

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 σ_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} , $V(X)$, $V(Y)$, $\sigma(X)$, $\sigma(Y)$, $\overline{X \cdot Y}$.
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 ρ_{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.