

**STATISTIQUES**

**I. DISTRIBUTIONS MARGINALES**

Activité 1 p 209

**DEFINITION 1**

Soit  $(X, Y)$  une série statistique double sur un échantillon de taille  $n$  et soit  $(x_i, y_i)_{1 \leq i \leq n}$  les valeurs numériques prises respectivement par les variables  $X$  et  $Y$ .

- \* La distribution marginale de la variable  $X$  est la distribution des valeurs  $(x_i)_{1 \leq i \leq n}$  prises par la variable  $X$
- \* La distribution marginale de la variable  $Y$  est la distribution des valeurs  $(y_i)_{1 \leq i \leq n}$  prises par la variable  $Y$

**DEFINITION 2**

- \* Soit  $X$  une série statistique sur un échantillon de taille  $n$  et soit  $(x_i)_{1 \leq i \leq p}$  les valeurs numériques prises par la variable  $X$  si elle est discrète, ou les centres des classes si la variable  $X$  est continue.
- \* L'entier  $n_i$  désigne l'effectif de la valeur  $x_i$ .
- \* Si  $\bar{X}$ ,  $V(X)$  et  $\sigma_X$  désigne respectivement la moyenne, la variance et l'écart-type de  $X$ , alors :

$$* \bar{X} = \frac{1}{n} \sum_{i=1}^p n_i x_i \quad * V(X) = \frac{1}{n} \sum_{i=1}^p n_i (x_i - \bar{X})^2 \quad * \sigma_X = \sqrt{V(X)}$$

$$* V(X) = \overline{X^2} - (\bar{X})^2 ; \text{ avec } \overline{X^2} = \sum_{i=1}^p n_i (x_i)^2$$

Activité 3 p 211

**II. COVARIANCE D'UNE SERIE STATISTIQUE DOUBLE**

**1. CAS D'UN ECHANTILLON SIMPLE**

**EXERCICE ( BAC. S. 2005)**

Le tableau suivant donne la distance de freinage  $d$  (en mètres) d'une voiture, en fonction de sa vitesse  $v$  (en kilomètres par heure)

$v$ (km/h)	30	40	50	60	70	80
$d$ (mètres)	42	60	80	90	95	110

- \* On note  $\bar{v}$  et  $\bar{d}$  les moyennes respectives de  $v$  et  $d$ .
- \* On note  $V(v)$  et  $V(d)$  les variances respectives de  $v$  et  $d$ .
- \* On note  $cov(v, d)$  la covariance de  $v$  et  $d$ .

Calculer  $\bar{v}$ ,  $\bar{d}$ ,  $V(v)$ ,  $V(d)$  et  $\frac{1}{6} \sum_{k=1}^6 v_k \cdot d_k - \bar{v} \bar{d}$ .

**DEFINITION**

Soit  $(X, Y)$  une série statistique double sur un échantillon de taille  $n$  et soit  $(x_i, y_i)_{1 \leq i \leq p}$  les valeurs numériques prises respectivement par les variables  $X$  et  $Y$  si  $X$  et  $Y$  sont discrètes, ou les centres des classes si la variable  $X$  ou  $Y$  est continue.

- \* On appelle covariance de  $(X, Y)$  le réel, noté  $cov(X, Y)$  défini par :

$$* cov(X, Y) = \frac{1}{n} \sum_{i=1}^p x_i y_i - \bar{X} \cdot \bar{Y} = \overline{X \cdot Y} - \bar{X} \cdot \bar{Y}$$

### INTERPRETATION DE LA COVARIANCE

- \* La covariance mesure la tendance qu'on les variables X et Y de varier ensemble.
- \* La covariance est positive si X et Y ont une tendance à varier dans le même sens.
- \* La covariance est négative si X et Y ont une tendance à varier en sens contraire.

Activité 3 p 213

#### EXERCICE 1 (CONT. M. 95)

Dans le tableau statistique suivant, X désigne la température moyenne extérieure en 24 heures et Y désigne la consommation de pétrole de chauffage pour les mêmes 24 heures et pour une famille donnée.

X en degrés	-2	0	4	8	10
Y en litres	40	30	20	15	10

Calculer  $\bar{X}$ ,  $\bar{Y}$ ,  $V(X)$ ,  $V(Y)$  et  $cov(X,Y)$ . Interpréter le résultat obtenu.

## 2. CAS D'UN ECHANTILLON GROUPE

### DEFINITION

Soit  $(X, Y)$  une série statistique double sur un échantillon de taille n et soit  $(x_i, y_j)_{1 \leq i \leq p \text{ et } 1 \leq j \leq q}$  les valeurs numériques prises respectivement par les variables X et Y si X et Y sont discrètes, ou les centres des classes si la variable X ou Y est continue. Soit  $n_{ij}$  l'effectif qui correspond au couple  $(x_i, y_j)$ .

\* On appelle covariance de  $(X, Y)$  le réel, noté  $cov(X, Y)$  défini par :

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

Exercice résolu p 213

## III. AJUSTEMENT D'UNE SERIE STATISTIQUE DOUBLE

### 1. METHODE DE MAYER

#### ACTIVITE

Le rendement R d'une variété de blé (en quintaux par hectare) et la quantité E d'engrais azotés (en kilogrammes par hectare) utilisée pendant la culture sont indiqués dans le tableau suivant :

E(kg/ha)	30	40	50	60	70	80	90	100
R (q/ha)	28,7	34,4	35,7	41,4	45,7	47,2	50,8	54,7

1. Construire, dans un plan rapporté à un repère orthogonal, le nuage de points représentant la série statistique double donnée. Que peut-on remarquer ?
2. Calculer  $\bar{X}$ ,  $\bar{Y}$ ,  $V(X)$ ,  $V(Y)$ ,  $\sigma(X)$ ,  $\sigma(Y)$ ,  $\overline{XY}$ .
3. Représenter le point moyen  $G(\bar{X}, \bar{Y})$ .
4. On partage le nuage de points en deux ensembles A et B
  - a. Déterminer le point moyen  $G_1$  de la partie A et le point moyen  $G_2$  de la partie B.
  - b. Donner une équation cartésienne de la droite  $(G_1 G_2)$ .
  - c. Vérifier que la droite  $(G_1 G_2)$  passe par le point moyen G du nuage de points.
5. Quel rendement peut-on prévoir pour une culture utilisant une quantité d'engrais azotés  $E = 120\text{kg/ha}$  ?

### DEFINITION

Soit  $(X, Y)$  une série statistique double de valeurs  $(x_i, y_i)_{1 \leq i \leq n}$ .

\* L'ensemble des points  $M_i(x_i, y_i)$  dans un repère orthogonal est appelé nuage de points représentant la série statistique.

\* Le point moyen du nuage est le point  $G(\bar{X}, \bar{Y})$ .

### PRINCIPE DE LA METHODE DE MAYER

Soit un nuage de points représentant une série statistique double  $(X, Y)$  et  $G$  son point moyen.

- \* On scinde le nuage de points de la série  $(X, Y)$  en deux parties contenant à peu près le même nombre de points.
- \* On considère alors les points moyens  $G_1$  et  $G_2$  des deux nages obtenus.
- \* La droite  $(G_1G_2)$  définit un ajustement affine du nuage de points représentant la série statistique double  $(X, Y)$ .
- \* La droite  $(G_1G_2)$  est appelée droite de Mayer et passe par le point moyen  $G$  du nuage.

Activité 2 p 218

## 2. METHODE DES MOINDRES CARRES

### THEOREME

Soit  $(X, Y)$  une série statistique double sur un échantillon de taille  $n$  et telle que  $\sigma_X \neq 0$ .

- \* Soit  $(x_i, y_i)_{1 \leq i \leq n}$  les valeurs observées de la série. Alors la somme  $\sum_{i=1}^n (ax_i + b - y_i)^2$  est minimale

pour le couple  $(a, b)$  tel que  $a = \frac{\text{cov}(X, Y)}{\sigma_X^2}$  et  $b = \bar{Y} - a\bar{X}$ .

### DEFINITION 1

Soit  $(X, Y)$  une série statistique double sur un échantillon de taille  $n$  et telle que  $\sigma_X \neq 0$ .

- \* La droite d'équation  $y = ax + b$  ; avec  $a = \frac{\text{cov}(X, Y)}{\sigma_X^2}$  et  $b = \bar{Y} - a\bar{X}$  ; est appelée droite des moindres carrés de  $Y$  en  $X$ , ou droite de régression de  $Y$  en  $X$ .

### DEFINITION 2

Soit  $(X, Y)$  une série statistique double sur un échantillon de taille  $n$  et telle que  $\sigma_Y \neq 0$ .

- \* La droite d'équation  $x = ay + b$  ; avec  $a = \frac{\text{cov}(X, Y)}{\sigma_Y^2}$  et  $b = \bar{X} - a\bar{Y}$  ; est appelée droite des moindres carrés de  $X$  en  $Y$ , ou droite de régression de  $X$  en  $Y$ .

### CONSEQUENCE

- \* Les droites des moindres carrés de  $Y$  en  $X$  et de  $X$  en  $Y$  passent par le point moyen  $G$  du nuage associé à la série  $(X, Y)$ .

Activité 2 p 220

## 3. COEFFICIENT DE CORRELATION LINEAIRE

### DEFINITION

Soit  $(X, Y)$  une série statistique double.

- \* On appelle coefficient de corrélation linéaire le réel  $\rho_{XY}$  défini par :  $\rho_{XY} = \frac{\text{cov}(X, Y)}{\sigma_X \cdot \sigma_Y}$

### PROPRIETES

Soit  $(X, Y)$  une série statistique double.

- \*  $-1 \leq \rho_{XY} \leq 1$
- \* Le coefficient de corrélation linéaire est invariant par changement d'unité ou d'origine.

INTERPRETATION DU COEFFICIENT DE CORRELATION LINEAIRE

\* On convient que : si  $|r_{XY}| > \frac{\sqrt{3}}{2}$  alors l'ajustement affine est justifié et les prédictions faites au moyen de cet ajustement sont raisonnables.