

# Série statistique double

## Distributions marginales

### Activité 1

Un relevé statistique des tailles  $X$  (en cm) et des poids  $Y$  (en kg) d'un échantillon de 100 élèves a permis de construire le tableau suivant :

$Y \backslash X$	[40, 45[	[45, 50[	[50, 55[	[55, 60[
[150, 155[	18	10	2	0
[155, 160[	3	16	5	1
[160, 165[	0	5	13	5
[165, 170[	0	2	6	14

Donner la distribution marginale de  $X$  et la distribution marginale de  $Y$ .

Calculer  $\bar{X}$  ;  $\bar{Y}$  ;  $V(X)$  ;  $V(Y)$  ;  $\sigma(X)$  et  $\sigma(Y)$  .

#### Distribution marginale de X:

Classes	[150, 155[	[155,160[	[160,165[	[165,170[	Total
Effectifs					100

#### Distribution marginale de Y:

Classes	[40, 45[	[45,50[	[50,55[	[55,60[	Total
Effectifs					100

$$\bar{X} = \frac{1}{N} \sum_{i=1}^4 c_i n_i = \dots\dots\dots$$

$$\bar{Y} = \frac{1}{N} \sum_{i=1}^4 c_i n_i = \dots\dots\dots$$

$$V(X) = \overline{X^2} - \bar{X}^2 = \frac{1}{N} \sum_{i=1}^4 c_i^2 n_i - \bar{X}^2 = \dots\dots\dots$$

$$V(Y) = \overline{Y^2} - \bar{Y}^2 = \frac{1}{N} \sum_{i=1}^4 c_i^2 n_i - \bar{Y}^2 = \dots\dots\dots$$

$$\sigma(X) = \sqrt{V(X)} = \dots\dots\dots \quad \sigma(Y) = \sqrt{V(Y)} = \dots\dots\dots$$

## Ajustement affine

### I. Méthode des moindres carrées

#### ---Covariance

##### 👉 Cas d'un échantillon simple

$$Cov(X, Y) = \overline{XY} - \bar{X} \cdot \bar{Y} = \frac{1}{n} \sum_{i=1}^n x_i y_i - \bar{X} \cdot \bar{Y} \quad \text{où } \bar{X} \text{ et } \bar{Y} \text{ sont les moyennes}$$

arithmétiques respectives des distributions  $x_{i \ 1 \leq i \leq n}$  et  $y_{i \ 1 \leq i \leq n}$  de  $X$  et  $Y$ .

##### 👉 Cas d'un échantillon groupé (voir exercice résolu page:213)

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

#### Interprétation:

La covariance est positive si  $X$  et  $Y$  ont tendance de varier dans le même sens.

La covariance est négative si  $X$  et  $Y$  ont tendance de varier dans des sens contraires.

#### ---Coefficient de corrélation linéaire

Soit une série statistique à deux caractères quantitatifs  $X$  et  $Y$  non constants observés dans une population donnée d'effectif total  $n$ .

On appelle coefficient de corrélation linéaire de la série double  $(X, Y)$ , le réel  $r$

défini par :  $r = \frac{Cov(X, Y)}{\sigma(X) \cdot \sigma(Y)}$  où  $\sigma(X)$  et  $\sigma(Y)$  sont les écarts-types respectifs des

variables statistiques  $X$  et  $Y$ .

Soit une série statistique à deux caractères quantitatifs  $X$  et  $Y$ .

Lorsque le coefficient de corrélation linéaire  $r$  du couple  $(X, Y)$  est proche, en valeur

absolue, de 1 ( $\frac{\sqrt{3}}{2} \leq |r| \leq 1$ ), le nuage de points de la série considérée a une forme

allongée et il est possible d'approcher la liaison entre  $X$  et  $Y$  par deux relations affines représentées graphiquement par deux droites  $D_1$  et  $D_2$  passant par le point moyen  $G(\bar{X}, \bar{Y})$  du nuage de points.

La droite  $D_1$  : appelée droite de régression de  $Y$  en  $X$  et ayant pour équation:

$$y = ax + b \text{ avec } a = \frac{cov(X, Y)}{V(X)} \text{ et } b = \bar{Y} - a\bar{X}$$

La droite  $D_2$  : appelée droite de régression de  $X$  en  $Y$  et ayant pour équation:


$$x = a' y + b' \text{ avec } a' = \frac{cov(X, Y)}{V(Y)} \text{ et } b' = \bar{X} - a'\bar{Y}$$

**Activité2**

Le tableau suivant donne l'âge  $X$  et la tension artérielle  $Y$  de 10 personnes.

$X$	58	40	74	34	65	49	53	51	36	40
$Y$	16,7	13,1	17,2	11,6	15,5	15,1	14,2	14,4	13,0	14,2

Construire le nuage de points de cette série statistique.



- 1) Déterminer la moyenne et la variance de chacune des variables  $X$  et  $Y$ .
- 2) Déterminer le coefficient de corrélation linéaire  $r$  des variables  $X$  et  $Y$ . Un ajustement linéaire entre  $X$  et  $Y$  est-il justifié?
- 3) Déterminer une équation de la droite de régression de  $Y$  en  $X$ .
- 4) Estimer la tension artérielle d'une personne âgée de 45 ans.

**Solutions**

$$\bar{X} = \frac{1}{10} \sum_{i=1}^{10} x_i = \dots\dots\dots$$

$$\bar{Y} = \frac{1}{10} \sum_{i=1}^{10} y_i = \dots\dots\dots$$

$$V(X) = \frac{1}{n} \sum_{i=1}^n x_i^2 - \bar{X}^2 = \frac{1}{10} \sum_{i=1}^{10} x_i^2 - \bar{X}^2 = \dots\dots\dots$$

$$V(Y) = \frac{1}{n} \sum_{i=1}^n y_i^2 - \bar{Y}^2 = \frac{1}{10} \sum_{i=1}^{10} y_i^2 - \bar{Y}^2 = \dots\dots\dots$$

$$\text{Cov}(X, Y) = \frac{1}{10} \sum_{i=1}^{10} x_i y_i - \bar{X} \bar{Y} = \dots\dots\dots$$

$$r = \frac{\text{Cov}(X, Y)}{\sigma(X)\sigma(Y)} = \frac{\dots\dots\dots}{\sqrt{\dots\dots\dots}\sqrt{\dots\dots\dots}} = \dots\dots\dots$$

.....

La droite de régression de  $Y$  en  $X$  admet pour équation:  $y = ax + b$  où

$$a = \frac{\text{Cov}(X, Y)}{V(X)} = \frac{\dots\dots\dots}{\dots\dots\dots} = \dots\dots\dots \quad \text{et} \quad b = \bar{Y} - a\bar{X} = \dots\dots\dots$$

La tension artérielle d'une personne âgée de 45 ans est: .....

## 2. Méthode de Mayer

### Activité3

Une banque a enregistré les nombres de retraits opérés dans un guichet automatique pendant une journée. Le tableau suivant donne les montants (en DT) des retraits et leurs effectifs.

Montant en DT : $x_i$	40	35	30	25	20	15	10	5
Effectifs de retraits: $y_i$	19	20	17	11	13	6	7	2

1) a) Construire, dans un repère orthogonal, le nuage des points représentant cette série statistique.

b) Quelle particularité peut-on remarquer au sujet de la forme du nuage ?

c) Déterminer, les coordonnées du point moyen  $G$  de ce nuage. Placer  $G$ .

2) On partage l'ensemble des points du nuage en deux parties. La première partie  $P_1$  correspond aux retraits inférieurs ou égaux à 25 DT et la deuxième partie  $P_2$  correspond aux autres retraits.

a) Déterminer les coordonnées des points moyens  $G_1$  et  $G_2$  respectifs des parties  $P_1$  et  $P_2$ . Placer  $G_1$  et  $G_2$  dans le même repère.


b) Donner une équation cartésienne de la droite  $(G_1G_2)$ .

c) Vérifier que la droite  $(G_1G_2)$  passe par le point  $G$ .

3) Quel nombre de retraits de 50 DT peut-on prévoir en une journée ?

Solutions -----

1) a)



b) .....

$$\bar{X} = \frac{1}{8} \sum_{i=1}^8 x_i = \dots\dots\dots, \quad \bar{Y} = \frac{1}{8} \sum_{i=1}^8 y_i = \dots\dots\dots \Rightarrow G(\dots\dots\dots, \dots\dots\dots)$$

2) a)  $\bar{X}_1 = \frac{1}{4} \sum_{i=1}^4 x_i = \dots\dots\dots, \quad \bar{Y}_1 = \frac{1}{4} \sum_{i=1}^4 y_i = \dots\dots\dots \Rightarrow G_1(\dots\dots\dots, \dots\dots\dots)$

$$\bar{X}_2 = \frac{1}{4} \sum_{i=5}^8 x_i = \dots\dots\dots, \quad \bar{Y}_2 = \frac{1}{4} \sum_{i=5}^8 y_i = \dots\dots\dots \Rightarrow G_2(\dots\dots\dots, \dots\dots\dots)$$

b).....

c) .....

3) .....

La droite  $(G_1G_2)$  est appelée droite de **Mayer**

On dit qu'on a fait un ajustement linéaire à l'aide de la méthode de Mayer

Cas d'un échantillon groupé (Tableau à double entrée)

Activité4

On donne la série double suivante, relative aux voitures selon leur puissance Y et la durée des pneumatiques X (en milliers de Km).

X \ Y	2	3	4	
20	0	8	30	38
25	5	20	7	32
30	25	3	2	30
	30	31	39	100

1. Calculer le coefficient de corrélation linéaire.
2. Un ajustement par la méthode des moindres carrés est-il justifié?

1. Distribution marginale de X:

X	2	3	4
n <sub>i</sub>	30	31	39

$$\bar{X} = \frac{1}{100} \sum_{i=1}^3 x_i n_i = \frac{60 + 93 + 156}{100} = 3,09$$

$$V(X) = \frac{1}{100} \sum_{i=1}^3 x_i^2 n_i - \bar{X}^2 = 0,6819, \sigma(X) = 0,8258$$

Distribution marginale de Y:

Y	20	25	30
n <sub>j</sub>	38	32	30

$$\bar{Y} = \frac{1}{100} \sum_{j=1}^3 y_j n_j = 24,6$$

$$V(Y) = \frac{1}{100} \sum_{j=1}^3 y_j^2 n_j - \bar{Y}^2 = 622 - (24,6)^2 = 16,84$$

Covariance de (X,Y) et coefficient de corrélation:

X \ Y	2	3	4	
20	0	8	30	2880
25	5	20	7	2450
30	25	3	2	2010
	1750	2250	3340	7340

n <sub>ij</sub>
x <sub>i</sub> y <sub>j</sub> n <sub>ij</sub>

$$\sum_{i=1}^3 \sum_{j=1}^3 x_i y_j n_{ij} = 7340$$

$$\bar{X} \cdot \bar{Y} = 3,09 \times 24,6 = 76,014$$

$$Cov(X, Y) = 73,4 - 76,014 = -2,614$$

Le coefficient de corrélation

$$r = \frac{Cov(X, Y)}{\sqrt{V(X)}\sqrt{V(Y)}} = \frac{-2,614}{0,8258 \times 4,1036} \simeq -0,77$$

.....  
 .....