

# Série Statistique à deux variables

## 1. Nuage de points

Le plan est muni d'un repère orthogonal .

Pour une population donnée, on peut s'intéresser simultanément à deux caractères  $x$  et  $y$ .

Les valeurs prises par  $x$  sont  $x_1, x_2, \dots, x_n$ .

Les valeurs prises par  $y$  sont  $y_1, y_2, \dots, y_n$ .

La représentation graphique des points  $M_i (x_i, y_i)$  est le nuage de points associé à cette série statistique.

## 2. Point moyen


Le point moyen du nuage de points associé à la série statistique double  $(x_i; y_i)$  est le point  $G ( \bar{x}; \bar{y} )$ .

où  $\bar{x}$  et  $\bar{y}$  sont les moyennes respectives des variables  $x_i$  et  $y_i$ .

Exemple

Le tableau suivant représente le montant en million d'Ariary des importations d'une société pendant 8 années consécutives :

Rang de l'année $x_i$	1	2	3	4	5	6	7	8
Montant $y_i$	5	6,5	7	6,5	10	12	11,5	13,5



## 3. Covariance

La covariance de la série statistique double est le nombre  $\text{Cov} (X, Y)$  définie par :

$$\text{cov} (X, Y) = \frac{1}{n} \sum_{i=1}^n x_i y_i - \bar{x} \bar{y}$$

On démontre que la covariance joue un rôle analogue à la variance dans le cas d'une série statistique simple . Si on fait  $X = Y$

on obtient la formule de la variance .

Exemple

Dans l'exemple de la série statistique précédente, on a  $\sum_{i=1}^n x_i \cdot y_i = 1.5 + 2.6,5 + \dots + 8.13,5 = 375,5$  ;

$\text{Cov}(X, Y) = \frac{375,5}{8} - 4,5 \cdot 9$  ; on a  $\text{Cov}(X, Y) = 6,44$

## 4. Coefficient de corrélation linéaire

On appelle coefficient de corrélation linéaire entre X et Y le réel défini par :

$$r = \frac{\text{cov}(X, Y)}{\sqrt{V(X)V(Y)}} = \frac{\text{cov}(X, Y)}{\sigma(X)\sigma(Y)}$$

- Le coefficient de corrélation linéaire r vérifie :  $-1 \leq r \leq 1$
- La corrélation entre X et Y est forte si  $|r| \geq 0,866$


Un ajustement affine entre X et Y consiste à déterminer une droite qui passe le plus près possible des différents nuage points associé à la série (X, Y) . Cette droite est alors utilisée pour estimer la valeur de l'une des variables X ou Y connaissant l'autre.

Si la corrélation entre X et Y est forte, on peut effectuer un ajustement affine entre X et Y.

## 5. Ajustement affine par la méthode des moindres carrés

### 5.1 Le principe de la méthode

On considère dans le plan muni d'un repère orthogonal le nuage de points associé à la série statistique double (X, Y). On trace une droite (D) :  $y = ax + b$  et on note  $P_i$  les projetés de  $M_i$  sur (D) parallèlement à l'axe des ordonnées.  $M_i P_i$  représente la distance entre les point  $M_i$  et  $P_i$  .



## 5.2 Droite de régression de y en x

On appelle droite de régression de y en x (ou droite d'ajustement de y en x) par la méthode des moindres carrés la droite (D) telle que la somme  $M_1P_1^2 + M_2P_2^2 + \dots + M_nP_n^2$  soit minimale.

Cette droite passe par le point moyen G

La droite de régression de y en x a pour équation  $y - \bar{y} = a(x - \bar{x})$  avec :

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

Exemple

repreons l'exemple de la série statistique étudiée dans ce chapitre, on sait que :

$\text{Cov}(X, Y) = 6,44$   $V(X) = 5,25$  et en tenant compte des résultats  $\bar{x} = 4,5$  et  $\bar{y} = 9$

(D) :  $y = 1,23x + 3,47$ .

## 5.3 Droite de régression de x en y

La droite de régression de x en y a pour équation  $x - \bar{x} = a'(y - \bar{y})$  avec :

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


Exemple

Considérons La série statistiques double représenté par le tableau suivant.

$x_i$	69,1	56,6	52,	50	48	45,3	43,3
$y_i$	7,3	10,8	11,4	11,4	12	12,3	12,1

- 1) Représenter le nuage de points associé à cette série.
- 2) Calculer les coordonnées du point moyen G
- 3) Calculer le coefficient de corrélation r.
- 4) Déterminer l'équation de la droite de régression de y en x.
- 5) estimer la valeur de y pour  $x = 40$ .

### 1) Nuage de points



### 2) Coordonnées de G

avec sinéquanon,  $G(52,0429 ; 11,0429)$

### 3) Coefficient de corrélation

$$r = \frac{\text{cov}(X,Y)}{\sqrt{V(X)V(Y)}} = \frac{\text{cov}(X,Y)}{\sigma(X)\sigma(Y)} = 0,967072$$

### 4) Droite de régression de y en x

$$(D) : y = -0,19x + 21,05$$

### 5) Estimation pour x = 40

$$\text{si } x = 40 ; y = -0,19(40) + 21,05 \quad ; \quad y = 13,45$$