


CORRECTION Exercices Chapitre 2 - Statistiques à deux variables.

Exercice 27

- On complète le tableau auquel on rajoute une ligne et une colonne :

$x \backslash y$	[0; 4[[4; 8[[8; 12[[12; 16[[16; 20[$n_i.$	$n_i. \nearrow$
[0; 60[16	6	2	1	0	25	25
[60; 120[5	10	5	3	0	23	48
[120; 180[2	7	17	10	4	40	88
[180; 240[1	1	1	5	4	12	100
$n_{.j}$	24	24	25	19	8	100	-
$n_{.j} \nearrow$	24	48	73	92	100	-	-


- Les étudiants ayant eu entre 8 et 20 à leur examen sont au nombre de $n_{.3} + n_{.4} + n_{.5} = 25 + 19 + 8 = 52$.
- Le pourcentage d'étudiants ayant eu une note inférieure à 8 et ayant révisé moins de 2 heures est égal à $\frac{n_{11}+n_{12}+n_{21}+n_{22}}{n} \times 100 = \frac{16+6+5+10}{100} \times 100 = 37\%$
- Le pourcentage d'étudiants ayant eu une note supérieure à 8 et ayant révisé plus de 2 heures est égal à $\frac{n_{33}+n_{34}+n_{35}+n_{43}+n_{44}+n_{45}}{n} \times 100 = \frac{17+10+4+1+5+4}{100} \times 100 = 41\%$.
- Les histogrammes sont donnés par les graphiques :



Le code R est le suivant :

```
> ni.<-c(25,23,40,12)
> n.j<-c(24,24,25,19,8)
> classes.X<-c(0,60,120,180,240)
> classes.Y<-c(0,4,8,12,16,20)
> centres.classes.X<-c(30,90,150,210)
> centres.classes.Y<-c(2,6,10,14,18)
> serie.X<-c(rep(centres.classes.X,ni.))
> serie.Y<-c(rep(centres.classes.Y,n.j))
> par(mfrow=c(1,2))
> hist(serie.X,classes.X,xlab='Temps révisé (minutes)',ylab='Effectifs',
+ main='Histogramme de la série x')
> hist(serie.Y,classes.Y,xlab='Note obtenue (sur 20)',ylab='Effectifs',
+ main='Histogramme de la série y')
```

- Les courbes des effectifs cumulés croissants sont données par les graphiques :




Le code R est le suivant :

```
> diagX<-plot(classes.X,c(0,cumsum(ni.)),type='b',xlab='Temps révisé (en minutes)',ylab='Ecc',
+ main='Courbe des effectifs cumulés croissants de la série x')
> diagY<-plot(classes.Y,c(0,cumsum(n.j)),type='b',xlab='Note obtenue (sur 20)',ylab='Ecc',
+ main='Courbe des effectifs cumulés croissants de la série y')
```

Exercice 28

1. Le nuage de points est donné ci-dessous :



Le code R est le suivant :

```
> x<-c(0,1,2,4,6,10)
> y<-c(76,67,59,46,35,20)
> plot(x,y,xlab='altitude x (en km)',ylab='hauteur barométrique y (en cm de mercure)',
+ main='Représentation graphique de la série',pch=20,xlim=c(-1,11),ylim=c(15,80))
```

2. L'équation de régression de y en x est donnée par $D_{y/x}$: $y = ax + b$ où $a = \frac{Cov(x,y)}{V(x)}$ et $b = \bar{y} - a\bar{x}$. On complète le tableau de l'énoncé :

i	1	2	3	4	5	6	TOTAL
x_i	0	1	2	4	6	10	23
y_i	76	67	59	46	35	20	303
x_i^2	0	1	4	16	36	100	157
$x_i y_i$	0	67	118	184	210	200	779

On en déduit $\bar{x} = \frac{23}{6} = 3,83$, $\bar{y} = \frac{303}{6} = 50,5$, $V(x) = \frac{157}{6} - (3,83)^2 = 11,50$, $Cov(x,y) = \frac{779}{6} - 3,83 \times 50,5 = -63,58$ à 10^{-2} près. Par conséquent, $a = \frac{-63,58}{11,47} = -5,54$ et $b = 50,5 - (-5,54) \times 3,83 = 71,72$. Ainsi la droite recherchée admet pour équation $y = -6,65x + 75,97$, qu'on peut tracer sur le graphique précédent à l'aide des commandes sous R (à mettre à la suite du code précédent) :

```
> abline(71.72,-5.54)
> text(2.5,75,'Dy/x :y=-5,54x+71,72')
```

3. Sachant que la hauteur barométrique en un lieu est de 40 cm, l'altitude est estimée en résolvant $40 = -5,54 \times x + 71,72 \Leftrightarrow x = 5,725632$ à 10^{-6} près soit approximativement 5726m. On peut représenter graphiquement ces données sur le graphe précédent grâce aux lignes de commande qui suivent :


```
> segments(-1,40,5.73,40,lty='dashed')
> segments(5.73,40,5.73,0,lty='dashed')
```

Exercice 29 On complète le tableau de l'énoncé :

i	1	2	3	4	5	6	7	8	TOTAL
x_i	1970	1975	1980	1985	1990	1995	2002	2006	15903
y_i	0,352	0,6660	1,073	2,026	3,369	6,420	9,592	10,89	34,39
x_i^2	3880900	3900625	3920400	3940225	3960100	3980025	4008004	4024036	31614315
y_i^2	0,12	0,44	1,15	4,10	11,35	41,22	92,01	118,59	268,99
$x_i y_i$	693,44	1315,35	2124,54	4021,61	6704,31	12807,90	19203,18	21845,34	68715,67

- On déduit du tableau les moyennes $\bar{x} = \frac{15903}{8} = 1987,88$ et $\bar{y} = \frac{34,39}{8} = 4,30$. Par conséquent, $G(1987,88; 4,30)$.
- Déterminons les variances de x et de y . On a $V(x) = \frac{31614315}{8} - (1987,88)^2 = 122,48$ et $V(y) = \frac{268,99}{8} - (4,30)^2 = 15,13$. On a ensuite $\text{Cov}(x, y) = \frac{68715,67}{8} - 1987,88 \times 4,30 = 41,58$. Finalement, $r = \frac{41,58}{\sqrt{122,48} \times \sqrt{15,13}} = 0,97$. Il y a donc une forte corrélation linéaire entre x et y , ou de manière équivalente un lien de dépendance linéaire très significatif entre ces deux variables.
- L'équation de régression de y en x est donnée par $D_{y/x}$: $y = ax + b$ où $a = \frac{\text{Cov}(x,y)}{V(x)}$ et $b = \bar{y} - a\bar{x}$. On a $a = \frac{41,58}{122,48} = 0,34$ et $b = 4,30 - 0,34 \times 1987,88 = -671,58$. Ainsi la droite recherchée admet pour équation $y = 0,34x - 671,58$, qu'on peut représenter graphiquement à l'aide du code ci-dessous :

```
> x<-c(1970,1975,1980,1985,1990,1995,2002,2006)
> y<-c(0.352,0.666,1.073,2.026,3.369,6.420,9.592,10.89)
> plot(x,y,xlab='année x',ylab='montant de la consommation de médicaments (en milliards d euros)', main='Représentation graphique de la série')
> abline(-671.5792,0.3395)
```



- Il suffit de remplacer x par 2010 dans l'équation précédente : on obtient $y = 0,34 \times 2010 - 671,58 = 11,82$ qui est donc une estimation (en milliards d'euros) de la consommation de médicaments des ménages en France en 2010.

Exercice 30

- On utilise le tableau de la page suivante pour cette question et la suivante. On déduit de ces valeurs que $\bar{x} = \frac{16}{4} = 4$, $\bar{y} = \frac{2,4}{4} = 0,6$, $V(x) = \frac{84}{4} - 4^2 = 5$, $V(y) = \frac{2,18}{4} - 0,6^2 = 0,185$ et $\text{Cov}(x, y) = \frac{13,4}{4} - 4 \times 0,6 = 0,95$. Par conséquent, $r_{x,y} = \frac{0,95}{\sqrt{5} \times \sqrt{0,185}} = 0,988$ à 10^{-3} près.
- On a, toujours d'après le tableau, $\bar{z} = 2,25$, $V(z) = \frac{23,3}{4} - (2,25)^2 = 0,76$ et $\text{Cov}(x, z) = \frac{41,2}{4} - 4 \times 2,25 = 1,3$. Ainsi, $r_{x,z} = \frac{1,3}{\sqrt{5} \sqrt{0,76}} = 0,667$ à 10^{-3} près.
- Étant donné que $r_{x,y} > r_{x,z}$, c'est l'élément y_i qui est le plus susceptible d'avoir influencé l'augmentation des prêts de livres x_i .
- Comme $a = \frac{\text{cov}(x,y)}{V(x)} = \frac{0,95}{5} = 0,19$ et $b = 0,6 - 0,19 \times 4 = -0,16$, on trouve aisément que $D_{y/x}$: $y = 0,19x - 0,16$.

5. Si on pose $x = 9$ dans l'équation précédente, on trouve $y = 0,19 \times 9 - 0,16 = 1,55$. Conclusion, une estimation du nombre de nouveaux lecteurs inscrits y_i , si l'on pense que l'augmentation du nombre des prêts sera de 9000 en 2007, est égale à 1550.

	2003	2004	2005	2006	TOTAL
x_i	3	7	1	5	16
y_i	0,3	1,2	0,1	0,8	2,4
z_i	0,9	3,2	2,1	2,8	9
x_i^2	9	49	1	25	84
y_i^2	0,09	1,44	0,01	0,64	2,18
z_i^2	0,81	10,24	4,41	7,84	23,3
$x_i y_i$	0,9	8,4	0,1	4,0	13,4
$x_i z_i$	2,7	22,4	2,1	14	41,2

Exercice 31

1. On a les données suivantes (les chiffres entre crochets correspondent à $n_{ji}y_jx_i$) :

$y_j \backslash x_i$	2	8	12	18	n_j	$n_j.y_j$	$n_j.y_j^2$
6	8 [96]	1 [48]	1 [72]	0 [0]	10	60	360
9	1 [18]	10 [720]	2 [216]	0 [0]	13	117	1053
11	1 [22]	2 [176]	14 [1848]	1 [198]	18	198	2178
14	0 [0]	0 [0]	2 [336]	7 [1764]	9	126	1764
$n.i$	10	13	19	8	50	501	5355
$n.i x_i$	20	104	228	144	496	[5514]	
$n.i x_i^2$	40	832	2736	2592	6200		

On a $\bar{x} = \frac{496}{50} = 9,92$, $\bar{y} = \frac{501}{50} = 10,02$, $V(x) = \frac{6200}{50} - (9,92)^2 = 25,39$, $V(y) = \frac{5355}{50} - (10,02)^2 = 6,70$, $\text{Cov}(x, y) = \frac{5514}{50} - 9,92 \times 10,02 = 10,88$. On en déduit que $a = \frac{\text{Cov}(x, y)}{V(x)} = \frac{10,88}{25,39} = 0,43$ et $b = 10,02 - 0,43 \times 9,92 = 5,75$. Finalement, une équation de régression de Y en X est donnée par $D_{Y/X}$: $y = 0,43x + 5,75$.

2. L'équation de la droite de régression de X en Y est $D_{X/Y}$: $x = a'y + b'$ avec $a' = \frac{10,88}{6,70} = 1,62$ et $b' = 9,92 - 1,62 \times 10,02 = -6,31$ soit $D_{X/Y}$: $x = 1,62y - 6,31$.
3. On a $r = \frac{10,88}{\sqrt{25,39} \times \sqrt{6,70}} = 0,83$.
4. On pose $y = 15$ dans l'équation de $D_{X/Y}$. On obtient $x = 1,62 \times 15 - 6,31 = 17,99$. La note prévue en méthodes quantitatives est approximativement 18/20.
5. On pose $x = 4$ dans l'équation de $D_{Y/X}$. On obtient $y = 0,43 \times 4 + 5,75 = 7,47$. La note prévue en marketing est approximativement 07,5/20.

Exercice 32

- Le pourcentage de personnes pesant moins de 80 kilos et mesurant plus de 180 centimètres est de $\frac{2}{60} \times 100 = 3,33\%$ à 10^{-2} près.
- La proportion de personnes pesant entre 60 et 90 kilos est de $\frac{15+19+10}{60} \times 100 = 73,33\%$ à 10^{-2} près.
- $2975 = 175 \times 17$.
• $106875 = 19 \times 75^2 = 106875$.
• $94350 = 6 \times 185 \times 85$.
- On a $\bar{x} = \frac{4290}{60} = 71,5$ et $\bar{y} = \frac{10240}{60} = 170,67$ à 10^{-2} près.
- On a $V(x) = \frac{314900}{60} - (71,5)^2 = 136,08$ et $V(y) = \frac{1755900}{60} - (170,67)^2 = 136,75$ à 10^{-2} près. On en déduit $\sigma(x) = \sqrt{136,08} = 11,67$ et $\sigma(y) = \sqrt{136,75} = 11,69$.
- On a $\text{Cov}(x, y) = \frac{739150}{60} - 71,5 \times 170,67 = 116,26$ et on en déduit $r = \frac{116,26}{\sqrt{136,08} \times \sqrt{136,75}} = 0,85$.
- Un ajustement linéaire n'est pas justifié car $|r| < 0,87$. On ne peut donc prévoir à l'aide de l'échantillon donné la taille d'une personne à partir de son poids.