

CORRIGE PARTIEL BLANC


L2AES-Statistique

Janvier 2012

1 EXERCICE 1

1. On note a_i et b_i les bornes inférieures et supérieures des classes et on calcule les amplitudes de classes : $b_i - a_i$. On représente ce caractère continu par un histogramme ; les classes étant d'amplitudes inégales, on doit corriger les effectifs en utilisant la densité $d_i = \frac{n_i}{b_i - a_i}$. On a pris pour effectifs corrigés : $n_{i\text{cor}} = 20d_i$, c'est-à dire le produit de la densité par l'amplitude minimale.

a_i	b_i	n_i	x_i	f_i	$f_{i\text{cc}}$	A_i	d_i	$n_{i\text{cor}}$
0	50	10	25	0,05	0,05	50	0,20	4
50	70	40	60	0,2	0,25	20	2,00	40
70	90	46	80	0,23	0,48	20	2,30	46
90	110	48	100	0,24	0,72	20	2,40	48
110	130	28	120	0,14	0,86	20	1,40	28
130	150	22	140	0,11	0,97	20	1,10	22
150	200	6	175	0,03	1	50	0,12	2,4
		200		1				



2. La classe modale est celle qui a la plus grande densité, soit la classe $[90; 110[$; c'est le rectangle le plus haut de l'histogramme. Le mode est calculé en considérant les classes encadrant la classe modale, ce qui donne avec les notations du cours : $\begin{cases} x_1 = 90 \\ x_2 = 110 \end{cases}$, $\begin{cases} h = 48 \\ h_1 = 46 \text{ et } h_2 = 28 \end{cases}$, $\begin{cases} k_1 = h - h_1 = 2 \\ k_2 = h - h_2 = 20 \end{cases}$ et pour conclure : $M_o = \frac{k_2 x_1 + k_1 x_2}{k_2 + k_1} = \frac{20 * 90 + 2 * 110}{22} \simeq \boxed{91.82}$; comme prévu, le mode est largement attiré à gauche.
3. La calculatrice donne : $\bar{x} = 93.1$, $\sigma(x) \simeq 32.35$ et $V(x) = \sigma^2(x) \simeq 1046.52$.
4. $\bar{x} - 1.5\sigma(x) = 93.1 - 1.5 * 32.35 = 44.58$ et $\bar{x} + 1.5\sigma(x) = 93.1 + 1.5 * 32.35 = 141.63$. On doit donc ajouter les effectifs des classes de 50 à 130, puis estimer les effectifs des intervalles $[44.58; 50[$ et $[130; 141.63[$, ce qui se fait

Intervalle	Amplitude	Densité	Effectif
[44.58; 50[5.42	0.2	$5.42 * 0.2 = 1.08$
[130; 141.63[11.63	1.1	$11.63 * 1.1 = 12.79$

en utilisant leurs densités : $(40 + 46 + 48 + 28) + 1.08 + 12.79 = 175.87$, soit une proportion de : $\frac{175.87}{200} = 0.8794$, soit 87.94%.

5. On doit calculer les quartiles et calculer $C_Y = \frac{Q_1 + Q_3 - 2Q_2}{Q_3 - Q_1}$; A l'aide des fréquences cumulées croissantes, on trouve : $Q_1 = 70, Q_2 = 91.67$ et $Q_3 = 114.29$, soit : $C_Y = \frac{Q_1 + Q_3 - 2Q_2}{Q_3 - Q_1} = \frac{70 + 114.29 - 2 * 91.67}{114.29 - 70} = 2.14 \times 10^{-2}$; ce qui donne un coefficient légèrement positif et une série légèrement étalée à droite.

2 EXERCICE-2

1. On trouve : $\bar{X} = 582.8$ et $\bar{Y} = 365.5$.

	X	Y
Moyenne	582.8	365.5
Ecart-type	26.06	34.40
Variance	678.96	1183.05

x_i	y_i	$x_i y_i$
525	325	170625
554	362	200548
575	315	181125
579	355	205545
585	325	190125
586	370	216820
590	390	230100
608	420	255360
610	410	250100
616	383	235928
5828	3655	2136276

- 2.
3. La covariance peut se calculer avec la formule : $Cov(x; y) = \frac{1}{n} \sum x_i y_i - \bar{x} * \bar{y} = \frac{2136276}{10} - 582.8 * 365.5 \simeq 614.2$.
4. On trouve : $\hat{y} = \hat{a}x + \hat{b} = 0.9046x - 161.71$
5. $\hat{a} \simeq 0.9046$, représente en roupies, la variation(augmentation) de la dépense alimentaire quand la dépense totale augmente de 1 roupie.
6. $r = \frac{Cov(x; y)}{\sigma(x) \sigma(y)} = 0.6853$, le coefficient de corrélation linéaire mesure l'intensité de la liaison linéaire existant entre x et y ; ce coefficient varie entre -1 et 1 ; ici il est relativement proche de 1 et traduit une assez bonne liaison linéaire entre x et y . et $R^2 = r^2 = \frac{\text{Variance expliquée}}{\text{Variance totale}} = \frac{V(\hat{y})}{V(y)} = \frac{\text{SCE}}{\text{SCT}} \simeq 0.4696$; ce coefficient donne la part de la variation totale expliquée par le modèle, ici 46.96%.
7. $\hat{y}(650) = 0.9046 * 650 - 161.71 \simeq 426.28$ roupies

3 EXERCICE-3

	Sportive	Sûre	n_{i+}	f_{i+}
BMW	256	74	330	0,6433
MERCEDES	41	42	83	0,1618
LEXUS	66	34	100	0,1949
n_{j+}	363	150	513	
f_{j+}	0,7076	0,2924		1


1. Les fréquences marginales sont en gras dans le tableau ci-dessus.
2. Cette fréquence partielle est donnée par : $f_{11} = \frac{256}{513} = 0.4990$. Il y a 49.90 % de voitures qui sont de marque *BMW* et perçues comme sportives
3. Il s'agit d'une fréquence conditionnelle : $f_{(j=2/i=3)} = f_{y=Sure/x=Lexus} = \frac{34}{100} = 0.34$. Il y a 34% de véhicules perçus comme sûrs parmi les Lexus.

4 EXERCICE-4

a_i	b_i	n_i	x_i	f_i	f_{icc}	$n_i x_i$	q_i	q_{icc}	S_i
0	2	222279	1	0,5870	0,5870	222279	0,1614	0,1614	0,0474
2	5	142380	3,5	0,3760	0,9630	498330	0,3617	0,5231	0,1287
5	30	8331	17,5	0,0220	0,9850	145792,5	0,1058	0,6289	0,0127
30	150	5680	90	0,0150	1,0000	511200	0,3711	1,0000	0,0122
		378670				1377601,5	1		0,2009

1. La médiane se localise à l'aide des fréquences cumulées croissantes dans la classe $[0; 2[$, puis on effectue une interpolation linéaire :

$A(0; 0)$, $B(2; 0.5870)$ et $M(Me; 0.50)$, ce qui donne : $\frac{0.587}{2} = \frac{0.5}{Me}$, soit $Me = \frac{1}{0.587} \simeq 1.70$. 50% des entreprises de ce secteur ont un chiffre d'affaire inférieur ou égal à 1.70 millions d'euros.



- 2.
3. On doit calculer l'aire de concentration : $A_c = 0.5 - \sum S_i = 0.50 - 0.2009 = 0.2991$ et l'indice de Gini est défini par : $I_G = \frac{A_c}{\text{Aire}(OAB)} = \frac{0.2991}{0.5} = 0.5982$; l'indice de Gini est toujours compris entre 0 et 1 ; quand il est proche de 1, la concentration est forte ; ici la concentration est assez forte.