

# Statistique à 2 variables

©Pascal Brachet (CC BY NC SA)

<https://www.xm1math.net>

## 1. Rappels sur les séries statistiques à 1 variable

Rappels					Exemple					
Étant donné une série statistique définie par :										
Valeurs du caractère	$x_1$	$x_2$	$\dots$	$x_p$	$x_i$	1	2	3	4	5
Effectif	$n_1$	$n_2$	$\dots$	$n_p$	$n_i$	2	3	1	3	1
L'effectif total est : $N = n_1 + n_2 + \dots + n_p$					$N = 2 + 3 + \dots + 1 = 10$					
La moyenne est définie par :										
$\bar{x} = \frac{n_1 x_1 + n_2 x_2 + \dots + n_p x_p}{N}$					$\bar{x} = \frac{2 \times 1 + 3 \times 2 + \dots + 1 \times 5}{10} = 2,8$					
La variance est définie par :										
$V = \frac{n_1 (x_1 - \bar{x})^2 + n_2 (x_2 - \bar{x})^2 + \dots + n_p (x_p - \bar{x})^2}{N}$					$V = \frac{2 \times (1 - 2,8)^2 + \dots + 1 \times (5 - 2,8)^2}{10}$					
					$= 1,76$					
L'écart-type est $\sigma = \sqrt{V}$					$\sigma = \sqrt{1,76} \approx 1,327$					

## 2. Séries statistiques à 2 variables

### a) Situation

Sur une même population, on étudie deux caractères. Pour chacun des individus, on note  $x_1, x_2, \dots, x_n$  les valeurs du 1<sup>er</sup> caractère et  $y_1, y_2, \dots, y_n$  les valeurs du 2<sup>e</sup> caractère. Les données sont présentées sous la forme suivantes :

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

### b) Nuage de points et point moyen

#### Définition

- Dans un repère orthogonal, on appelle **nuage de points** associé à une série statistique à 2 variables, l'ensemble des points d'abscisse  $x_1, x_2, \dots, x_n$  et d'ordonnée  $y_1, y_2, \dots, y_n$ .
- Le **point moyen** du nuage de points est le point  $G$  d'abscisse  $\bar{x}$  (moyenne des  $x_i$ ) et d'ordonnée  $\bar{y}$  (moyenne des  $y_i$ ).

## 2. Séries statistiques à 2 variables

### Exemple(s)

Avec la série :


$x_i$	1	2	3	4	5
$y_i$	3	4	7	7	8

On a :

$$\bar{x} = \frac{1 + 2 + 3 + 4 + 5}{5} = 3$$

$$\bar{y} = \frac{3 + 4 + 7 + 7 + 8}{5} = 5,8$$

Le point moyen  $G$  a pour abscisse 3 et pour ordonnée 5,8



### b) Covariance d'une série statistique à 2 variables

#### Définition


La covariance des  $x_i$  et  $y_i$  est le réel noté  $\text{cov}(x; y)$  défini par :

$$\text{cov}(x; y) = \frac{(x_1 - \bar{x})(y_1 - \bar{y}) + (x_2 - \bar{x})(y_2 - \bar{y}) + \cdots + (x_n - \bar{x})(y_n - \bar{y})}{n}$$

### 3. Ajustement d'un nuage de points

#### a) Introduction - Méthode des moindres carrés

- Effectuer un **ajustement** de  $y$  en  $x$  d'un nuage de points, c'est chercher une fonction  $f$  dont la courbe est la « plus proche possible » des points du nuage.
- On peut alors se servir de l'ajustement pour **estimer** une valeur de  $y$  pour un  $x$  non donné dans le nuage :
  - si le  $x$  est à l'extérieur du nuage, l'estimation est appelée **extrapolation** ;
  - si le  $x$  est à l'intérieur du nuage, l'estimation est appelée **interpolation** ;
- Pour chaque point du nuage d'abscisse  $x_i$  et d'ordonnée  $y_i$ , on appelle **résidu** la différence  $y_i - f(x_i)$ .
- La méthode d'ajustement par **les moindres carrés** consiste à trouver une fonction  $f$  telle que la somme des carrés des résidus soit la plus petite possible.



#### b) Cas des ajustements affines

Lorsqu'on cherche un ajustement avec une fonction  $f$  affine dont la courbe est une droite, on dit qu'on effectue un **ajustement affine** de  $y$  en  $x$ . Ce type d'ajustement est adapté aux cas où les points du nuage semblent « à peu près alignés ».

### 3. Ajustement d'un nuage de points

#### Définition-Propriété

- L'utilisation de la méthode des moindres carrés pour déterminer un ajustement affine donne une droite, appelée **droite des moindres carrés** ou **droite de régression** de  $y$  en  $x$ , telle que :
  - cette droite passe par le point moyen  $G$  du nuage de points ;
  - cette droite admet comme équation  $y = ax + b$  avec  $a = \frac{\text{cov}(x; y)}{V(x)}$  et  $b = \bar{y} - a\bar{x}$  ( $a$  et  $b$  sont fournis directement par la calculatrice)
- La « qualité » de l'ajustement peut-être vérifié par le calcul du **coefficient de corrélation linéaire**  $r = \frac{\text{cov}(x; y)}{\sigma(x)\sigma(y)}$ . Plus ce coefficient est proche de 1 (pour des données croissantes) ou de  $-1$  (pour des données décroissantes), plus les points du nuage sont proches de la droite des moindres carrés.

#### Obtention de la droite des moindres carrés avec une 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 (ainsi que  $r$ )

### 3. Ajustement d'un nuage de points

#### Obtention de la droite des moindres carrés avec une 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 :

Pour  $a$  et  $b$  : **stats** **CALC** **4:RegLin(ax+b)**

Xlist : L1 et Ylist : L2, puis Calculs

Pour  $r$  : **var** **5:Statistiques** **EQ** **r**

#### Exemple(s)

Avec la série :

$x_i$	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  $x = 7$  :  $y = 1,5 \times 7 + 6,5 = 17$

### 3. Ajustement d'un nuage de points

#### c) Ajustement se ramenant par changement de variable à un ajustement affine

##### Remarque(s)

Quand les points du nuage ne semblent pas « regroupés autour d'une même droite » mais plutôt autour d'une courbe, on peut être amené à effectuer des ajustements affines entre  $x_i$  et  $\ln(y_i)$ , ou entre  $\ln(x_i)$  et  $\ln(y_i)$ , ou entre  $x_i^2$  et  $y_i$  ...


##### Exemple(s)

Le tableau ci-dessous indique la population d'une ville en milliers d'habitants selon l'année :

Année	2015	2016	2017	2018	2019	2020
Rang de l'année $x_i$	0	1	2	3	4	5
Nb d'habitants $y_i$	10,5	11,1	11,8	12,7	14,3	16,4

Le nuage de points associé suggère qu'un ajustement affine de  $y$  en  $x$  ne semble pas très adapté : la progression du nombre d'habitants semble plus être exponentielle qu'affine.

On pense donc à effectuer un ajustement affine non pas entre  $x_i$  et  $y_i$ , mais entre  $x_i$  et  $\ln(y_i)$ .




### 3. Ajustement d'un nuage de points

#### Exemple(s)

- ① On pose  $z = \ln y$ . La série de  $z$  en  $x$  devient :

Rang de l'année $x_i$	0	1	2	3	4	5
$z_i = \ln(y_i)$	2,35	2,41	2,47	2,54	2,66	2,88

Et le nuage de points de  $z$  en  $x$  devient :



- ② Avec la calculatrice, on obtient  $z = 0,092x + 2,313$  comme droite de régression de  $z$  en  $x$  par la méthode des moindres carrés.
- ③ Reste à en déduire le nombre de milliers d'habitants  $y$  sous la forme  $y = A e^{Bx}$  :
- $$z = 0,092x + 2,313$$
- $$\Leftrightarrow \ln y = 0,092x + 2,313$$
- $$\Leftrightarrow y = e^{0,092x + 2,313}$$
- $$\Leftrightarrow y = e^{2,313} \times e^{0,092x}$$
- $$\Leftrightarrow y = 10,105 e^{0,092x}$$
- ④ On peut dès lors obtenir, par exemple, une estimation du nombre de milliers d'habitants en 2021 en prenant  $x = 6$  : pour  $x = 6$ , on a  $y = 10,105 e^{0,092 \times 6} \approx 17,55$

Fin du chapitre