

CORRIGES DES EXERCICES : Tests du khi-deux d'homogénéité et d'indépendance


Exercice 1

$\mathcal{P} = \{\text{patients d'un hôpital psychiatrique}\}$, $X = \text{saison}$ définie sur $E = \{\text{printemps, été, automne, hiver}\}$ variable qualitative à 4 modalités, $Y = \text{réaction à un certain médicament}$ définie sur $F = \{\text{oui, non}\}$ variable qualitative à 2 modalités.

Test du khi-deux d'indépendance : $\begin{cases} H_0: X \text{ et } Y \text{ indépendantes} \\ H_1: X \text{ et } Y \text{ liées} \end{cases}$ au risque $\alpha = 5\%$.

Sur deux échantillons appariés de X et de Y de taille $n = 490$, les effectifs observés n_{ij} et les effectifs théoriques (attendus) e_{ij} notés entre parenthèses :

X saison	Y réaction	
	oui	non
printemps	55 (54,9)	64 (64,1)
été	59 (54,9)	60 (64,1)
automne	52 (53)	63 (62)
hiver	60 (63,2)	77 (73,8)



Sous H_0 , la statistique de test Q^2 suit approximativement une loi du khi-deux à 3 ddl car $n > 30$ et tous les e_{ij} sont supérieurs à 5. La région de rejet du test au risque 5% est $\mathcal{R}_{5\%} = [x^2_{3,5\%}; +\infty[= [7,81; +\infty[$ car $x^2_{3,5\%}$ est le quantile d'ordre 0,95 de la loi χ^2_3 , et la valeur observée de Q^2 vaut $q^2 = 0,9 \notin \mathcal{R}_{5\%}$. Donc on ne rejette pas H_0 au risque 5% : il n'existe pas de lien entre la saison et la réaction au risque $\alpha = 5\%$.

Exercice 2


$\mathcal{P}_1 = \{\text{lycéens du lycée A}\}$, $X_1 = \text{résultat à l'examen dans le lycée A}$
 $\mathcal{P}_2 = \{\text{lycéens du lycée B}\}$, $X_2 = \text{résultat à l'examen dans le lycée B}$
 X_1 et X_2 variables qualitatives à 2 modalités définies sur $E = \{\text{réussite, échec}\}$.

Test du khi-deux d'homogénéité sur 2 populations avec une variable à 2 modalités c'est à dire un test de comparaison de deux proportions sur 2 échantillons indépendants (procédure bilatérale) :

$$\begin{cases} H_0: p_1 = p_2 \\ H_1: p_1 \neq p_2 \end{cases} \quad \text{où} \quad \begin{cases} p_1 = \text{proportion de réussite dans le lycée A} \\ p_2 = \text{proportion de réussite dans le lycée B} \end{cases}$$

Sur deux échantillons indépendants de tailles $n_1 = 100$ et $n_2 = 120$, les effectifs observés n_{ij} et les effectifs théoriques (attendus) e_{ij} notés entre parenthèses :

X résultat	lycée	
	A	B
réussite	40 (34,1)	35 (40,9)
échec	60 (65,9)	85 (79,1)



Sous H_0 , la statistique de test Q^2 suit approximativement une loi du khi-deux à 1 ddl car $n = n_1 + n_2 > 30$ et tous les e_{ij} sont supérieurs à 5. La région de rejet du test au risque 5% est $\mathcal{R}_{5\%} = [x^2_{1,5\%}; +\infty[= [3,84; +\infty[$ car $x^2_{1,5\%}$ est le quantile d'ordre 0,95 de la loi χ^2_1 , et la valeur observée de Q^2 : $q^2 = 2,85 \notin \mathcal{R}_{5\%}$. Donc on ne rejette pas H_0 au risque 5% : la proportion de réussite est la même dans les deux lycées au risque $\alpha = 5\%$.

La région de rejet du test au risque 10% est $\mathcal{R}_{10\%} = [x_{1,10\%}^2; +\infty[= [2,71; +\infty[$ car $x_{1,10\%}^2$ est le quantile d'ordre 0,9 de la loi χ_1^2 , et la valeur observée de Q^2 : $q^2 = 2,85 \in \mathcal{R}_{10\%}$. Donc on rejette H_0 au risque 10% : la proportion de réussite est différente dans les deux lycées au risque $\alpha=10\%$.

Correction de Yates : sous H_0 , la statistique de test du khi-deux corrigé Q_Y^2 suit approximativement une loi du khi-deux à 1 ddl car $n > 30$ et tous les e_{ij} sont supérieurs à 5. La valeur observée de Q_Y^2 : $q_Y^2 = 2,39$.

$q_Y^2 \notin \mathcal{R}_{5\%}$: on ne rejette pas H_0 au risque 5%.

$q_Y^2 \notin \mathcal{R}_{10\%}$: on ne rejette pas H_0 au risque 10%.

Exercice 3

$\mathcal{P} = \{\text{personnes}\}$, $X = \text{niveau d'instruction définie sur } E = \{\text{BEPC, BAC, universitaire}\}$ variable qualitative à 3 modalités, $Y = \text{opinion sur le droit de vote à 16 ans définie sur } F = \{\text{pour, contre}\}$ variable qualitative à 2 modalités.

Test du khi-deux d'indépendance : $\begin{cases} H_0: X \text{ et } Y \text{ indépendantes} \\ H_1: X \text{ et } Y \text{ liées} \end{cases}$ au risque $\alpha=5\%$.

Sur deux échantillons appariés de X et de Y de taille $n=250$, les effectifs observés n_{ij} et les effectifs théoriques (attendus) e_{ij} notés entre parenthèses :

niveau d'instruction	opinion	
	pour	contre
BEPC	10 (5,1)	15 (19,9)
BAC	21 (21,4)	84 (83,6)
universitaire	20 (24,5)	100 (95,5)

Sous H_0 , la statistique de test Q^2 suit approximativement une loi du khi-deux à 2 ddl car $n > 30$ et tous les e_{ij} sont supérieurs à 5. La région de rejet du test au risque 5% est $\mathcal{R}_{5\%} = [x_{2,5\%}^2; +\infty[= [5,99; +\infty[$ car $x_{2,5\%}^2$ est le quantile d'ordre 0,95 de la loi χ_2^2 , et la valeur observée de Q^2 vaut $q^2 = 6,95 \in \mathcal{R}_{5\%}$. Donc on rejette H_0 au risque 5% : il existe un lien entre l'opinion d'une personne et son niveau d'instruction au risque $\alpha=5\%$.

Exercice 4

$\mathcal{P}_1 = \{\text{étudiants du collège I}\}$, $X_1 = \text{participation à un club sportif dans le collège I}$

$\mathcal{P}_2 = \{\text{étudiants du collège II}\}$, $X_2 = \text{participation à un club sportif dans le collège II}$

X_1 et X_2 variables qualitatives à 2 modalités définies sur $E = \{\text{oui, non}\}$.

Test du khi-deux d'homogénéité sur 2 populations avec une variable à 2 modalités c'est à dire un test de comparaison de deux proportions sur 2 échantillons indépendants (procédure bilatérale) :

$\begin{cases} H_0: p_1 = p_2 \\ H_1: p_1 \neq p_2 \end{cases}$ où $\begin{cases} p_1 = \text{taux de participation dans le collège I} \\ p_2 = \text{taux de participation dans le collège II} \end{cases}$

Sur deux échantillons indépendants de X_1 et X_2 de tailles $n_1=50$ et $n_2=60$, les effectifs observés n_{ij} et les effectifs théoriques (attendus) e_{ij} notés entre parenthèses :

X participation	collège	
	I	II
oui	12 (17,3)	26 (20,7)
non	38 (32,7)	34 (39,3)

Sous H_0 , la statistique de test Q^2 suit approximativement une loi du khi-deux à 1 ddl car $n=n_1+n_2 > 30$ et tous les e_{ij} sont supérieurs à 5. La région de rejet du test au risque 5% est $\mathcal{R}_{5\%} = [x_{1,5\%}^2; +\infty[= [3,84; +\infty[$ car $x_{1,5\%}^2$ est le quantile d'ordre 0,95 de la loi χ_1^2 , et la valeur observée de Q^2 : $q^2 = 4,51 \in \mathcal{R}_{5\%}$. Donc on rejette pas H_0 au risque 5% : le taux de participation n'est pas le même dans les deux collèges au risque $\alpha=5\%$.

Correction de Yates : sous H_0 , la statistique de test du khi-deux corrigé Q_Y^2 suit approximativement une loi du khi-deux à 1 ddl car $n=n_1+n_2 > 30$ et tous les e_{ij} sont supérieurs à 5. La valeur observée de Q_Y^2 : $q_Y^2 = 3,69 \in \mathcal{R}_{5\%}$. Donc on ne rejette pas H_0 au risque 5%: le taux de participation est le même dans les deux

collèges au risque $\alpha=5\%$. Dans ce cas les conclusions diffèrent entre les tests du khi-deux et du khi-deux corrigé.

Exercice 5

$\mathcal{P}=\{\text{enfants}\}$, $X=\text{note au test de Peabody}$ définie sur $E=\{[60;86[; [86;111[]\}$ variable qualitative à 2 modalités, $Y=\text{sexe}$ définie sur $F=\{\text{fille, garçon}\}$ variable qualitative à 2 modalités.

Test du khi-deux d'indépendance : $\begin{cases} H_0: X \text{ et } Y \text{ indépendantes} \\ H_1: X \text{ et } Y \text{ liées} \end{cases}$ au risque $\alpha=10\%$.

Sur deux échantillons appariés de X et Y de taille $n=85$, les effectifs observés n_{ij} et les effectifs théoriques (attendus) e_{ij} notés entre parenthèses :

X note	Y sexe	
	fille	garçon
[60 - 86[31 (30,1)	33 (9,9)
[86 - 111[9 (33,9)	12 (11,1)

Sous H_0 , la statistique de test Q^2 suit approximativement une loi du khi-deux à 1 ddl car $n>30$ et tous les e_{ij} sont supérieurs à 5. La région de rejet du test au risque 10% est $\mathcal{R}_{10\%} = [x_{1;10\%}^2; +\infty[= [2,71; +\infty[$ car $x_{1;10\%}^2$ est le quantile d'ordre 0,9 de la loi χ_1^2 , et la valeur observée de $Q^2 : q^2 = 0,21 \notin \mathcal{R}_{10\%}$. Donc on ne rejette pas H_0 au risque 10% : le sexe et la note au test de Peabody sont indépendantes au risque $\alpha=10\%$.

Correction de Yates : sous H_0 , la statistique de test du khi-deux corrigé Q_Y^2 suit approximativement une loi du khi-deux à 1 ddl car $n>30$ et tous les e_{ij} sont supérieurs à 5. La valeur observée de $Q_Y^2 : q_Y^2 = 0,04 \notin \mathcal{R}_{10\%}$ donc on ne rejette pas H_0 au risque 10%.

Exercice 6

$\mathcal{P}=\{\text{enfants}\}$, $X=\text{réussite scolaire}$ définie sur $E=\{\text{bonne, moyenne, médiocre}\}$ variable qualitative à 3 modalités, $Y=\text{adaptation sociale}$ définie sur $F=\{\text{bonne, moyenne, mauvaise}\}$ variable qualitative à 3 modalités.

Test du khi-deux d'indépendance : $\begin{cases} H_0: X \text{ et } Y \text{ indépendantes} \\ H_1: X \text{ et } Y \text{ liées} \end{cases}$ aux risques $\alpha=5\%$ et $\alpha=1\%$.

Sur deux échantillons appariés de X et de Y de taille $n=200$, les effectifs observés n_{ij} et les effectifs théoriques (attendus) e_{ij} notés entre parenthèses :

X réussite scolaire	Y adaptation sociale		
	bonne	moyenne	mauvaise
bonne	29 (20,4)	18 (20,4)	13 (19,2)
moyenne	22 (25,5)	29 (25,5)	24 (24)
médiocre	17 (22,1)	21 (22,1)	27 (20,8)

Sous H_0 , la statistique de test Q^2 suit approximativement une loi du khi-deux à 4 ddl car $n>30$ et tous les e_{ij} sont supérieurs à 5. La région de rejet du test au risque 5% est $\mathcal{R}_{5\%} = [x_{4;5\%}^2; +\infty[= [9,49; +\infty[$ car $x_{4;5\%}^2$ est le quantile d'ordre 0,95 de la loi χ_4^2 , et la valeur observée de Q^2 vaut $q^2 = 9,95 \in \mathcal{R}_{5\%}$. Donc on rejette H_0 au risque 5% : il existe un lien entre réussite scolaire et adaptation sociale au risque $\alpha=5\%$.

La région de rejet du test au risque 1% est $\mathcal{R}_{1\%} = [x_{4;1\%}^2; +\infty[= [13,28; +\infty[$ car $x_{4;1\%}^2$ est le quantile d'ordre 0,99 de la loi χ_4^2 , et la valeur observée de $Q^2 : q^2 = 9,95 \notin \mathcal{R}_{1\%}$. Donc on ne rejette pas H_0 au risque 1% : réussite scolaire et adaptation sociale sont indépendantes au risque $\alpha=1\%$.

Exercice 7

$\mathcal{P} = \{\text{personnes}\}$, $X = \text{opinion sur l'avortement}$ définie sur $E = \{\text{pour, contre}\}$ variable qualitative à 2 modalités, $Y = \text{nombre d'années de scolarité}$ définie sur $F = \{\text{moins de 8 ans, entre 9 et 12 ans, plus de 12 ans}\}$ variable qualitative à 3 modalités.

Test du khi-deux d'indépendance : $\begin{cases} H_0: X \text{ et } Y \text{ indépendantes} \\ H_1: X \text{ et } Y \text{ liées} \end{cases}$ au risque $\alpha = 0,001$.

Sur deux échantillons appariés de X et de Y de taille $n = 625$, les effectifs observés n_{ij} et les effectifs théoriques (attendus) e_{ij} notés entre parenthèses :

X scolarité	Y opinion sur l'avortement	
	pour	contre
moins de 8 ans	31 (44,3)	56 (42,7)
entre 9 et 12 ans	171 (177)	177 (171)
plus de 12 ans	116 (96,7)	74 (93,3)

Sous H_0 , la statistique de test Q^2 suit approximativement une loi du khi-deux à 2 ddl car $n > 30$ et tous les e_{ij} sont supérieurs à 5. La région de rejet du test au risque 0,001 est $\mathcal{R}_{0,001} = [x_{2;0,001}^2; +\infty[= [13,82; +\infty[$ car $x_{2;0,001}^2$ est le quantile d'ordre 0,999 de la loi χ_2^2 , et la valeur observée de Q^2 : $q^2 = 16,38 \in \mathcal{R}_{0,001}$. Donc on rejette H_0 au risque 0,001 : il existe un lien entre l'opinion sur l'avortement et la durée de la scolarité au risque $\alpha = 0,001$.

Exercice 8

$\mathcal{P}_1 = \{\text{élèves de terminale du département I}\}$, $X_1 = \text{nature du bac préparé dans le département I}$

$\mathcal{P}_2 = \{\text{élèves de terminale du département II}\}$, $X_2 = \text{nature du bac préparé dans le département II}$

$\mathcal{P}_3 = \{\text{élèves de terminale du département III}\}$, $X_3 = \text{nature du bac préparé dans le département III}$

X_1, X_2 et X_3 variables qualitatives à 4 modalités définies sur $E = \{A, B, C, D\}$.

Test du khi-deux d'homogénéité : $\begin{cases} H_0: \text{les 3 populations sont homogènes vis à vis de } X \\ H_1: \text{les 3 populations sont hétérogènes vis à vis de } X \end{cases}$ au risque $\alpha = 1\%$

ou $\begin{cases} H_0: X \text{ a la même distribution dans les 3 populations} \\ H_1: X \text{ a des distributions différentes dans les 3 populations} \end{cases}$

Sur trois échantillons indépendants de X_1, X_2 et X_3 , les effectifs observés n_{ij} et les effectifs théoriques (attendus) e_{ij} notés entre parenthèses :

X baccalauréat	département					
	I		II		III	
A	11	(32,2)	30	(25,3)	39	(22,5)
B	51	(46,7)	36	(36,7)	29	(32,7)
C	32	(20,9)	14	(16,4)	6	(14,6)
D	46	(40,2)	30	(31,6)	24	(28,2)

Sous H_0 , la statistique de test Q^2 suit approximativement une loi du khi-deux à 6 ddl car $n = n_1 + n_2 + n_3 = 140 + 110 + 98 > 30$ et tous les e_{ij} sont supérieurs à 5. La région de rejet du test au risque 1% est $\mathcal{R}_{1\%} = [x_{6;1\%}^2; +\infty[= [16,81; +\infty[$ car $x_{6;1\%}^2$ est le quantile d'ordre 0,99 de la loi χ_6^2 , et la valeur observée de Q^2 : $q^2 = 40,55 \in \mathcal{R}_{1\%}$. Donc on rejette H_0 au risque 1% : les élèves de terminale ne se répartissent pas de façon homogène dans les trois départements choisis, quant à la nature du baccalauréat qu'ils préparent, au risque $\alpha = 1\%$.

Exercice 9

$\mathcal{P}_1 = \{\text{sujets du groupe expérimental recevant le somnifère}\}$, $X_1 = \text{amélioration du sommeil avec le somnifère}$

$\mathcal{P}_2 = \{\text{sujets du groupe témoin recevant le placebo}\}$, $X_2 = \text{amélioration du sommeil avec le placebo}$

X_1 et X_2 variables qualitatives à 2 modalités définies sur $E = \{\text{oui, non}\}$.

Test du khi-deux d'homogénéité sur 2 populations avec une variable à 2 modalités c'est à dire un test de comparaison de deux proportions sur 2 échantillons indépendants (procédure bilatérale) :

$$\begin{cases} H_0: p_1 = p_2 \\ H_1: p_1 \neq p_2 \end{cases} \quad \text{ou} \quad \begin{cases} p_1 = \text{proportion d'amélioration du sommeil dans le groupe expérimental} \\ p_2 = \text{proportion d'amélioration du sommeil dans le groupe témoin} \end{cases}$$

Sur deux échantillons indépendants de X_1 et X_2 de tailles $n_1 = n_2 = 50$, les effectifs observés n_{ij} et les effectifs théoriques (attendus) e_{ij} notés entre parenthèses :

X amélioration	groupe	
	expérimental	témoin
oui	30 (27,5)	25 (27,5)
non	20 (22,5)	25 (22,5)

Sous H_0 , la statistique de test Q^2 suit approximativement une loi du khi-deux à 1 ddl car $n = n_1 + n_2 > 30$ et tous les e_{ij} sont supérieurs à 5. La région de rejet du test au risque 1% est $\mathcal{R}_{1\%} = [x_{1;1\%}^2; +\infty[= [6,63; +\infty[$ car $x_{1;1\%}^2$

est le quantile d'ordre 0,99 de la loi χ_1^2 , et la valeur observée de Q^2 : $q^2 = 1,01 \notin \mathcal{R}_{1\%}$. Donc on ne rejette pas H_0 au risque 1% : la proportion d'amélioration du sommeil est la même dans les deux groupes c'est à dire que le somnifère n'est pas efficace, au risque $\alpha = 1\%$.

Correction de Yates : sous H_0 , la statistique de test du khi-deux corrigé Q_Y^2 suit approximativement une loi du khi-deux à 1 ddl car $n > 30$ et tous les e_{ij} sont supérieurs à 5. La valeur observée de Q_Y^2 : $q_Y^2 = 0,65 \notin \mathcal{R}_{1\%}$ donc on ne rejette pas H_0 au risque 1%.

Exercice 10

\mathcal{P}_1 = population des cas = {femmes atteintes d'un cancer du sein}, X_1 = nombre d'enfants des cas

\mathcal{P}_2 = population des témoins = {femmes indemnes de cancer}, X_2 = nombre d'enfants des témoins

X_1 et X_2 variables qualitatives à 5 modalités définies sur $E = \{0, 1, 2, 3, \text{plus de } 4\}$.

Test du khi-deux d'homogénéité : $\begin{cases} H_0: \text{les 2 populations sont homogènes vis à vis de } X \\ H_1: \text{les 2 populations sont hétérogènes vis à vis de } X \end{cases}$ au risque $\alpha = 10\%$

ou $\begin{cases} H_0: X \text{ a la même distribution dans les 2 populations} \\ H_1: X \text{ a des distributions différentes dans les 2 populations} \end{cases}$

Sur deux échantillons indépendants de X_1 et X_2 de tailles $n_1 = n_2 = 918$, les effectifs observés n_{ij} et les effectifs théoriques (attendus) e_{ij} notés entre parenthèses :

X nombre d'enfants	population	
	cas	témoin
0	159 (138)	117 (138)
1	124 (123,5)	123 (123,5)
2	431 (438)	445 (438)
3	156 (165)	174 (165)
plus de 4	48 (53,5)	59 (53,5)

Sous H_0 , la statistique de test Q^2 suit approximativement une loi du khi-deux à 4 ddl car $n = n_1 + n_2 = 2 \times 918 > 30$ et tous les e_{ij} sont supérieurs à 5. La région de rejet du test au risque 10% est $\mathcal{R}_{10\%} = [x_{4;10\%}^2; +\infty[= [7,78; +\infty[$ car $x_{4;10\%}^2$ est le quantile d'ordre 0,9 de la loi χ_4^2 , et la valeur observée de Q^2 : $q^2 = 8,73 \in \mathcal{R}_{10\%}$. Donc on rejette H_0 au risque 10% : les nombres d'enfants ne se répartissent pas de façon homogène dans les deux populations, les distributions du nombre d'enfants dans les deux populations sont différentes au risque $\alpha = 10\%$.