1 ; 20 fois le 2 ; .... ; d'où le tableau de contingence.

Face	1	2	3	4	5	6
Répartition théorique	20	20	20	20	20	20
Répartition observée	14	16	28	30	18	14

# Test de conformité entre une distribution théorique et une distribution expérimentale

## 6. Exemple 1 : Solution

$$\chi^2 = \frac{(14-20)^2}{20} + \frac{(16-20)^2}{20} + \frac{(28-20)^2}{20} + \frac{(30-20)^2}{20} + \frac{(18-20)^2}{20} + \frac{(14-20)^2}{20}$$

$$\chi^2 = 12.8$$

# Test de conformité entre une distribution théorique et une distribution expérimentale

## 6. Exemple 1 : Solution

- **Hypothèses:**

- $H_0$  : le dé est équilibré
- $H_1$  : le dé n'est pas équilibré.

- **Le nombre de degrés de liberté :**

- On n'utilise pas la distribution expérimentale pour définir la distribution théorique. D'où :  $v = 6 - 1 = 5$   
 $nddl = 5 = v$

# Test de conformité entre une distribution théorique et une distribution expérimentale

## 6. Exemple 1 : Solution

- **Règle de décision :**

- Lecture de  $\chi^2_{0.05; 5}$  à  $\alpha = 0.05$  et sur la ligne ddl = 5, on lit  $\chi^2_{\text{seuil}} = 11.070$

- **Conclusion :**

- Puisque  $\chi^2 = 12.8$  et  $\chi^2_{\text{seuil}} = 11.070$ , on rejette l'hypothèse nulle selon laquelle, le dé est équilibré.

# Indépendance de variables aléatoires ; Tableau de contingence

## 1. Cas des tableaux 2 x2:

- Soient 2 variables aléatoires A et B, chacune ayant 2 modalités :
- Exemple :
  - A -----→ sexe (masculin ou féminin) et
  - B -----→ réponse à un médicament ( bonne ou mauvaise).
- On peut construire le tableau suivant :

# Indépendance de variables aléatoires ; Tableau de contingence

## 1. Cas des tableaux 2 x2: (suite)

		REPOSES		TOTAL
		Bonne	Mauvaise	
SEXE	Masculin	17	13	30
	Féminin	20	10	30
TOTAL		37	23	60

# Indépendance de variables aléatoires ; Tableau de contingence

## 1. Cas des tableaux 2 x2: (suite)

- On peut ainsi calculer les effectifs théoriques de chaque case .
- **Règle** : *on multiplie le total de la ligne par le total de la colonne et on divise par le nombre total d'individus.*
- Ex : cas (1,2) =  $30 \times 23/60 = 11.5$

	REPONSES		TOTAL
	Bonne	Mauvaise	
Masculin	17 (18.5)	13 (11.5)	30
Féminin	20 (18.5)	10 (11.5)	30
<b>TOTAL</b>	37	23	60

# Indépendance de variables aléatoires ; Tableau de contingence

## 1. Cas des tableaux 2 x2: (suite)

- ***Nombre de degré de liberté :***

- Si on se donne les effectifs totaux ; si on place 1 valeur dans le tableau à 4 cases, toutes les autres valeurs sont fixées, d'où :

- $u = 1 \text{ ddl}$

- $u = (\text{nombre de lignes} - 1) \times (\text{nombre de colonnes} - 1) = (2-1) \times (2-1) = 1$

# Indépendance de variables aléatoires ; Tableau de contingence

## 1. Cas des tableaux 2 x2: (suite)

- *Calcul du  $\chi^2$ :*

- $$\chi^2 = \frac{(17-18.5)^2}{18.5} + \frac{(13-11.5)^2}{11.5} + \frac{(20-18.5)^2}{18.5} + \frac{(10-11.5)^2}{11.5}$$

- $$\chi^2 = 0.63$$

# Indépendance de variables aléatoires ; Tableau de contingence

## 1. Cas des tableaux 2 x2: (suite)

- **Hypothèses :**

- $H_0$ : les 2 caractères (Sexe, Réponse) sont indépendants ;
- $H_1$ : les 2 caractères ne sont pas indépendants.

- **Seuil de signification :  $\alpha = 0.05$**

- Lecture du  $\chi^2_{0.05; 1}$  dans la table :
- $\chi^2_{\text{seuil}} = 3.84$

# Indépendance de variables aléatoires ; Tableau de contingence

## 1. Cas des tableaux 2 x2: (fin)

- ***Décision :***

- $\chi^2 = 0.63$        $\chi^2 < \chi^2_{\text{seuil}}$

- *On retient donc l'hypothèse  $H_0$  (les 2 caractères sont indépendants). Il n'existe pas d'association entre la réponse au médicament et le sexe du malade.*

# Indépendance de variables aléatoires ; Tableau de contingence

## 2. Cas des petits échantillons:

Les effectifs théoriques calculés doivent être supérieurs à 5 pour que le  $\chi^2$  soit interprétable.

Le nombre total de sujets doivent être supérieur à 30.

Si ces conditions ne sont pas réalisées, on peut utiliser la correction de Yates à condition que les effectifs ne soient pas trop éloignés de 5.

On calcule le  $\chi^2$  en retranchant  $\frac{1}{2}$ .

$$\chi^2 \text{ Yates} = \sum_{i=1}^k \frac{(O_i - E_i - 0.5)^2}{E_i}$$

# Indépendance de variables aléatoires ; Tableau de contingence

## 2. Cas des petits échantillons: (suite)

- **Exemple :**

Sur un échantillon de 40 souris soumises à un carcinogène on a observé en fonction du sexe, le nombre de souris avec ou sans cancer.

	Cancer	Pas cancer	
Mâle	3	17	20
Femelle	6	14	20
	9	31	40

Question: Y-a-t-il une répartition différente des différents cancers?

# Indépendance de variables aléatoires ; Tableau de contingence

## 2. Cas des petits échantillons: (suite)

- **Exemple :**

Sur un échantillon de 40 souris soumises à un carcinogène on a observé en fonction du sexe, le nombre de souris avec ou sans cancer.

	Cancer	Pas cancer	
Mâle	3 (4,5)	17 (15,5)	20
Femelle	6 (4,5)	14 (15,5)	20
	9	31	40

Question: Y-a-t-il une répartition différente des différents cancers?

# Indépendance de variables aléatoires ; Tableau de contingence

## 2. Cas des petits échantillons: (suite)

### • Exemple : Solution

– Calcul des effectifs théoriques:

- $9 \times 20 / 40 = 4.5$
- $31 \times 20 / 40 = 15.5$

– Calcul du  $\chi^2$ :

- La cellule (1,1) a un effectif de  $4.5 < 5$ . Il faut utiliser la correction de Yates pour corriger le  $\chi^2$

$$\chi^2_{Yates} = \frac{(3 - 4.5 + 0.5)^2}{4.5} + \frac{(17 - 15.5 - 0.5)^2}{15.5} + \frac{(6 - 4.5 - 0.5)^2}{4.5} + \frac{(14 - 15.5 + 0.5)^2}{15.5}$$

- $\chi^2_{Yates} = 1/4.5 + 1/15.5 + 1/4.5 + 1/15.5 = 0.573$

- $\chi^2_{0.05;1} = 3.84$

– Il n'y a pas de différence statistiquement significative entre la répartition des cancers chez les mâles et chez les femelles.

# Indépendance de variables aléatoires ; Tableau de contingence

## 2. Cas des petits échantillons: (fin)

### Remarques :

Cette correction encore appelée correction de continuité est approximative.

On peut faire un calcul exact : c'est la méthode de FISHER (1930). Le principe est basé sur le calcul de la probabilité d'avoir une répartition particulière.

Ce calcul doit être fait si l'effectif est inférieur à 20 ou si un effectif d'une case est inférieur à 5.

# Indépendance de variables aléatoires ; Tableau de contingence

## 3. Cas des tableaux m lignes x n colonnes:

(suite)

On calcul de la même manière les effectifs théoriques.

–  $E(1,1) = S_1 \times T_1 / N$

–  $E(2,2) = S_2 \times T_1 / N$

Etc.

# Indépendance de variables aléatoires ; Tableau de contingence

## 3. Cas des tableaux m lignes x n colonnes:

On calcul aussi de la même manière le  $\chi^2$

$$\chi^2 = \sum \frac{(O - E)^2}{E}$$

Le nombre de degrés de liberté est égale à :

$$u = (m-1) \times (n-1)$$

La valeur seuil est donnée par la table du  $\chi^2$  à  $\alpha = 5\%$

$$\chi^2_{0.05;u}$$

On rejette l'hypothèse nulle  $H_0$  si  $\chi^2 > \chi^2_{0.05;u}$

# Indépendance de variables aléatoires ; Tableau de contingence

## 3. Cas des tableaux m lignes x n colonnes:

### Exemple :

On a sélectionné 3864 mariages au hasard en 1980. On a recherché le devenir de ces mariages 5 ans après en fonction de la résidence des jeunes ménages. On obtient la table de contingence suivante :

	Rural	Petite ville	Grande ville	
Encore mariés	287 (275.6)	1124 (1096.2)	2081 (2120.2)	3492
séparés	18 (29.4)	89 (116.8)	265 (255.8)	372
	305	1213	2346	3864

Y-a-t-il une indépendance entre le lieu de résidence et l'état marital ?

# Indépendance de variables aléatoires ; Tableau de contingence

## 3. Cas des tableaux m lignes x n colonnes:

**Exemple : Solution**

**Hypothèses :**

H0 : indépendance entre les états maritaux et la résidence.

H1 : dépendance entre les deux facteurs

**Seuil  $\alpha = 0.05$**

**Calcul des effectifs théoriques:**

- $(1,1) = (305 \times 3492) / 3864 = 275.6$
  - $(2,2) = (1213 \times 372) / 3864 = 116.8$
- Etc.

# Indépendance de variables aléatoires ; Tableau de contingence

## 3. Cas des tableaux m lignes x n colonnes:

### Exemple : Solution

- **Calcul du  $\chi^2$**

- $\chi^2 = (287-275.6)^2/275.6 + (1124 - 1096.2)^2/1096.2 + (2081-2120.2)^2/2120.2 + (18 - 29.4)^2/29.4 + (89 -116.8)^2/116.8 + (265 - 255.8)^2/255.8 = 19.68$
- $\chi^2 = 19.68$

- **Nombre de degrés de liberté**

- $u = (3-1) \times (2-1) = 2$

- **Recherche du  $\chi^2_{0.05;2}$  sur la table**

- $\chi^2_{0.05;2} = 5.991$

# Indépendance de variables aléatoires ; Tableau de contingence

## 3. Cas des tableaux m lignes x n colonnes:

### Exemple : Solution

- **Conclusion:**

- Il existe une dépendance entre la résidence et le statut marital, cinq ans après le mariage.
- Niveau de significativité sur la table  $\chi^2_{0.01;2} = 13.815$
- $\chi^2_{\text{calculé}} > \chi^2_{0.01;2}$
- L'hypothèse  $H_0$  est rejetée avec un niveau de significativité  $p > 0.001$ .

# Test de Fischer

- Ce test donne des résultats exacts pour des tables  $2 \times 2$  ;
- Mais il n'est utile que lorsque l'on s'attend à obtenir des valeurs espérées petites, c'est-à-dire lorsque le test du  $\chi^2$  n'est pas applicable.

# Test de Fischer

- **Exemple:**

Un échantillon de 40 souris est soumis à un agent carcinogène. On dénombre en fonction du sexe, le nombre de souris avec ou sans cancer.

	<b>Cancer</b>	<b>Pas cancer</b>	
<b>Mâle</b>	2 (3)	18 (17)	20
<b>Femelle</b>	4 (3)	16 (17)	20
	6	34	40

**Question:** Peut-on dire qu'il existe une répartition différente du nombre de cancers dans les 2 groupes ?

# Test de Fischer

- Exemple: Solution

- Calcul des effectifs théoriques :

- Case (1,1) =  $(6 \times 20) / 40 = 3$
    - Case (1,2) =  $(34 \times 20) / 40 = 17$

- On ne doit pas utiliser le test du  $\chi^2$  même corrigé par la correction de Yates car les effectifs théoriques sont trop faibles [3 pour la case (1,1) et 3 pour la case (2,1)].

# Test de Fischer

- Exemple: Solution

## Théorie :

- Supposons que  $P_1$  soit la probabilité de développer un cancer chez la souris mâle et  $P_2$  la probabilité de développer un cancer chez la souris femelle.
- On souhaite tester l'hypothèse nulle.
  - $H_0 : P_1 = P_2 = P$  vis-à-vis de l'hypothèse alternative
  - $H_1 : P_1 \neq P_2$

# Test de Fischer

- **Exemple:** Solution
- Théorie (suite)
  - Si les effectifs marginaux sont fixés, on peut calculer la probabilité d'observer une répartition particulière.

	Cancers	Pas cancers	
Mâle	a	b	a + b
Femelle	c	d	c + d
	a + c	b + d	n

# Test de Fischer

- **Exemple: Solution**
- **Théorie (suite)**
  - La probabilité exacte d'observer une répartition particulière sera :

- $$\Pr (a,b,c,d) = \frac{(a+b)!(c+d)!(a+c)!(b+d)!}{n!a!b!c!d!}$$

# Test de Fischer

- **Exemple:**
- Calcul de la probabilité d'observer la répartition (2,18,4,16)

$$\bullet \Pr (2,18,4,16) = \frac{20!20!6!34!}{40!2!18!4!16!} = \frac{19 \times 20 \times 17 \times 18 \times 19 \times 20 \times 5 \times 6}{2 \times 35 \times 36 \times 37 \times 38 \times 39 \times 40}$$

$$= \frac{19 \times 17 \times 15}{7 \times 37 \times 2 \times 39} = 0,2398$$

# Comparaison de deux pourcentages observés

## Cas de séries appariées:

On souhaite comparer 2 traitements A et B sur 100 malades, chacun recevant successivement les 2 traitements dans un ordre aléatoire.

Le résultat est noté (+) ou (-)

On obtient 100 couples de réponses :

# Comparaison de deux pourcentages observés: Cas de séries appariées

<b>Résultats avec</b>		<b>Nombre de malades</b>
<b>A</b>	<b>B</b>	
-	-	<b>35</b>
-	+	<b>5</b>
+	-	<b>15</b>
+	+	<b>45</b>
<b>TOTAL</b>		<b>10</b>

# Comparaison de deux pourcentages observés: Cas de séries appariées

	<b>0</b>
--	----------

# Comparaison de deux pourcentages observés: Cas de séries appariées

- On peut également faire un  $\chi^2$ :

	A	B	
+	60 (55)	50 (55)	110
-	40 (45)	50 (45)	90
	100	100	200

# Comparaison de deux pourcentages observés: Cas de séries appariées

- Les 2 séries ne sont pas indépendantes, la question posée est :
  - quel est le meilleur médicament ?
- Les réponses concordantes (- - et + +) n'apporte rien. On utilisera les réponses discordantes pour conclure.
  - On a observé 20 discordances soit (- +) 5 fois et (+ -) 15 fois.
- L'hypothèse nulle devrait donner 10 discordances dans un sens et 10 dans l'autre sens

# Comparaison de deux pourcentages observés: Cas de séries appariées

- $\chi^2$  Mc Némar

		B		
		+	-	
A	+	45	15	60
	-	5	35	40
		50	50	100

# Comparaison de deux pourcentages observés: Cas de séries appariées

- Khi2 de Mc Nemar:

$$\text{Khi2} = \quad = 5$$

- on rejette l'hypothèse nulle

# Limites du $\chi^2$

- Le  $\chi^2$  ne donne aucune information:
  - sur le sens de la liaison,
  - ni sur la force de la liaison.

**MERCI DE VOTRE ATTENTION**