


Tests relevant de la statistique du χ^2

Règle de décision :

- Déterminer la valeur critique de la statistique de test $\chi^2_{\text{théo}}$ délimitant les zones d'acceptation et rejet de H_0 (pour un risque α fixé , avec $\text{ddl} = \text{nb modalités} - 1$)
 → Table loi χ^2 (unilatéral)

Zone de rejet (bleu) : 5% des valeurs les plus extrêmes de la statistique de test qui n'ont presque aucune chance d'être observée si H_0 est vraie. ($\chi^2 = \text{unilatéral}$)



Tests relevant de la statistique du χ^2

Règle de décision :


- Calcul du χ^2_{obs} à partir des observations sur l'échantillon

→ Comparaison à distribution sous H_0 : si $\chi^2_{obs} \geq \chi^2_{\text{théo}}$ → rejet H_0 (accepte H_1)

- On peut aussi utiliser la **p-value (aire rouge)**:

« *probabilité d'obtenir sous H_0 une valeur de la statistique de test au moins aussi extrême que celle obtenue à partir des observations* »

→ Si p-value < α , on rejette H_0 et on accepte H_1




Tests relevant de la statistique du χ^2

Règle de décision :

Quelques remarques :

- Si χ^2_{obs} très faible = bonne adéquation à la distribution théorique \rightarrow non rejet de H_0 .
- Plus χ^2_{obs} (écart effectif observés et attendus) sera grand, moins H_0 sera probable.
- Pour un même écart, χ^2_{obs} sera d'autant plus grand que l'effectif total est grand.



Tests relevant de la statistique du χ^2

Application :

On a effectué le croisement de balsamines blanches avec des balsamines pourpres. En première génération (F1) les fleurs sont toutes pourpres.



On obtient en seconde génération (F2) 4 catégories avec les effectifs suivants :

Couleur	Pourpre	Rose	Blanc lavande	blanc
Effectifs	1790	547	548	213

Peut on accepter l'hypothèse de répartition mendélienne
(9/16, 3/16, 3/16, 1/16) pour $\alpha = 0.05$?

→ *Revoir la réalisation du test « à la main » en vidéo sur Moodle* ←

Tests relevant de la statistique du χ^2

Solution :

H_0 : distribution observée **conforme** à la théorique

H_1 : distribution observée **non conforme** à la théorique




Trouver $\chi^2_{théo}$ dans la table de la loi du χ^2 :

pour $\alpha = 0.05$

et degré de liberté (ddl) =

nb modalités-1 = 4 - 1 = 3

→ $\chi^2_{théo} = 7.81$



$n \setminus \alpha$	0.99	0.975	0.95	0.9	0.1	0.05	0.025	0.01	0.001
1	0.0002	0.001	0.0039	0.0158	2.71	3.84	5.02	6.63	10.83
2	0.02	0.05	0.1	0.21	4.61	5.99	7.38	9.21	13.82
3	0.11	0.22	0.35	0.58	6.25	7.81	9.35	11.34	16.27
4	0.3	0.48	0.71	1.06	7.78	9.49	11.14	13.28	18.47

ddl →

Tests relevant de la statistique du χ^2

Solution :

H_0 : distribution observée **conforme** à la théorique

H_1 : distribution observée **non conforme** à la théorique

$$\chi^2_{théo} = 7.81$$



Effectifs observés

Proportions attendues

Effectifs attendus

Couleurs	Pourpre	Rose	B-Lavande	Blanc	Totaux
O_i	1790	547	548	213	3098 = n
p_i	9/16	3/16	3/16	1/16	1

Tests relevant de la statistique du χ^2

Solution :

H_0 : distribution observée **conforme** à la théorique

H_1 : distribution observée **non conforme** à la théorique

$$\chi^2_{théo} = 7.81$$

Effectifs observés

Proportions attendues

Effectifs attendus



Couleurs	Pourpre	Rose	B-Lavande	Blanc	Totaux
O_i	1790	547	548	213	3098 = n
p_i	9/16	3/16	3/16	1/16	1
$c_i = n * p_i$	1742.6	580.8	580.8	193.8	3098 = n

$$\chi^2 = \sum \frac{(O_i - C_i)^2}{C_i}$$

$$\chi^2_{obs} = \frac{(1790 - 1742.6)^2}{1742.6} + \frac{(547 - 580.8)^2}{580.8} + \frac{(548 - 580.8)^2}{580.8} + \frac{(213 - 193.8)^2}{193.8} = 7.06$$

$\chi^2_{obs} < \chi^2_{théo}$ **non rejet de H_0** → Hypothèse de répartition mendélienne acceptée

Effectuer ce test sous R

Code : 1) On crée les vecteurs de données :

```
eff_obs<-c(1790,547,548,213)
prop_theo<-c(9/16,3/16,3/16,1/16)
```

```
eff_theo<-sum(eff_obs)*prop_theo ←  $C_i = n * p_i$ 
```

```
ifelse(sum(eff_theo)==sum(eff_obs),
      "c'est bon!:", "y'a un pb! :(") ← Doit être == effectif total
```

2) On utilisera la fonction « **chisq.test** » :

```
chisq.test(eff_obs,p=prop_theo)
```

ou

```
chisq.test(eff_obs,p=eff_theo,rescale.p = T)
```

Quand on donne 1 vecteur d'effectifs (R doit recalculer les probabilités théoriques)

Effectuer ce test sous R

Sortie : A vous d'interpréter la sortie R!

chi-squared test for given probabilities

```
data: c(1790, 547, 548, 213)
x-squared = 7.0628, df = 3, p-value = 0.06992
```

↑
 χ^2_{obs}

↑
ddl

↑
p-value > 0.05, non rejet de H0

Tests relevant de la statistique du χ^2

20

3) Test d'homogénéité /d'égalité

But : Comparer la distribution d'1 VA qualitative V1 observée dans J populations
→ vérifier que la répartition des effectifs dans les différentes modalités sont équivalentes entre les J échantillons (suivent la même loi de probabilité).

Ex : Est-ce que la distribution des groupes sanguins est homogènes entre les localités A et B ?

2 variables qualitatives:

V1: VA d'intérêt (VD) à I modalités mesurée sur les individus statistiques



V2 : Variable (VI) à J modalités, **fixées** par l'expérimentateur, **déterminant** les **échantillons** (groupes) à comparer

Tests relevant de la statistique du χ^2

Les données :

Tableau de contingence (TDC) = croise les modalités de 2 variables qualitatives (**V1** en colonnes et **V2** en lignes) et contient des **effectifs observés** O_{ij} (N individus distribués dans le $I \times J$ cases du tableau).

Structure TDC:

		Modalités de V1			Σ effectifs obs. par ligne
		1	i	I	
Modalités de V2	1 (échantillon A)	O_{11}	O_{1i}	O_{1I}	$n_{1.}$
	J (échantillon B)	O_{J1}	O_{Ji}	O_{JI}	$n_{J.}$
Σ effectifs obs. par colonne		Marge ligne	$n_{.1}$	$n_{.i}$	$n_{.I}$
					N

Effectif total

Tests relevant de la statistique du χ^2

Les hypothèses :

H_0 : la distribution de V1 est identique dans toutes les populations d'où sont tirés les échantillons (V2) → homogénéité/égalité des effectifs entre échs.

Les échantillons proviennent de la même population et les différences d'effectifs observées sont dues aux fluctuations d'échantillonnage.

H_1 : la distribution de V1 n'est pas identique dans toutes les populations d'où sont tirés les échs (V2) → hétérogénéité/différence des effectifs entre échs.

Ils proviennent de populations différentes et les variations observées sont liées aux caractéristiques des groupes comparés (= modalités du facteur principal V2).

Tests relevant de la statistique du χ^2

La statistique de test :

Avec : O_{ij} = effectif observé et C_{ij} = effectif attendu

$$\chi^2 = \sum \frac{(O_{ij} - C_{ij})^2}{C_{ij}}$$

Comment calculer l'effectif théorique attendu C_{ij} si inconnu?

$$C_{ij} = \frac{\text{Total au bout de la ligne} \times \text{total au bout de la colonne}}{\text{Effectif total}}$$

$$\text{Ex : } C_{11} = \frac{n_{1.} \times n_{.1}}{N}$$

V2/V1	1	i	I	Marge colonne
1 (échantillon A)	O_{11}	O_{1i}	O_{1I}	$n_{1.}$
	C_{11}	C_{1i}	C_{1I}	
J (échantillon B)	O_{J1}	O_{Ji}	O_{JI}	$n_{J.}$
	C_{J1}	C_{Ji}	C_{JI}	
Marge ligne	$n_{.1}$	$n_{.i}$	$n_{.I}$	N


Tests relevant de la statistique du χ^2

Règle de décision :

- Déterminer la valeur de la statistique de test $\chi^2_{\text{théo}}$ au seuil α et avec **ddl** = (nb modalités V1 -1)*(nb modalités V2 -1) → Table loi χ^2 (unilatéral)
- Calcul du χ^2_{obs} à partir des observations sur les échantillons
 → Si $\chi^2_{\text{obs}} \geq \chi^2_{\text{théo}}$ ou p-value < α , on rejette H_0 et on accepte H_1

Les différences d'effectifs observées entre les échantillons sont :

- soit dues aux fluctuations d'échantillonnage (H_0),
- soit liées aux modalités des groupes comparés = effet du facteur principal testé (H_1).



Tests relevant de la statistique du χ^2

Application :

On veut comparer le salaire des femmes et des hommes dans une entreprise. On prend un échantillon de 120 hommes et un échantillon de 150 femmes puis on note le salaire : "faible", "moyen" ou "élevé".



On observe les effectifs suivants :

	Faible	Moyen	Elevé	Marge colonne
Homme	10	70	40	120
Femme	30	60	60	150
Marge ligne	40	130	100	270

Peut-on dire au seuil $\alpha=5\%$ que les hommes et les femmes ont un niveau de salaire équivalent?

→ *Revoir la réalisation du test « à la main » en vidéo sur Moodle* ←

Tests relevant de la statistique du χ^2

Solution :

H_0 : les distributions observées sont équivalentes


H_1 : les distributions observées sont différentes





Trouver $\chi^2_{th\acute{e}o}$ dans la table de la loi du χ^2 :

pour $\alpha = 0.05$

et $ddl = (\text{nb de modalités V1} - 1) * (\text{nb de modalités V2} - 1)$
 $= (3-1) * (2-1) = 2$



→ $\chi^2_{th\acute{e}o} = 5.99$

$n \backslash \alpha$	0.99	0.975	0.95	0.9	0.1	0.05	0.025	0.01	0.001
1	0.0002	0.001	0.0039	0.0158	2.71	3.84	5.02	6.63	10.83
2	0.02	0.05	0.1	0.21	4.61	5.99	7.38	9.21	13.82
3	0.11	0.22	0.35	0.58	6.25	7.81	9.35	11.34	16.27

Tests relevant de la statistique du χ^2

Solution :

H_0 : les distributions observées sont équivalentes

H_1 : les distributions observées sont différentes

$$\chi^2_{théo} = 5.99$$



	Faible	Moyen	Elevé	Marge colonne
Homme	10	70	40	120
	17.8	57.8	44.4	
Femme	30	60	60	150
	22.2	72.2	55.6	
Marge ligne	40	130	100	270

$$C_{ij} = \frac{\text{Total au bout de la ligne} \times \text{total au bout de la colonne}}{\text{Effectif total}}$$

$$\text{Ex : } C_{11} = \frac{120 \times 40}{270} = 17.8$$

Tests relevant de la statistique du χ^2

Solution :

H_0 : les distributions observées sont équivalentes

H_1 : les distributions observées sont différentes

$$\chi^2_{théo} = 5.99$$



$$\chi^2 = \sum \frac{(O_{ij} - C_{ij})^2}{C_{ij}}$$

	Faible	Moyen	Elevé	Marge colonne
Homme	10	70	40	120
Femme	30	60	60	150
Marge ligne	40	130	100	270

$$\chi^2_{obs} = \frac{(10 - 17.8)^2}{17.8} + \frac{(70 - 57.8)^2}{57.8} + \dots + \frac{(60 - 72.2)^2}{72.2} + \frac{(60 - 55.6)^2}{55.6} = 11.58$$

$\chi^2_{obs} > \chi^2_{théo}$ **rejet de H_0** → hommes et femmes sont traités différemment au niveau du salaire

Effectuer ce test sous R

Code :

```

### Rentrer les données
# vecteurs des 2 echs (effectifs obs)
Hom<-c(10,70,40)
Fem<-c(30,60,60)

# en faire une matrice
table<- matrix(c(Hom, Fem), 2, 3, byrow=T)

```

Matrice au format : 2 L * 3 C

Remplissage par lignes
(T=TRUE)

```

# ajouter le noms de lignes et colonnes
colnames(table)<-c("Faible", "Moyen", "Elevé")
row.names(table)<-c("Homme", "Femme")

# pour ajouter les marges L et C
addmargins(table)

```

Sortie :

	Faible	Moyen	Elevé	Sum
Homme	10	70	40	120
Femme	30	60	60	150
Sum	40	130	100	270

← Tableau de
contingence

Effectuer ce test sous R

Code : On utilise « **chisq.test** », directement sur la matrice qu'on vient de créer :

```
khi_test2 <- chisq.test(table)
khi_test2
```

↑
La matrice 2 L * 3 C

Sortie : Pearson's Chi-squared test

```
data: table
X-squared = 11.579, df = 2, p-value = 0.00306
```

↑
 χ^2_{obs}

↑
ddl

↑

p-value très significative (< 0.01)
→ rejet de H0

Effectuer ce test sous R

31


Signif. codes: 0 ‘***’ 0.001 ‘**’ 0.01 ‘*’ 0.05 ‘.’ 0.1 ‘ ’ 1

P-value	Code	Niveau de significativité
1 à 0.1		Non Significatif (NS)
0.1 à 0.05	.	« presque » significatif
0.05 à 0.01	*	Significatif
0.01 à 0.001	**	Très significatif
0.001 à 0	***	Hautement significatif

Effectuer ce test sous R

Code : ## Récupérer les valeurs compilées dans le test :

```
#effectifs attendus (théoriques)
round(khi_test2$expected,2)
```



Arrondir à 2 chiffres
après la virgule

Sortie :

	Faible	Moyen	Élevé
Homme	17.78	57.78	44.44
Femme	22.22	72.22	55.56

NB: l'objet *khi_test2* est une liste!

●	khi_test2	list [9] (S3: htest)	List of length 9
●	statistic	double [1]	11.57885
●	parameter	integer [1]	2
	p.value	double [1]	0.003059747
	method	character [1]	'Pearson\'s Chi-squared test'
	data.name	character [1]	'table'
	observed	double [2 x 3]	10 30 70 60 40 60
	expected	double [2 x 3]	17.8 22.2 57.8 72.2 44.4 55.6
	residuals	double [2 x 3]	-1.845 1.650 1.608 -1.438 -0.667
	stdres	double [2 x 3]	-2.68 2.68 3.00 -3.00 -1.13 1.13

Tests relevant de la statistique du χ^2

4) Test d'indépendance

1 seul échantillon de n individus statistiques (issus d'1 seule population), sur lesquels on mesure simultanément 2 caractéristiques (2 VA quali. V1 et V2).

But : Tester l'existence d'un lien statistique entre ces 2 variables qui seraient susceptibles de créer une différence de répartition d'effectif par rapport à ceux attendus sous l'hypothèse d'indépendance.

Qu'est ce que veut dire l'indépendance ? 2 variables sont dites indépendantes lorsque les variations de l'une n'a aucune influence sur les variations de l'autre.

Ex : est-ce que connaître le sexe de quelqu'un permet de supposer la couleur de ses cheveux?

Réponse : non.

est-ce que connaître l'origine ethnique de quelqu'un permet de supposer celle de ses yeux?

Réponse : peut-être bien...