

Statistiques Descriptives

Devoir Surveillé 1

Durée : une heure.

Les calculatrices sont autorisées ; tout autre matériel électronique (comme le téléphone portable) est interdit.

Exercice 1. (10 pts)

Table 1 donne la répartition d'un échantillon de quarante personnes par classe d'âge et de masse.

		masse (y)		
		[50, 70[	[70, 90[	[90, 100]
âge (x)	[20, 30[	2	8	2
	[30, 40[	5	10	5
	[40, 60]	2	5	1

Table 1: Tableau de contingence de l'âge mesuré en années et de la masse mesurée en kg d'un échantillon de quarante personnes

Partie A. Une seule des trois réponses proposées à chacun des cinq items suivants est exacte ; entourez sans justification la réponse qui vous semble correcte et rayez les autres. Une réponse juste apporte un point ; une réponse fausse enlève 0,5 points ; une absence de réponse n'apporte ni n'enlève de points.

1. L'âge modal^a arrondi à l'unité est : (a) 32 (b) 33 (c) 34.

L'âge modal déterminé par la méthode des diagonales est : $30 + 10 \times 8 / (8 + 16) \approx 33,3$; la bonne réponse est (b).

2. L'âge médian^b est : (a) 34 (b) 35 (c) 36.

L'âge médian déterminé par interpolation linéaire est : $30 + (10/0,5) \times 0,2 = 34$; la bonne réponse est (a).

3. Le neuvième décile de l'âge est : (a) 45 (b) 50 (c) 55.

Le neuvième décile est 50, le milieu entre 40 (huitième décile) et 60 (dixième décile) ; la bonne réponse est (b).

4. Le quotient $n_{3,2}/n_{\bullet,2}$ est égal à : (a) 5/20 (b) 5/23 (c) 5/40.

$n_{3,2}/n_{\bullet,2} = 5/(5 + 10 + 8)$; la bonne réponse est (b).

5. Ce quotient représente la proportion de personnes

- (a) entre 40 et 60 ans parmi les 70-90 kg
- (b) entre 90 et 100 kg parmi les 30-40 ans
- (c) ayant entre 40 et 60 ans et pesant de 70 à 90 kg

$n_{3,2}/n_{\bullet,2}$ représente la proportion de personnes âgées de 40 à 60 ans parmi les 70-90 kg ; la bonne réponse est (a).

Partie B.

âge	[20, 30[	[30, 40[	[40, 60]
masse moyenne	$\bar{y}_1 \approx 79, 2$	$\bar{y}_2 \approx 78, 7$	$\bar{y}_3 \approx 76, 9$

Table 2: *Masses moyennes conditionnelles à l'âge*

1. Déterminez la masse moyenne dans chaque classe d'âge.

La masse moyenne des 20-30 ans est $\bar{y}_1 = \left(\sum_{j=1}^3 n_{1,j} y_j \right) / n_{1,\bullet} = (2 \times 60 + 8 \times 80 + 2 \times 95) / 12 \approx 79, 2$. On détermine ainsi les masses moyennes conditionnelles données par Table 2.

2. Déterminez la distribution marginale de la masse.

La distribution marginale des effectifs, relative à la masse, est donnée par Table 3.

masse	[50, 70[	[70, 90[	[90, 100]
effectif	$n_{\bullet,1} = 9$	$n_{\bullet,2} = 23$	$n_{\bullet,3} = 8$

Table 3: *Distribution marginale des effectifs, relative à la masse*

3. Calculez de deux manières différentes la masse moyenne.

La masse moyenne est la moyenne des masses de Table 3 : $\bar{y} = \left(\sum_{j=1}^3 n_{\bullet,j} \times y_j \right) / n = (9 \times 60 + 23 \times 80 + 8 \times 95) / 40 = 78, 5$. De façon équivalente, on peut calculer la moyenne pondérée des moyennes conditionnelles de Table 2 : $\bar{y} = \left(\sum_{i=1}^3 n_{i,\bullet} \times \bar{y}_i \right) / n \approx (12 \times 79, 2 + 20 \times 78, 7 + 8 \times 76, 9) / 40 \approx 78, 5$.

4. Calculez de deux manières différentes la variance des masses.

La variance de la masse peut être obtenue directement grâce à Table 3 : $\text{var}(y) = \left(\sum_{j=1}^3 n_{\bullet,j} \times y_j^2 \right) / n - \bar{y}^2 = (9 \times 60^2 + 23 \times 80^2 + 8 \times 95^2) / 40 - 78, 5^2 = 132, 75$.

On peut aussi conditionner par l'âge. Pour les 20-30 ans la variance de la masse est : $v_1 = \left(\sum_{j=1}^3 n_{1,j} \times y_j^2 \right) / n_{1,\bullet} - \bar{y}_1^2 \approx (2 \times 60^2 + 8 \times 80^2 + 2 \times 95^2) / 12 - 79, 2^2 \approx 103, 5$; les autres variances conditionnelles sont données par Table 4.

âge	[20, 30[	[30, 40[	[40, 60]
variance de la masse	$v_1 \approx 103, 5$	$v_2 \approx 154, 7$	$v_3 \approx 118, 4$

Table 4: *Variance de la masse conditionnellement à l'âge*

La variance de la masse, $\text{var}(y)$, est la somme de deux termes :

- la moyenne des variances conditionnelles de Table 4 : $\left(\sum_{i=1}^3 n_{i,\bullet} \times v_i \right) / n \approx (12 \times 103, 5 + 20 \times 154, 7 + 8 \times 118, 4) / 40 \approx 132, 06$
- la variance des moyennes conditionnelles de Table 2 : $\left(\sum_{i=1}^3 n_{i,\bullet} (\bar{y}_i^2 - \bar{y}^2) \right) / n \approx (12 \times (79, 2 - 78, 5)^2 + 20 \times (78, 7 - 78, 5)^2 + 8 \times (76, 9 - 78, 5)^2) / 40 \approx 0, 69$.

Exercice 2. (10 pts)

Table 5 indique la taille (x) et la masse (y) d'un échantillon de quatre personnes.

taille (cm)	160	150	160	180
masse (kg)	60	70	80	80

Table 5: *Taille et masse d'un échantillon de quatre personnes*

1. Déterminez les coordonnées du point moyen.

Le point moyen G a pour coordonnées $\bar{x} = (\sum_{i=1}^4 x_i) / 4 = 162, 5$ et $\bar{y} = (\sum_{i=1}^4 y_i) / 4 = 72, 5$

A. Lourme, Faculté d'économie, gestion & AES, Université Montesquieu - Bordeaux IV. <http://alexandrebourme.free.fr>

^adéterminé par la méthode des diagonales

^bobtenu par interpolation linéaire

2. Déterminez la variance de la taille et celle de la masse.

La variance de la taille est : $\text{var}(x) = \left(\sum_{i=1}^4 x_i^2 \right) / 4 - \bar{x}^2 = 118,75$; celle de la masse est : $\text{var}(y) = \left(\sum_{i=1}^4 y_i^2 \right) / 4 - \bar{y}^2 = 68,75$.

3. Quelle serait la variance de la taille si les tailles étaient données en mètres ?

La variance est multipliée par 10^{-4} lorsqu'on convertit les tailles de centimètres en mètres.

4. Quelle est la covariance des deux variables ?

La covariance des deux variables est : $\text{cov}(x, y) = \left(\sum_{i=1}^4 x_i y_i \right) / 4 - \bar{x} \bar{y} = 43,75$.

5. Quel est leur coefficient de corrélation linéaire ?

Leur coefficient de corrélation linéaire est : $\rho = \text{cov}(x, y) / \sqrt{\text{var}(x) \times \text{var}(y)} \approx 0,4842$.

6. Déterminez l'équation de la droite d'ajustement de la masse en la taille.

La droite d'ajustement de la masse (y) en la taille (x) a pour équation : $\mathcal{D} : y = 0,37 \times x + 12,63$. En effet $\alpha = \text{cov}(x, y) / \text{var}(x) \approx 0,37$ et $\bar{y} - \alpha \bar{x} \approx 12,63$.

7. Calculez et interprétez le coefficient de détermination.

Puisque la régression est linéaire, le coefficient de détermination est le carré du coefficient de corrélation linéaire ; il vaut donc environ 0,23 : l'ajustement linéaire de la masse par la taille explique 23% de la variabilité de la masse.