

Statistique à deux variables : L'essentiel du cours

Pour une série :

Caractère x_i	x_1	x_2	\dots	x_n
Caractère y_i	y_1	y_2	\dots	y_n

a) Point moyen

Le point moyen G a pour abscisse la moyenne des x_i et pour ordonnée la moyenne des y_i .

b) Droite des moindres carrés

La droite des moindres carrés de y en x :

- a pour équation $y = ax + b$ où a et b sont donnés par la calculatrice
 - ▶ pour CASIO :

MENU

 →

STAT

 - Entrée des données : rentrer les valeurs x_i dans la liste 1 et les valeurs y_i dans la liste 2.
 - Affichage des résultats :

CALC

 →

SET

 Pour 2Var XList, choisir List 1
 Pour 2Var YList, choisir List 2
 Pour 2VarFreq, taper 1
 Choisir

REG

, puis

X

 On peut lire a et b dans la liste des résultats
 - ▶ pour TI :
 - Entrée des données :

stats

EDIT

1:Edite

 ; rentrer les valeurs x_i dans L1 et les valeurs y_i dans L2.
 - Affichage des résultats :

stats

CALC

4:RegLin(ax+b)

 Xlist : L1 et Ylist : L2, puis Calculs
- doit passer par le point moyen.

▶ Exemple :

x_i	1	2	3	4	5
y_i	8	9	12	12	14

- Point moyen : $\bar{x} = \frac{1+2+3+4+5}{5} = 3$; $\bar{y} = \frac{8+9+12+12+14}{5} = 11$

Donc, on a $G(3; 11)$

- Droite des moindres carrés : La calculatrice donne $a = 1,5$ et $b = 6,5$. Une équation de la droite des moindres carrés est donc : $y = 1,5x + 6,5$
- Estimation de la valeur de y pour $x = 7$: $y = 1,5 \times 7 + 6,5 = 17$

c) Coefficient de corrélation

Le coefficient de corrélation linéaire r :

- s'obtient à la calculatrice ;
- est toujours compris entre -1 et 1 ;
- plus les points sont « regroupés » autour d'une même droite et plus il est proche de 1 pour des données croissantes et de -1 pour des données décroissantes ;
- ne prouve en rien un lien de cause à effet entre les deux variables de la série statistique.

Statistique à deux variables

► Exercice n°1

Calculer les coordonnées du point moyen de la série suivante :

x_i	200	205	208	211	215
y_i	5200	5400	5600	5900	6400

► Exercice n°2

Déterminer x et y pour que le point moyen de la série soit de coordonnées $(7,5 ; 12,6)$.

x_i	8,2	7,4	x	6,1	9
y_i	15	12,1	16,3	y	12

Rappel :

Détermination à la calculatrice de la droite des moindres carrés :

► pour CASIO :

MENU → **STAT**

• Entrée des données : rentrer les valeurs x_i dans la liste 1 et les valeurs y_i dans la liste 2.

• Affichage des résultats : **CALC** → **SET**

Pour 2Var XList, choisir List 1

Pour 2Var YList, choisir List 2

Pour 2VarFreq, taper 1

Choisir **REG**, puis **X**

On peut lire a et b dans la liste des résultats

► pour TI :

• Entrée des données : **stats** **EDIT** **1:Edite** ; rentrer les valeurs x_i dans L1 et les valeurs y_i dans L2.

• Affichage des résultats : **stats** **CALC** **4:RegLin(ax+b)**


Xlist : L1 et Ylist : L2, puis Calculs

► Exercice n°3

On considère la série statistique double ci-dessous.

x_i	1	3	4	6	7	8
y_i	11,1	13	14,5	16	16,9	19

1. Représenter le nuage de points $M_i(x_i, y_i)$ dans le repère ci-dessous :



2. Calculer les coordonnées du point moyen et placer ce point dans le repère.
3. Donner une équation de la droite de régression de y en x obtenue par la méthode des moindres carrés et tracer cette droite dans le repère. (a et b seront arrondis à 0,01 près)

► Exercice n°4

Le tableau suivant donne la moyenne y des maxima de tension artérielle en fonction de l'âge x .

âge x_i	36	42	48	54	60	66	70
tension y_i	12	13	13,6	14,3	15,4	15,8	16

1. Donner une équation de la droite de régression de y en x obtenue par la méthode des moindres carrés. (a et b seront arrondis à 0,01 près)
2. Quelle serait la tension théorique d'une personne de 75 ans en utilisant le modèle de la droite des moindres carrés? (arrondir le résultat à 0,1 près)

► Exercice n°5


Un nuage de points $A_i(x_i, y_i)$ est tel que $\ln y_i = 2x_i + 5$. Écrire y_i en fonction de x_i . (on écrira y_i sous la forme $A e^{Bx_i}$ en arrondissant A à 0,01 près)

► **Exercice n°6**


Le tableau suivant donne le nombre d'abonnés à un jeu en ligne.

Année	2014	2015	2016	2017	2018
Rang de l'année x_i	1	2	3	4	5
Nombre d'abonnés y_i (en milliers)	40	80	130	260	420
$z_i = \ln y_i$					

1. Le nuage de points $A_i(x_i, y_i)$ est représenté ci-dessous. Un ajustement affine vous semble-t-il adapté ?



2. Compléter dans le tableau la ligne indiquant $z_i = \ln y_i$. (arrondir à 0,01 près)
 3. Représenter le nuage de points $B_i(x_i, z_i)$ dans le repère ci-dessous :



4. Donner une équation de la droite de régression de z en x obtenue par la méthode des moindres carrés et tracer cette droite dans le repère. (a et b seront arrondis à 0,001 près)

5. En déduire l'expression de y en fonction de x en suivant ce modèle. (on écrira y sous la forme Ae^{Bx} en arrondissant A à 0,001 près)
 6. Selon ce modèle, quel serait le nombre d'abonnés en 2022 ? (donner le résultat au millier près)

► **Exercice n°7**

Le tableau suivant indique la teneur en CO₂ depuis 1850.

Année	1850	1900	1950	1990
Rang de l'année : x_i	0	50	100	140
Teneur en CO ₂ : y_i	275	290	315	360
$z_i = \ln(y_i - 250)$				

1. Compléter dans le tableau la ligne indiquant $z_i = \ln(y_i - 250)$.
 2. Donner une équation de la droite de régression de z en x obtenue par la méthode des moindres carrés. (a et b seront arrondis à 0,01 près)
 3. Selon ce modèle, quel serait le taux de CO₂ en 2050 ? (donner le résultat à une unité près)

► **Exercice n°8**

Un étude sur la solubilité d'un médicament en fonction de la température de l'eau a donné les résultats suivants :

Température x_i	20	30	40	50	60	70
Solubilité s_i	10,30	10,59	10,81	11	11,15	11,28
$y_i = e^{s_i}$						

1. Compléter dans le tableau la ligne indiquant $y_i = e^{s_i}$. (arrondir à l'unité près)
 2. Donner une équation de la droite de régression de y en x obtenue par la méthode des moindres carrés. (a et b seront arrondis à l'unité près)
 3. En déduire l'expression de la solubilité S en fonction de x en suivant ce modèle.

► **Exercice n°9**


On considère la série suivante :

x_i	1	2	3	4	5
y_i	5	20	70	300	800

1. Ces données qui progressent rapidement en ordonnée peuvent difficilement être représentées dans un repère orthogonal classique. Dans ce cas là, on peut utiliser un repère dit semi-logarithmique où un point d'ordonnée y est placé à une « hauteur » $Y = \log y$ (dans l'unité choisie) où \log représente le logarithme

décimal.

Placer dans le repère semi-logarithmique ci-dessous le nuage de points A_i .



2. Placer dans ce repère, G , le point moyen de ce nuage de points.
3. Déterminer à la calculatrice le coefficient de corrélation pour les données $(x_i; y_i)$ et comparer le à celui des données $(x_i; \log(y_i))$

Statistique à deux variables

► **Exercice n°1**

$\bar{x} = 207,8$; $\bar{y} = 700$


► **Exercice n°2**

On doit avoir $\begin{cases} \frac{8,2 + 7,4 + x + 6,1 + 9}{5} = 7,5 \\ \frac{15 + 12,1 + 16,3 + y + 12}{5} = 12,6 \end{cases}$

$\Leftrightarrow \begin{cases} \frac{30,7 + x}{5} = 7,5 \\ \frac{55,4 + y}{5} = 12,6 \end{cases} \Leftrightarrow \begin{cases} 30,7 + x = 37,5 \\ 55,4 + y = 63 \end{cases} \Leftrightarrow \begin{cases} x = 6,8 \\ y = 7,6 \end{cases}$

► **Exercice n°3**

1.



2. $\bar{x} = 4,83$; $\bar{y} = 15,8$

3. $y = 1,06x + 9,95$

► **Exercice n°4**

1. $y = 0,12x + 7,84$

2. Si $x = 75$, $y \approx 16,8$

► **Exercice n°5**

$\ln y_i = 2x_i + 5 \Leftrightarrow y_i = e^{2x_i+5} = e^{2x_i} \times e^5 \approx 148,41 e^{2x_i}$.


► **Exercice n°6**

1. Non.

2.

Année	2014	2015	2016	2017	2018
Rang de l'année x_i	1	2	3	4	5
Nombre d'abonnés y_i (en milliers)	40	80	130	260	420
$z_i = \ln y_i$	3,69	4,38	4,87	5,56	6,04

3.



4. $z = 0,588x + 3,144$

5. $\ln y = 0,588x + 3,144 \Leftrightarrow y = e^{0,588x+3,144} = e^{0,588x} \times e^{3,144} \approx 23,196 e^{0,588x}$

6. 2022 correspond à $x = 9$.

On a alors $y \approx 23,196 e^{0,588 \times 9} \approx 4610$ milliers d'abonnés.

► Exercice n°7

1.

Année	1850	1900	1950	1990
Rang de l'année : x_i	0	50	100	140
Teneur en CO ₂ : y_i	275	290	315	360
$z_i = \ln(y_i - 250)$	3,22	3,69	4,17	4,70

2. $z = 0,01x + 3,19$

3. 2050 correspond à $x = 200$.

On a alors $z \approx 0,01 \times 200 + 3,19 \Leftrightarrow \ln(y - 250) \approx 5,19 \Leftrightarrow y - 250 \approx e^{5,19}$
 $\Leftrightarrow y \approx 250 + e^{5,19} \approx 429$

► Exercice n°8

1.


Température x_i	20	30	40	50	60	70
Solubilité s_i	10,30	10,59	10,81	11	11,15	11,28
$y_i = e^{s_i}$	29733	39735	49513	59874	69564	79221

2. $y = 992x + 9955$

3. $y = 992x + 9955 \Leftrightarrow e^s = 992x + 9955 \Leftrightarrow s = \ln(992x + 9955)$

► Exercice n°9

1.



2. $\bar{x} = 3$; $\bar{y} = 239$

3. Coefficient de corrélation pour $(x_i; y_i)$: $r \approx 0,882$

Coeficient de corrélation pour $(x_i; \log(y_i))$: $r \approx 0,998$

Les points sont beaucoup plus proches d'une droite avec la série $(x_i; \log(y_i))$.