

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 $\sum_{i=1}^n x_i \cdot y_i = 1.5 + 2.6,5 + \dots + 8.13,5 = 375,5$;

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

4. Coefficient de corrélation linéaire

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

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

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

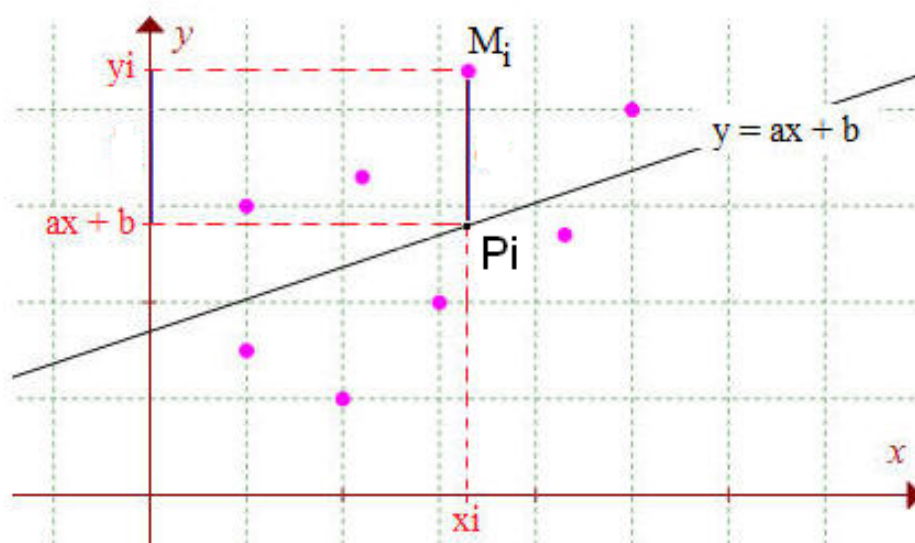
Un ajustement affine entre X et Y consiste à déterminer une droite qui passe le plus près possible des différents nuage points associé à la série (X, Y). Cette droite est alors utilisée pour estimer la valeur de l'une des variables X ou Y connaissant l'autre.

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

Exemple

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

$Cov(X, Y) = 6,44$ $V(X) = 5,25$ 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 : $a' = \frac{Cov(X, Y)}{V(Y)}$

Exemple

Considérons La série statistiques double représenté par le tableau suivant.

xi	69,1	56,6	52,	50	48	45,3	43,3
yi	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 $x = 40$.