

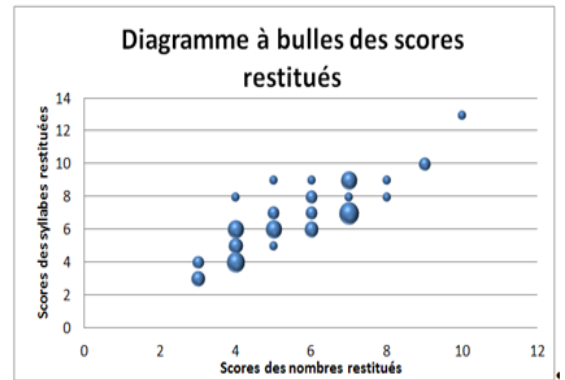
Fiche de TD N° 07  
Statistique descriptive bi-variée

**Exercice 1**

On propose 2 tests de mémorisation à des étudiants. Pour le premier, on présente une série de 30 nombres qu'ils doivent apprendre en un temps limité. On leur demande de rappeler le maximum de nombres une minute après. Pour le second, on leur présente une série de 30 syllabes qu'ils devront également apprendre et restituer. Pour chacun de ces tests, on recueille dans un tableau le nombre d'éléments rappelés après la minute de pause. Chaque sujet est caractérisé par deux scores: un score  $X$  au test des nombres et un score  $Y$  au test de syllabes.

Les résultats portant sur 50 sujets sont reportés dans le tableau ci-dessous, et représentés par le diagramme à bulles.

S	X	Y	S	X	Y	S	X	Y	S	X	Y	S	X	Y
1	5	7	11	3	3	21	8	9	31	4	4	41	7	7
2	4	5	12	4	6	22	6	7	32	5	6	42	6	6
3	4	6	13	7	9	23	5	6	33	10	13	43	8	8
4	5	9	14	6	6	24	7	8	34	4	4	44	7	7
5	4	8	15	7	7	25	4	6	35	6	8	45	3	3
6	5	7	16	9	10	26	7	7	36	4	4	46	7	9
7	6	9	17	4	4	27	3	4	37	4	5	47	4	5
8	7	9	18	9	10	28	3	3	38	4	4	48	4	6
9	6	7	19	5	6	29	6	6	39	5	6	49	3	4
10	7	7	20	6	8	30	7	7	40	5	5	50	7	9



1. Décrire le graphe.
2. Dresser la table de contingence correspondante à la série double  $(X,Y)$  en explicitant les marges.
3. Calculer et interpréter les fréquences suivantes :  $f_{23}$ ,  $f_{55}$ ,  $f_{3\bullet}$  et  $f_{\bullet 4}$
4. Calculer les scores moyens des nombres et des syllabes restituées pour l'ensemble des sujets testés.
5. Calculer le score moyen des nombres des étudiants ayant un score des syllabes égal à 5.
6. Calculer le coefficient de corrélation linéaire entre  $X$  et  $Y$ . Que peut-on conclure ?
7. Déterminer les équations des droites de régression de  $Y$  en  $X$  et de  $X$  en  $Y$ , et les représenter sur le graphe.
8. Peut-on prévoir le score des nombres restitués d'un étudiant avait un score des syllabes égal à 14?

**Exercice 2**

Un technicien de laboratoire désire étudier l'influence d'un antibiotique sur une culture bactérienne. Il répartit dans 10 tubes des volumes égaux de culture additionnées d'une quantité  $X$  d'antibiotique, et il mesure, après incubation, la densité optique  $D$ . La densité optique permet de déterminer la concentration en bactérie du milieu de culture.

Antibiotique $X$	0,1	0,2	0,3	0,4	0,5	0,6	0,7	0,8	0,9	1
Densité optique $D$	19	21	35	38	64	66	115	130	200	210

1. a. Construire le nuage de points représentant la densité optique en fonction de la concentration d'antibiotique. Que conclure.  
 b. Calculer le coefficient de corrélation linéaire entre  $X$  et  $D$ .  
 c. Trouver l'expression de la droite de régression de  $D$  en  $X$ . Tracer le sur le graphique.
2. On reprend l'analyse en posant  $Y = \ln(D)$ 
  - a. Calculer les valeurs de  $Y$  on arrondira à  $10^{-2}$  près.
  - b. Un ajustement linéaire de  $Y$  en  $X$  est-il plus légitime ? Pourquoi ?
  - c. En déduire le modèle ajustant le mieux les données initiales.
3. Un onzième tube est additionné d'une quantité d'antibiotique égale à 1,2. Donner une estimation de la densité optique de ce tube qu'on mesurera après incubation
4. En réalité, la densité optique a augmenté de 80% entre les deux mesures de la quantité d'antibiotique : 1 et 1,2. Déterminer l'erreur commise sur la densité optique en prenant l'estimation obtenue à la troisième question au lieu de la valeur réelle.

**Exercice 3**

Ajuster, par la méthode des moindres carrés, chacun des nuages de points suivants par la fonction indiquée :

1. 

$x_i$	0	2	4	6	8	10
$y_i$	1,1	0,19	0,08	0,06	0,04	0,03

$$y = \frac{1}{ax + b}$$

2. 

$x_i$	1	3	5	7	9
$y_i$	1,1	4,4	5,8	6,8	7,7

$$y = a \ln x + b$$

3. 

$x_i$	1	2	3	4	5
$y_i$	1,6	1,4	1,7	2,3	2,7

$$y = \frac{a}{x} + bx$$

Courge TD N° 07

Statistique descriptive bivariee

Exo 3

1/ Description des graphes:

Lorsqu'on décrit un nuage de points associé à une série statistique à deux variables, on doit en préciser :

- La forme : affine ou non.
- Sens : positive ou négative.
- Intensité : forte, modérée ou faible.
- Il faut aussi détecter la présence de valeurs aberrantes (points très éloignés des autres points du nuage).

\* Le graphe donné dans l'exercice est un diagramme à bulles, c'est une variante d'un graphique en nuage de points dans lequel les données sont représentées par des bulles de tailles proportionnelles aux effectifs. Il représente la distribution des 50 étudiants selon leurs scores de nombres et de syllabes.

\* Ce nuage de points fait apparaître une corrélation linéaire, bonne et positive entre les deux scores. Il ne semble pas y avoir des points aberrants.

2/ Tableau de contingence:

$x_i \backslash y_j$	3	4	5	6	7	8	9	10	13	$n_{i0}$	$n_{0i}$	$n_{i0} \cdot n_{0i}$	$\frac{n_{ij} \cdot n_{i0}}{n_{i0}}$	$\frac{n_{ij} \cdot n_{0i}}{n_{0i}}$
3	3	2	0	0	0	0	0	0	0	5	15	45	17	51
4	0	5	3	4	0	1	0	0	0	13	52	208	67	268
5	0	0	1	4	2	0	1	0	0	8	40	200	52	260
6	0	0	0	3	2	2	1	0	0	8	48	288	57	342
7	0	0	0	0	6	1	4	0	0	11	77	539	86	602
8	0	0	0	0	0	1	1	0	0	2	16	128	17	136
9	0	0	0	0	0	0	0	2	0	2	18	162	20	180
10	0	0	0	0	0	0	0	0	1	1	10	100	13	130
$n_{i0}$	3	7	4	11	10	5	7	2	1	50	276	1670		1969
$\frac{n_{ij} \cdot n_{i0}}{n_{i0}}$	9	28	20	66	70	40	63	20	11	323				
$\frac{n_{ij} \cdot n_{0i}}{n_{0i}}$	27	112	100	324	490	320	567	200	163	2321				
$\sum n_{ij} x_i$	9	26	17	54	64	31	47	18	10					
$\sum n_{ij} y_j$	27	104	85	324	448	248	423	180	130	1969				

on bien égal aussi

$$= \frac{1}{N} \sum_{i=1}^p x_i \sum_{j=1}^q n_{ij} y_j - \bar{X} \bar{Y}$$

$$= \frac{1969}{50} - (5,52 \times 6,58)$$

$$= 3,0584$$

3/ Calcul de fréquences:

$f_{23} = \frac{n_{23}}{N} = \frac{3}{50} = 0,06$

6% des étudiants ont eu un score de nombres = 4 et un score de syllabes égal à 3.

$f_{55} = \frac{n_{55}}{N} = \frac{6}{50} = 0,12$

12% des étudiants ont eu X=7 et

$f_{34} = \frac{n_{34}}{N} = \frac{8}{50} = 0,16$

16% des étudiants ont eu un score de

$f_{44} = \frac{n_{44}}{N} = \frac{11}{50} = 0,22$

22% des étudiants ont eu un score de syllabes = 6.

4/ Calcul de  $\bar{X}$ ,  $\bar{Y}$ :

$\bar{X} = \frac{1}{N} \sum_{i=1}^p n_{i0} \cdot x_i = \frac{276}{50} = 5,52$

$\bar{Y} = \frac{1}{N} \sum_{j=1}^q n_{0j} \cdot y_j = \frac{329}{50} = 6,58$

5/ Calcul de  $\bar{X}_{Y=5}$

$\bar{X}_{Y=5} = \frac{1}{n_{23}} \sum_{i=1}^p n_{i2} \cdot x_i = \frac{17}{4} = 4,25$

6/ Calcul de r:

$r = \frac{\text{Cov}(X,Y)}{\sqrt{s_x \cdot s_y}}$

$\text{Cov}(X,Y) = \frac{1}{N} \sum_{j=1}^q \sum_{i=1}^p n_{ij} x_i y_j - \bar{X} \cdot \bar{Y}$

$$= \frac{1}{N} \sum_{j=1}^q y_j \sum_{i=1}^p n_{ij} x_i - \bar{X} \bar{Y}$$

$V(X) = \frac{1}{N} \sum_{i=1}^p n_{i0} \cdot x_i^2 - \bar{X}^2 = \frac{1670}{50} - 5,52^2 = 2,9296$

$\Rightarrow s_x = \sqrt{2,9296} = 1,71$

$V(Y) = \frac{1}{N} \sum_{j=1}^q n_{0j} \cdot y_j^2 - \bar{Y}^2 = \frac{2321}{50} - 6,58^2 = 4,3236$

$\Rightarrow s_y = \sqrt{4,3236} = 2,07$

$r = \frac{3,0584}{1,71 \times 2,07} = 0,86$

0,7 < r < 0,95  $\Rightarrow$  bonne corrélation linéaire entre les deux scores.



1. Donner les valeurs exactes :

$y/x : y = ax + b$  avec :

$a = \frac{Cov(X, Y)}{V(X)} = \frac{2,0584}{2,9236} = 1,04$

$b = \bar{Y} - a\bar{X} = 6,53 - 1,04 \cdot 6,52 = 0,81$

$D_{y/x} : \boxed{y = 1,04x + 0,81}$

2.  $x = ay + b$  avec :

$a = \frac{Cov(X, Y)}{V(Y)} = \frac{3,0514}{4,3236} = 0,70$

$b = \bar{X} - a\bar{Y} = 5,52 - 0,70 \cdot 6,53 = 0,86$

$D_{x/y} : x = 0,70y + 0,86 \Leftrightarrow y = 1,42x - 1,22$


$D_{x/y} : \boxed{y = 1,42x - 1,22}$

3. On peut prévoir le score des nombres absolutés d'... en utilisant l'équation de la droite de régression de X sur Y :

$x = 0,7(14) + 0,86 = 10,60$

02 -

a. Nuage de Points :



La densité optique en fonction de la quantité d'antibiotique

Conclusion: le nuage de points semble presque aligné, ce qui justifie une corrélation forte, linéaire et positive entre X et D.

b. Calcul :  $r(X, D)$

$\bar{X} = \frac{1}{N} \sum_{i=1}^n x_i = \frac{55}{10} = 5,5$

$x_i$	$d_i$	$x_i^2$	$d_i^2$	$x_i d_i$	$\frac{x_i}{n}$	$\frac{d_i}{n}$	$\frac{x_i d_i}{n}$
01	13	01	169	13	0,1	1,3	1,3
02	21	04	441	42	0,2	2,1	4,2
03	35	09	1225	105	0,3	3,5	10,5
04	46	16	2116	184	0,4	4,6	18,4
05	64	25	4096	320	0,5	6,4	32,0
06	66	36	4356	396	0,6	6,6	39,6
07	115	49	13225	795	0,7	11,5	79,5
08	130	64	16900	1040	0,8	13,0	104,0
09	180	81	32400	1620	0,9	18,0	162,0
1	210	1	44100	210	1,0	21,0	210,0
55	375	3025	140625	677,9	41,73		

$V(X) = \frac{1}{N} \sum_{i=1}^n x_i^2 - \bar{X}^2 = \frac{3,25}{10} - 0,55^2 = 0,0825$

$\sigma_X = \sqrt{V(X)} = 0,28$

$\bar{D} = \frac{1}{N} \sum_{i=1}^n d_i = \frac{375}{10} = 37,5$

$V(D) = \frac{1}{N} \sum_{i=1}^n d_i^2 - \bar{D}^2 = \frac{124,149}{10} - 37,5^2 = 450,76$

$\sigma_D = \sqrt{V(D)} = 67,45$

$Cov(X, D) = \frac{1}{N} \sum_{i=1}^n x_i d_i - \bar{X} \bar{D}$

$= \frac{677,9}{10} - 0,55 \times 37,5 = 18,4$

$r(X, D) = \frac{Cov(X, D)}{\sigma_X \sigma_D} = \frac{18,4}{0,28 \times 67,45} = 0,97$

Interpretation :  $r(X, D) > 0,95 \Rightarrow$  il existe une forte corrélation linéaire entre X et D.

c. Droite de régression de D sur X :

$D_{D/X} : d = ax + b$  avec :

$a = \frac{Cov(X, D)}{V(X)} = \frac{18,4}{0,0825} = 223,03$

$b = \bar{D} - a\bar{X} = 37,5 - 223,03 \times 0,55 = -32,86$

$D_{D/X} : \boxed{d = 223,03x - 32,86}$



2. On pose  $Y = \ln(D)$

a. Valeurs de Y (Tableau)

b. Pour répondre à cette question, on calcule  $\bar{Y}$  et le compare avec  $\bar{X}$ .

$$\bar{Y} = \frac{1}{n} \sum_{i=1}^n y_i = \frac{41,73}{10} = 4,173$$

$$V(Y) = \frac{1}{n} \sum_{i=1}^n y_i^2 - \bar{Y}^2 = \frac{121,5871}{10} - 4,173^2$$

$$V(Y) = 0,69 \Rightarrow \sigma_Y = 0,83$$

$$\begin{aligned} \text{Cov}(X, Y) &= \frac{1}{n} \sum_{i=1}^n x_i y_i - \bar{X} \cdot \bar{Y} \\ &= \frac{25,354}{10} - 0,55 \times 4,173 \\ &= 0,23 \end{aligned}$$

$$r_{X,Y} = \frac{\text{Cov}(X, Y)}{\sigma_X \sigma_Y} = \frac{0,23}{0,28 \times 0,83} = 0,99$$

$$r_{X,Y} > r_{X,D}$$

⇒ l'ajustement de Y en X est plus légitime.

c. Modèle ajustant le mieux les données initiales ( $x_i, d_i$ ):

La droite de régression de Y en X:

$$D_{Y/X}: y = \alpha x + \beta$$

$$\alpha = \frac{\text{Cov}(X, Y)}{V(X)} = \frac{0,23}{0,025} = 9,2$$

$$\beta = \bar{Y} - \alpha \bar{X} = 4,173 - 9,2 \times 0,55 = 2,64$$

$$D_{Y/X}: y = 9,2x + 2,64$$

$$\Leftrightarrow \ln d = 9,2x + 2,64$$

$$\Leftrightarrow d = e^{2,64} \times e^{9,2x}$$

$$\Leftrightarrow d = 14,01 \cdot (16,11)^x$$

c'est un modèle exponentiel qui ajuste le mieux les données initiales

3. Estimation de la densité optique pour le 11<sup>ème</sup> tube:  $x = 1,2$

$$\frac{d(1,2)}{e} = 14,01 \cdot (16,11)^{1,2} = 393,50$$

4. L'erreur commise sur la densité optique

du note  $d_R$ : la densité optique réelle

$$\begin{aligned} d_R(1,2) &= d_R(1) + 0,8 \cdot d_R(1) \\ &= 1,8 \cdot d_R(1) = 1,8 \times 210 = 378 \end{aligned}$$

Donc l'erreur commise est:

$$e = |d_R(1,2) - d_e(1,2)| = |378 - 393,50|$$

$$\Rightarrow e = 15,5$$

Exo3. Ajustement non linéaire:

$$y = \frac{1}{ax+b} \Leftrightarrow \frac{1}{y} = ax+b$$

Donc X et  $\frac{1}{y}$  sont liés linéairement

$$\text{D'où: } a = \frac{\text{Cov}(X, 1/Y)}{V(X)} = \frac{37,63}{11,66} = 3,22$$

$$b = \frac{1}{\bar{Y}} - a \bar{X} = 15,6 - 3,22 \times 5 = -9,5$$

$x_i$	$y_i$	$y_i^2$	$x_i^2$	$x_i/y_i$
0	11	121	0	0
2	0,19	0,0361	4	10,52
4	0,08	0,0064	16	50
6	0,06	0,0036	36	93,96
8	0,04	0,0016	64	200
10	0,03	0,0009	100	333,3
30		93,85	220	693,78

$$\bar{X} = \frac{30}{6} = 5, \quad V_X = \frac{220}{6} - 5^2 = 11,66$$

$$\bar{1/Y} = \frac{93,85}{6} = 15,6 \quad \text{Cov}(X, 1/Y) = \frac{693,78}{6} - 5 \times 15,6 = 37,63$$

Donc le modèle d'ajustement est:

$$y = \frac{1}{3,22x - 9,5}$$

$$2/. y = a \ln x + b$$

$$a = \frac{\text{Cov}(\ln X, Y)}{V(\ln X)}$$

$$b = \bar{Y} - a \bar{\ln X}$$

$x_i$	$y_i$	$\ln x_i$	$(\ln x_i)^2$	$y_i \cdot \ln x_i$
1	11	0	0	0
3	4,4	1,09	1,1881	4,79
5	5,8	1,6	2,56	9,28
7	6,8	1,94	3,7636	13,19
9	7,7	2,19	4,7961	16,86
	25,8	6,82	12,3078	44,11

$$\bar{\ln X} = \frac{6,82}{5} = 1,364 \quad V(\ln X) = \frac{12,3078}{5} - 1,364^2 = 0,60$$



$$\bar{Y} = \frac{25,8}{5} = 5,16$$

$$\text{cov}(\ln X, Y) = \frac{44,131}{5} - 1,364 \times 5,16 = 1,78$$

Donc:  $a = \frac{1,78}{0,60} = 2,96$

$$b = 5,16 - a \times 1,364 = 1,11$$

$$\Rightarrow y = 2,96 \ln x + 1,11$$

3/  $y = \frac{a}{x} + bx \Leftrightarrow y/x = \frac{a}{x^2} + b$

Donc:  $a = \frac{\text{cov}(1/x^2, Y/X)}{V(1/x^2)}$

$$b = \overline{Y/X} - a \overline{1/x^2}$$

$x_i$	$x_i$	$1/x_i^2$	$1/x_i^4$	$1/x_i$	$y_i/x_i^3$
1	1,6	1	1	1,6	1,6
2	1,4	0,25	0,0625	0,7	0,175
3	1,7	0,11	0,0121	0,56	0,0616
4	2,3	0,06	0,0036	0,57	0,0342
5	2,7	0,04	0,0016	0,54	0,0216
		1,46	1,0798	3,97	1,8924

$$\overline{1/x^2} = \frac{1,46}{5} = 0,292$$

$$V(1/x^2) = \frac{1,0798}{5} - 0,292^2 = 0,13$$

$$\overline{Y/X} = \frac{3,97}{5} = 0,794$$

$$\text{cov}(1/x^2, Y/X) = \frac{1,8924}{5} - 0,292 \times 0,794 = 0,14$$

Ainsi:  $a = \frac{0,14}{0,13} = 1,07$

$$b = 0,794 - a \times 0,292 = 0,47$$

$$\Rightarrow y = \frac{1,07}{x} + 0,47x$$

2<sup>ème</sup> méthode:

En appliquant la méthode des moindres carrés.

par exemple le 3<sup>ème</sup> modèle:

Pour déterminer les paramètres du modèle:  $y = \frac{a}{x} + bx$  on minimise

la fonction:  $S(a,b) = \sum_{i=1}^N \left( \frac{a}{x_i} + bx_i - y_i \right)^2$

$$\Rightarrow \begin{cases} \frac{\partial S}{\partial a} = 0 \\ \frac{\partial S}{\partial b} = 0 \end{cases} \Rightarrow \begin{cases} 2 \sum_{i=1}^N \frac{1}{x_i} \left( \frac{a}{x_i} + bx_i - y_i \right) = 0 \\ 2 \sum_{i=1}^N x_i \left( \frac{a}{x_i} + bx_i - y_i \right) = 0 \end{cases}$$

$$\Rightarrow \begin{cases} a \sum_{i=1}^N \frac{1}{x_i^2} + Nb = \sum_{i=1}^N \frac{y_i}{x_i} \\ Na + b \sum_{i=1}^N x_i^2 = \sum_{i=1}^N x_i y_i \end{cases}$$

Il reste à calculer les sommes du système.

$1/x_i^2$	$x_i^2$	$x_i y_i$	$y_i/x_i$
1	1	1,6	1,6
4	4	2,8	0,175
9	9	5,1	0,0616
16	16	9,2	0,0342
25	25	13,5	0,0216
1,46	55	32,2	1,8924

Donc on obtient le système linéaire:

$$\begin{cases} 1,46a + 5b = 3,97 \\ 5a + 55b = 32,2 \end{cases}$$

$$\Delta = \begin{vmatrix} 1,46 & 5 \\ 5 & 55 \end{vmatrix} = 55,3 \neq 0$$


$$a = \frac{1}{55,3} \begin{vmatrix} 3,97 & 5 \\ 32,2 & 55 \end{vmatrix} = \frac{5}{55} = 1,07$$

$$b = \frac{1}{55,3} \begin{vmatrix} 1,46 & 3,97 \\ 5 & 32,2 \end{vmatrix} = \frac{3,97}{32,2} = 0,47$$


Voici les nuages de points correspondants

1.  $y = \frac{1}{ax+b}$

y en fonction de x




1/y en fonction de x




2.  $y = a \ln x + b$

y en fonction de x




y en fonction de ln x



3.  $y = \frac{a}{x} + bx$

y en fonction de x



y/x en fonction de 1/x^2

