

Chapitre 2 : Statistique descriptive à deux variables

- Il arrive souvent que l'étude statistique porte simultanément sur deux caractères X et Y .
- Pour présenter les résultats, on peut utiliser deux modes de représentation :
 - le tableau de contingence
 - la représentation graphique.

1. Tableau de contingence (ou de corrélation) :

Soient :


- les valeurs possibles x_1, x_2, \dots, x_p pour le caractère statistique X (ou les modalités, ou les classes).
- les valeurs possibles y_1, y_2, \dots, y_q pour le caractère statistique Y (ou les modalités, ou les classes).
- l'effectif n_{ij} correspond à chaque observation ($X = x_i, Y = y_j$) avec $\sum_{i=1}^p \sum_{j=1}^q n_{ij} = n$.
- si n désigne l'effectif total, la fréquence correspondante est $f_{ij} = \frac{n_{ij}}{n}$ avec $\sum_{i=1}^p \sum_{j=1}^q f_{ij} = 1$.
- Ces renseignements se présentent souvent avec un tableau à double entrée s'appelant tableau de contingence.

$\begin{matrix} Y \\ X \end{matrix}$	y_1	y_j	y_q
x_1	n_{11}	n_{1j}	n_{1q}
.	.		.		.
.	.		.		.
.	.		.		.
x_i	n_{i1}	n_{ij}	n_{iq}
.	.				.
.	.				.
.	.				.
.	.				.
x_p	n_{p1}	n_{pj}	n_{pq}

2. Nuage de points :

- La représentation graphique n'est valable que si les données sont quantitatives.
- Envisageons l'exemple où les caractères X et Y (quantitatifs) sont la taille (en cm) et le poids (en kg).
- Pour chaque sujet, on a un couple de valeurs (une taille, un poids).
- En portant en abscisse la taille et en ordonnée le poids, on définit chaque sujet par un point sur le diagramme.
- L'ensemble des points constitue le nuage de points.

Nuage de points



3. Distributions marginales :

A partir de la distribution statistique du couple (X, Y) , on peut déduire la distribution statistique concernant le caractère X seul, et celle qui est relative au caractère Y seul :

- $(X = x_i)$ a pour effectif : $n_{i.} = \sum_{j=1}^q n_{ij}$ et pour fréquence : $f_{i.} = \frac{n_{i.}}{n}$.
- $(Y = y_j)$ a pour effectif : $n_{.j} = \sum_{i=1}^p n_{ij}$ et pour fréquence : $f_{.j} = \frac{n_{.j}}{n}$.
- La détermination des effectifs $n_{i.}$ et $n_{.j}$ se fait à partir du tableau de contingence par addition suivant les lignes et les colonnes, et en reportant les résultats en marge du tableau.

Y X	y_1	y_j	y_q	Total
x_1	n_{11}	n_{1j}	n_{1q}	$n_{1.}$
.
.
.
x_i	n_{i1}	n_{ij}	n_{iq}	$n_{i.}$
.
.
.
x_p	n_{p1}	n_{pj}	n_{pq}	$n_{p.}$
Total	$n_{.1}$	$n_{.j}$	$n_{.q}$	n

$$\sum_{i=1}^p n_{i.} = \sum_{j=1}^q n_{.j} = n$$

4. Distributions conditionnelles :

A- Distribution conditionnelle de Y pour $X = x_i$:

C'est la distribution des $n_{i.}$ observations vérifiant la condition $X = x_i$ et réparties selon les valeurs prises par Y .

Pour ceci, il suffit d'extraire du tableau de contingence la ligne correspondante à $X = x_i$.

$Y/X = x_i$	y_1	y_j	y_q	Total
Effectif	n_{i1}	n_{ij}	n_{iq}	n_i

On obtient des fréquences conditionnelles en divisant les effectifs par n_i :

$$f_{j/i} = \frac{n_{ij}}{n_i} \quad \text{avec} \quad \sum_{j=1}^q f_{j/i} = 1.$$

B- Distribution conditionnelle de X pour $Y = y_j$:

De la même manière, c'est la distribution des n_j observations vérifiant la condition $Y = y_j$.

$X/Y = y_j$	x_1	x_i	x_p	Total
Effectif	n_{1j}	n_{ij}	n_{pj}	n_j

En divisant les effectifs par n_j , on obtient les fréquences conditionnelles :

$$f_{i/j} = \frac{n_{ij}}{n_j} \quad \text{avec} \quad \sum_{i=1}^p f_{i/j} = 1.$$

5. Paramètres d'une série statistique double :

A- Moyennes et variances marginales :

$$\bar{x} = \frac{1}{n} \sum_{i=1}^p n_i x_i \quad \text{et} \quad \bar{y} = \frac{1}{n} \sum_{j=1}^q n_j y_j$$

➤ Le point de coordonnées (\bar{x}, \bar{y}) s'appelle le point moyen.

$$➤ S_{echX}^2 = \left(\frac{1}{n} \sum_{i=1}^p n_i x_i^2 \right) - (\bar{x})^2$$

$$➤ S_{echY}^2 = \left(\frac{1}{n} \sum_{j=1}^q n_j y_j^2 \right) - (\bar{y})^2$$

B- Covariance :

- La notion de covariance généralise à deux variables la notion de variance.
- Sa formule est la suivante :

$$\begin{aligned} Cov(X, Y) &= \frac{1}{n} \sum_{i=1}^p \sum_{j=1}^q n_{ij} (x_i - \bar{x})(y_j - \bar{y}) \\ &= \frac{1}{n} \left(\sum_{i=1}^p \sum_{j=1}^q n_{ij} x_i y_j \right) - (\bar{x} \bar{y}). \end{aligned}$$

- Propriétés :

1. $Cov(X, Y) = Cov(Y, X)$.
2. $Cov(X, X) = Var(X) = S_{echX}^2$.
3. $Cov(aX + b, cY + d) = ac Cov(X, Y)$ avec $a, b, c, d \in \mathbb{R}$.
4. $|Cov(X, Y)| \leq S_{echX} \cdot S_{echY}$

C- Coefficient de corrélation :

La covariance n'a pas de signification concrète. Pour cela, on doit passer à un indicateur interprétable qui s'appelle le coefficient de corrélation linéaire :

$$r = \frac{Cov(X, Y)}{S_{echX} \cdot S_{echY}}$$

- Propriétés :

1. r est toujours entre -1 et 1 : $-1 \leq r \leq 1$.
2. Le nuage de points (x_i, y_j) est une droite si, et seulement si $r = 1$ (droite à pente positive) ou $r = -1$ (droite à pente négative).
3. Si $|r| \approx 1$, on dit qu'il existe une forte corrélation linéaire entre X et Y .

D- Coefficient de détermination :

- Le coefficient de détermination linéaire de Pearson, noté R , est une mesure de la qualité de la prédiction d'une régression linéaire.

$$R = r^2$$

- R est toujours entre 0 et 1.
- Plus le coefficient de détermination R se rapproche de 0, plus le nuage de points se disperse autour de la droite de régression. Au contraire, plus le R tend vers 1, plus le nuage de points se resserre autour de la droite de régression.

5. Ajustement : Droite de régression

- On considère un nuage de points (x_i, y_j) .
- L'allure de ce nuage et des considérations sur le phénomène étudié peuvent suggérer une relation fonctionnelle entre X et Y , par exemple:

$$y = ax + b, \quad y = ax^b, \quad y = a \ln(x) + b, \quad \dots$$

- Quand les points du nuage sont à peu près alignés, on retient comme modèle $y = ax + b$ (ajustement affine), ou $y = ax$ (ajustement linéaire) quand la droite passe par l'origine.


❖ Droite de régression de Y par rapport à X : au sens de moindres carrés

- La droite d'équation

$y = ax + b$ qui passe par le point moyen $M(\bar{x}, \bar{y})$ et dont la pente

$a = \frac{\text{Cov}(X,Y)}{S_{echX}^2}$ s'appelle droite de régression de Y par rapport de X .

$$b = \bar{y} - a\bar{x}$$




Exercice : Pour une personne, on a fait varier l'intensité du travail fourni X (en kilojoules par minute) et on a relevé la fréquence cardiaque Y (nombre de battements par minute). On a obtenu les résultats suivants :

x_i	9,6	12,8	18,4	31,2	36,8	47,2	49,6	56,8
y_j	70	86	90	104	120	128	144	154

- Représenter ces données par un nuage de points.
- Calculer le coefficient de corrélation linéaire r .
- Déterminer la droite de régression de Y par rapport à X .
- Estimer la fréquence cardiaque lorsque l'intensité de travail fourni est 30 kilojoules par minute ; puis lorsqu'elle est de 75.

Solution :

a) Nuage de points : On observe que les points expérimentaux sont à peu près alignés, ce qui justifie l'hypothèse d'un modèle d'ajustement affine.



b) Calculs :

Puisque tous les effectifs sont égaux à 1 :

$$\bar{x} = \frac{1}{8} \sum_{i=1}^8 x_i = 32,8 \text{ et } \bar{y} = \frac{1}{8} \sum_{i=1}^8 y_i = 112.$$

x_i^2	92,16	163,84	338,56	973,44	1354,24	2227,84	2460,16	3226,24	Somme= 10836,48
y_i^2	4900	7396	8100	10816	14400	16348	20736	23716	Somme= 106412

$$S_{echX}^2 = \frac{1}{n} \sum_{i=1}^8 x_i^2 - (\bar{x}^2) = \frac{10836,48}{8} - (32,8)^2 = 278,72$$

$$S_{echY}^2 = \frac{1}{n} \sum_{i=1}^8 y_i^2 - (\bar{y}^2) = \frac{106412}{8} - (112)^2 = 757,5$$

$$S_{echX} = 16,695 \text{ et } S_{echY} = 27,523$$

x_i	672	1100,8	1656	3244,8	4416	6041,6	7142,4	8747,2	Somme=33020,8
$\times y_i$									

$$Cov(X, Y) = \frac{1}{n} \sum_{i=1}^8 \sum_{i=1}^8 x_i y_i - (\bar{x}\bar{y}) = \frac{33020,8}{8} - (32,8 \times 112) = 454$$

Donc le coefficient de corrélation

$$r = \frac{Cov(X, Y)}{S_{echX} \cdot S_{echY}} = \frac{454}{16,695 \times 27,523} = 0,988.$$

c) Droite de régression :

$$y = ax + b \text{ avec } a = \frac{Cov(X, Y)}{S_{echX}^2} = \frac{454}{278,72} = 1,629 \text{ et } b = \bar{y} - a\bar{x} = 112 - (1,629 \times 32,8) = 58,569$$

Donc $y = 1,629x + 58,569$.

d) Estimation affine :

Pour estimer la fréquence cardiaque pour une intensité du travail fourni égale à 30, il suffit de remplacer x par 30 dans la droite de régression :

$$y = (1,629 \times 30) + 58,569 = 107,44.$$

La même chose pour $x = 75$:

$$y = (1,629 \times 75) + 58,569 = 180,74.$$