

Exercice 1 : (6 points).

1. **Définition de la population dans une situation statistique :**

L'ensemble des individus observables.

2. **Indiquer les différentes natures de variable :**

Les variables nominales, ordinales, discrète et continues

3. **Que représente les notations ?**

- (a) p : le nombre de modalités de Y.
- (b) y_3 : la valeur de Y observée sur le troisième individu [de l'échantillon].
- (c) $E_{m'_2}$: le sous-échantillon induit par la seconde modalité de Y ;
ou : les individus ayant la seconde modalité comme valeur pour Y.
- (d) $X_{m'_3}$: la distribution de X conditionnée par la troisième modalité de Y.

4. **Notation de l'effectif total de la seconde ligne :** n_2 .

5. **Définition d'une distribution conditionnelle de X ; combien peut-on en construire ?**

C'est la distribution de X observés sur les individus ayant la même valeur pour Y ; on peut en construire autant qu'il y a de modalités de Y, p.

6. **Formule de la fréquence de la seconde modalité de Y_{m_4} :**

La distribution Y_{m_4} est décrite par la 4ème ligne ; c'est donc $\frac{n_{42}}{n_4}$.

7. **Notation et formule de l'effectif de la modalité conjointe (m_1, m'_4) sous hypothèse d'indépendance de X et Y.**

$$\tilde{n}_{14} = \frac{n_{1.} * n_{.4}}{n}$$

8. **Donner une propriété qui permette d'assurer que X et Y sont indépendantes.**

Les distributions conditionnelles de X en fréquence sont égales ;
ou : les distributions conditionnelles de Y en fréquence sont égales ;
ou : les effectifs observés sont égaux aux effectifs théoriques ;
ou : le χ^2 est nul.

Exercice 2 : (12 points)

1. **Combien peut-on construire de distributions de X à partir du tableau ?**

5 : 4 conditionnelles plus 1 marginale.

2. **Signification et valeur des expressions suivantes :**

- (a) n_{12} : c'est l'effectif de la modalité conjointe (A ; -) ; il vaut 14.
- (b) f_{24} : c'est la fréquence de la modalité conjointe (B ; ++) ; elle vaut $\frac{n_{24}}{n} = \frac{45}{330} = 13,6\%$.
- (c) $n_{3.}$: la somme de la troisième ligne ; elle vaut $330 - 104 - 90 = 136$
- (d) $f_{.2}$: la fréquence de la deuxième colonne ; elle vaut $100 - 23,6 - 18,5 - 39,4 = 18,5\%$
- (e) \tilde{n}_{31} : effectif sous hypothèse d'indépendance (ou effectif théorique) de la modalité conjointe (C, 1) ; $\tilde{n}_{31} = \frac{n_{3.} * n_{.1}}{n} = \frac{78 * 90}{330} = 32,15$

3. Compléter le tableau de contingence et les marges.

X / Y	--	-	+	++	Marge	en %
A	35	14	11	30	90	27,3
B	23	12	24	45	104	31,5
C	20	35	26	55	136	41,2
Marge	78	61	61	130		
en %	23,6	18,5	18,5	39,4		

4. Donner la valeur de $\sum_{i=1,2} \sum_{j=2,4} n_{ij}$.

$$n_{12} + n_{13} + n_{14} + n_{22} + n_{23} + n_{24} = 14 + 11 + 30 + 12 + 24 + 45 = 136$$

5. Les individus dont la valeur pour X est B sont-ils relativement plus nombreux dans E_+ ou dans E_{++} ?

$$\text{Dans } E_+ : \frac{24}{61} = 39,3\% \text{ contre } \frac{45}{130} = 34,6\% \text{ dans } E_{++}.$$

6. Vérifier que les deux variables ne sont pas indépendantes.

l'effectif observé $n_{31} = 20$ est différent de l'effectif théorique correspondant $\tilde{n}_{31} = 32,15$

7. Etudier l'indépendance statistique des deux variables par un test du χ^2 en utilisant le 95ème centile de la distribution du χ^2 qui vaut 7,8 9,5 12,6 14,1 ou 21,0 selon que le d.d.l. est 3, 4, 6, 7 ou 12.

(a) d.d.l. = $(3 - 1) * (4 - 1) = 6$

(b) le seuil de rejet S est donc 12,6

(c) calcul du χ^2

$$\tilde{n}_{11} = \frac{n_{78} * n_{90}}{330} = 21,27 \text{ donc } \chi_{11}^2 = \frac{(35 - 21,27)^2}{21,27} = 8,86$$


$$\tilde{n}_{31} = 32,15 \text{ donc } \chi_{31}^2 = \frac{(20 - 32,15)^2}{32,15} = 4,59$$

conclusion $\chi^2 > \chi_{11}^2 + \chi_{31}^2 = 13,45 > S$: on rejette l'hypothèse d'indépendance statistique entre X et Y.

8. Étude d'une liaison entre X et Y :

(a) calculer les distributions conditionnelles cumulées de Y_A et Y_C et les représenter proprement sur la même grille.

	--	-	+	++	Total
Y_A	35	14	11	30	90
cumul	35	49	60	90	
%	38,9	54,4	66,7	100,0	
Y_C	20	35	26	55	136
cumul	20	55	81	136	
%	14,7	40,4	59,6	100,0	



(b) tirer les conclusions de cette représentation concernant la liaison entre X et Y :

Comme $F_{Y_A} > F_{Y_C}$ on peut énoncer que $E_A <_Y E_C$: les individus ayant A pour X ont globalement des valeurs de Y inférieures aux individus ayant C pour X.

9. Il s'agit de simuler 10 observations de la variable X en utilisant la série de chiffres au hasard suivante

273513462355864586590699288558457425679271027

- (a) **déterminer la population de simulation** : Elle compte 1000 individus ;
 les 273 premiers notés de 1 à 273 ont l'étiquette A (le pourcentage est bien égal à f_1 .)
 les 315 suivants notés de 274 à 588 ont l'étiquette B ($31,5\%=f_2$.);
 les 412 derniers notés de 589 à 1000 ont l'étiquette C ($41,2\%=f_3$.);

- (b) **faire la simulation des 10 observations** :
 273+1→B; 513+1→B; 462+1→B; 355+1→B; 864+1→C;
 586+1→B; 590+1→C; 699+1→C; 288+1→B; 558+1→B

- (c) **construire la distribution de ces 10 observations** :

X	A	B	C	Total
effectif	0	7	3	10

Exercice 3 : (2 points) Les rangs à deux épreuves passées par 12 individus sont donnés dans le tableau suivant :

Calculer le τ de Kendall de cette série d'observations. On range les données par X croissant, et on calcul le bilan $cov_+ - cov_-$ pour chaque individu :

Individu	l	h	a	e	d	c	i	k	j	b	f	g	Total
Épreuve A	1	2	3	4	5	6	7	8	9	10	11	12	
Épreuve B	4	1	2	7	6	3	9	12	11	5	8	10	
Bilan	8-3	10-0	9-0	5-3	5-2	6-0	3-2	0-4	0-3	2-0	1-0		32

Et alors : $\tau = \frac{2*32}{12*11} = 0,48$