

Exercice 1 : (7 points).

1. **Dans un tableau de contingence, que désignent les notations ?** n_{23} , f_{54} , $n_{.2}$ et \tilde{n}_{32} ?

n_{23} : effectif [observé] de la modalité $(m_2 ; m'_3)$ (situé au croisement de la 2ème ligne et de la 3ème colonne)

f_{54} : proportion [observée] de la modalité $(m_5 ; m'_4)$

$n_{.2}$: effectif de la 2ème modalité de Y ou la somme de la 2ème colonne

\tilde{n}_{32} : effectif théorique de la modalité $(m_3 ; m'_2)$

Calcul de f_{54} à partir des effectifs : $f_{54} = n_{54}/n$

2. **Qu'appelle-t-on moyenne conditionnelle de X, dans le contexte d'une variable conjointe XxY ?**

La moyenne de X pour les individus ayant même modalité pour Y ; ou autre ...

3. **Définition de la variance inter de Y, et formule dans le cas où X a 4 modalités.**

C'est la variance des moyennes conditionnelles de Y.

$$\text{var inter} = \frac{\sum_{i=1,4} n_{i.} * (\bar{Y}_i - \bar{Y})^2}{n} \text{ ou } \frac{n_{1.} * \bar{Y}_1^2 + n_{2.} * \bar{Y}_2^2 + n_{3.} * \bar{Y}_3^2 + n_{4.} * \bar{Y}_4^2}{n} - \bar{Y}^2$$

4. **Construire un exemple de tableau de contingence avec 3 modalités pour X et 4 pour Y, où la covariance a un sens. Donner l'expression de cette covariance (le calcul n'est pas obligatoire).**

Les variables doivent être quantitatives, discrète ou continue.

On note c_i et c'_j les centres des classes de X et Y.

$$\text{Cov}(X, Y) = \frac{\sum_{i=1,3}^{j=1,4} n_{ij} * (c_i - \bar{X}) * (c'_j - \bar{Y})}{n} \text{ ou}$$

$$\text{moyenne des produits} - \text{produit des moyennes} = \frac{\sum_{i=1,3}^{j=1,4} n_{ij} * c_i * c'_j}{n} - \bar{X} * \bar{Y}$$

5. $F'(0.3)$ vaut **0.382** pour la variable gaussienne ($P(Z > 0.3) = 0.382$), et $F'(0.6)$ vaut **0.274**. **Quelle est la proportion des individus dont la valeur appartient aux intervalles** $] - \infty ; 0.3[$, $] - 0.6 ; 0.3[$ **et** $] - 0.6 ; -0.3[$?

$$P(Z < 0.3) =_{\text{cpt}} 1 - P(Z > 0.3) = 1 - 0.382 = 0.618$$

$$P(-0.6 < Z < 0.3) = P(Z < 0.3) - P(Z < -0.6) = P(Z < 0.3) - P(Z > 0.6) = 0.618 - 0.274 = 0.344$$

$$P(-0.6 < Z < -0.3) =_{\text{sym}} P(0.3 < Z < 0.6) = P(Z > 0.3) - P(Z > 0.6) = 0.382 - 0.274 = 0.108$$

Exercice 2 : (3 points).

Dans cet exercice, les mots sont formés avec l'alphabet $A = \{a,b,c,d,e,f,g\}$.

1. **Combien y a-t-il de mots à 5 lettres toutes différentes ?**

$$\text{Le nombre de 5-énumération de } 7 = A_7^5 = 2520$$

2. **Combien y a-t-il de mots à 5 lettres ayant au moins une lettre avec plusieurs occurrences ?**

$$\text{Le nombre de mots à 5 lettres diminué du nombre de mots à 5 lettres toutes différentes : } 7^5 - A_7^5 = 16807 - 2520 = 14287$$

3. Combien y a-t-il de mots à 6 lettres ayant exactement 3 a ?

On place d'abord les 3 a dans une des parties de 3 parmi 6 : il y a $\binom{6}{3} = 20$ possibilités ; puis on remplit les 3 places restantes avec un mot sans a : $(7-1)^3 = 216$ possibilités ; au total on trouve $20 \cdot 216 = 4320$ mots.

4. Combien y a-t-il de mots à 6 lettres ayant exactement 3 a et au moins 1 b ?

Nombre de mots ayant 3a et 1 b : $\binom{6}{3} * \binom{3}{1} * (7-2)^2 = 20 * 3 * 25 = 1500$

Nombre de mots ayant 3a et 2 b : $\binom{6}{3} * \binom{3}{2} * (7-2) = 20 * 3 * 5 = 300$

Nombre de mots ayant 3a et 3 b : $\binom{6}{3} * \binom{3}{3} = 20 * 1$

Au total on trouve $1500 + 300 + 20 = 1820$ mots

Exercice 3 : (5 points).

Il s'agit d'effectuer un test du χ^2 du tableau de contingence suivant, portant sur le vote par groupe d'âges de 1280 individus d'un échantillon ; on prendra comme seuil de décision le 95ème centile du χ^2 égal à 12,6 pour ce tableau.

X=Candidat - Y=Âge	18-35	35-50	50-80
A	127	113	140
B	98	84	98
C	101	113	241
D	57	41	67

1. Quel degré de liberté a-t-on choisi pour calculer le seuil ?

$$(4-1) * (3-1) = 6$$

2. Formule et valeur de l'effectif de la modalité (C ; 18-35) si X et Y sont indépendantes.

$$\tilde{n}_{31} = \frac{n_{3.} * n_{.1}}{n} = \frac{455 * 383}{1280} = 136.14$$

3. Formule et valeur du taux de liaison t_{13} .

$$t_{13} = \frac{(n_{13} - \tilde{n}_{13})}{\sqrt{\tilde{n}_{13}}} ; \text{ comme } \tilde{n}_{13} = \frac{380 * 546}{1280} = 162.09, \text{ on a}$$

$$t_{13} = \frac{(140 - 162.09)}{\sqrt{162.09}} = -1,73$$

4. Faire le test en indiquant précisément les conclusions auxquelles vous aboutissez.

$$\chi_{11}^2 = \frac{(127 - 113.70)^2}{113.70} = 1.55 \text{ car } \tilde{n}_{11} = \frac{383 * 380}{1280} = 113.70$$

$$\chi_{13}^2 = t_{13}^2 = 3.01$$

$$\chi_{31}^2 = \frac{(101 - 136.14)^2}{136.14} = 9.07$$

Si bien que :

$$\chi^2 \geq \chi_{11}^2 + \chi_{13}^2 + \chi_{31}^2 = 1.55 + 3.01 + 9.07 \geq 12,6$$

On décide donc de rejeter l'hypothèse d'indépendance de X et Y [avec un risque d'erreur de 5%

Exercice 4 : (5 points).

On a mesuré une variable continue X sur 4 groupes disjoints d'individus, et on a obtenu les résultats suivants :

	Taille du groupe	Moyenne	Variance
Groupe 1	380	46.4	300.9
Groupe 2	280	45.6	298.4
Groupe 3	455	52.2	294.0
Groupe 4	165	47.1	320.8

ainsi que la variance des moyennes égale à 8.2.

1. Calculez la moyenne globale de X.

D'après la formule de décomposition de la moyenne, la moyenne globale est la moyenne des moyennes conditionnelles pondérée par la distribution de Y :

$$\bar{X} = \frac{\sum_{j=1,4} n_j \bar{X}_j}{n} = \frac{380*46.4+280*45.6+455*52.2+165*47.1}{1280} = 48.38$$

2. Calculez la variance globale de X.

Variance globale = variance inter + variance intra

Variance inter = variance des moyennes conditionnelles = 8.2

Variance intra = moyenne des variances conditionnelles pondérée par la distribution de Y :

$$\text{var inter} = \frac{\sum_{j=1,4} n_j \text{var}(X_j)}{n} = \frac{380*300.9+280*298.4+455*294.0+165*320.8}{1280} = 300.47$$

Au total :

$$\text{Variance globale} = 8.2 + 300.5 = 308.7$$

3. Faire l'analyse de la variance de X, avec le dernier centile de la distribution du χ^2 égal à 11,35. Vous préciserez le degré de liberté utilisé, et vous indiquerez précisément les conclusions auxquelles vous aboutissez.

On teste l'égalité des moyennes conditionnelles : on sait que si c'est le cas, le nombre $(1280-4)*\text{var-inter}/\text{var-intra}$ suit une loi du χ^2 à 3 degrés de liberté.

Pour cet échantillon, ce nombre est égal à $1276*8.2/300,47=34.8$; comme il est supérieur à 11.35 on rejette l'hypothèse d'égalité des moyennes conditionnelles en considérant que l'appartenance à un groupe a un effet sur la mesure de X.