

Les série statistiques doubles

Définition:

- Une série statistique double ou série statistique à deux variables est un ensemble des résultats issus de l'observation de deux caractères numériques sur une même population.

Exemple:

- La taille est le poids d'un groupe d'enfants.
- Le salaire et la qualification d'un ensemble de salariés.
- La température et la pression d'un milieu à différentes heures.

Notation et représentation des séries statistiques doubles:

- La série statistique des couples (x_i, y_j) sera notée (X, Y) .
- Une série statistique double peut être donnée comme l'énumération d'un certain nombre de résultats, on distingue deux cas:
 - 1) Les effectifs des valeurs égaux à 1.
 - 2) Les effectifs des couples (x_i, y_j) égaux à n_{ij} .

Les effectifs des couples (x_i, y_i) égaux 1:

- Dans ce cas , une série statistique double se présente comme suit:

X_1	X_1	X_2	X_N
Y_1	Y_1	Y_2	Y_N

Exemple:

- On prélève un échantillon de 10 nouveau-nés pour lesquels, en plus de leur poids, on regarde leur taille à la naissance:

POIDS	2,1	2,5	2,65	2,8	3,1	3,35	3,65	3,75	4,245	4,4
TAILLE	40	45	43	50	48	51	49	51	53	55

La moyenne, la variance et l'écart type:

- Les variables statistiques X , Y ont chacune , une moyenne , une variance et un écart-type:

$$\bar{X} = \sum_{i=1}^N \frac{x_i}{N} \quad \bar{Y} = \sum_{i=1}^N \frac{y_i}{N}$$

$$V(X) = \sum_{i=1}^N \frac{x_i^2}{N} - \bar{X}^2 \quad V(Y) = \sum_{i=1}^N \frac{y_i^2}{N} - \bar{Y}^2$$

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

Les effectifs des couples (x_i, y_j) égaux n_{ij} :

- Soit X et Y deux séries statistiques définies sur la même population.
- X prenant les valeurs x_1, x_2, \dots, x_r
- Y prenant les valeurs y_1, y_2, \dots, y_p
- $(1 \leq i \leq r)$
- $(1 \leq j \leq p)$

Tableau d'effectifs:

X/Y	Y₁	...	Y_j	...	Y_p	TOTAL N_{i.}
X₁	N₁₁		N_{1j}		N_{1p}	N_{1.}
...						
X_i	N_{i1}		N_{ij}		N_{ip}	N_{i.}
...						
X_R	N_{R1}		N_{Rj}		N_{Rp}	N_{R.}
TOTAL N_{.j}	N_{.1}		N_{.j}		N_{.p}	N

Définition:

- Si n_{ij} est l'effectif partiel d'un couple (x_i, y_j) et
- N l'effectif total.
- le rapport $f_{ij} = \frac{n_{ij}}{N}$ s'appelle la fréquence partiel du couple (x_i, y_j) .

- Remarque:

$$\sum_i \sum_j n_{ij} = N$$

- N est l'effectif total

Remarque:

- La somme des effectifs partiels correspondant à la valeur x_i est égale à l'effectifs des individus pour lesquels X prend la valeur x_i , on représente par le symbole n_i :

$$n_i = n_{i1} + n_{i2} + \dots + n_{ip}$$

Remarque:

- La somme des effectifs partiels correspondant à la valeur y_j est égale à l'effectifs des individus pour lesquels Y prend la valeur y_j , on représente par le symbole $n_{.j}$

$$n_{.j} = n_{1j} + n_{2j} + \dots + n_{rj}$$

Remarque:

- Les nombres $n_{i.}$ et $n_{.j}$ sont appelés les effectifs partiels marginaux, donc:

$$\sum_i n_{i.} = \sum_j n_{.j} = N$$

- De la même manière on définit les fréquences partiels marginaux:
- On appelle fréquence marginale $f_{i.}$ de la valeur x_i de la variable X le rapport: $f_{i.} = \frac{n_{i.}}{N}$

Remarque:

- On appelle fréquence marginale f_j de la valeur y_j de la variable Y le rapport:
- En fait les distributions (x_i, n_i) $\{1 \leq i \leq r\}$ et (y_j, n_j) $\{1 \leq j \leq p\}$ sont les distributions des effectifs des séries X et Y respectivement.

Caractéristiques d'une série a deux variables quantitatives:

- Soit (X,Y) une série statistique double quantitative définie sur une même population.

- La moyenne de X : $\bar{X} = \sum_{i=1}^r \frac{n_i \cdot x_i}{N}$

- La variance de X:

$$V(X) = \sum_{i=1}^r \frac{n_i \cdot x_i^2}{N} - \bar{X}^2$$

- L'écart-type: $\sigma(X) = \sqrt{V(X)}$

Caractéristiques d'une série a deux variables quantitatives:

- La moyenne de Y : $\bar{Y} = \sum_{j=1}^p \frac{n_j y_j}{N}$
- La variance de y:

$$V(Y) = \sum_{j=1}^p \frac{n_j y_j^2}{N} - \bar{Y}^2$$

- L'écart-type de Y:

$$\sigma(Y) = \sqrt{V(Y)}$$

Définition:

- Etant donné un couple (X,Y) de série statistiques quantitative définies sur une même population.
- les moyennes \bar{X}, \bar{Y} s'appellent les moyennes marginales du série (X,Y) .
- Les variances $V(X), V(Y)$ s'appellent les variances marginales du série (X,Y) .

Exemple:

- Soit la série double suivante:

$X \setminus Y$	10	20	30	40	$n_{i.}$	$n_{i.}x_i$	$n_{i.}x_i^2$
2	2	0	1	0	3	6	12
3	3	1	3	0	7	21	63
4	7	4	9	2	22	88	352
5	0	2	1	1	4	20	100
$n_{.j}$	12	7	14	3	36=N	135	527
$n_{.j}y_j$	120	140	420	120	800		
$n_{.j}y_j^2$	1200	2800	12600	4800	21400		

Example:

- On calcul:
$$\bar{X} = \sum_{i=1}^r \frac{n_i x_i}{N} = \frac{137}{36} = 3,75$$


$$\bar{Y} = \sum_{j=1}^p \frac{n_j y_j}{N} = \frac{800}{36} = 22,22$$

$$V(X) = \sum_{i=1}^r \frac{n_i x_i^2}{N} - \bar{X}^2 = \frac{527}{36} - (3,75)^2 = 0,57 \Rightarrow \sigma(X) = 0,76$$

$$V(Y) = \sum_{j=1}^p \frac{n_j y_j^2}{N} - \bar{Y}^2 = \frac{21400}{36} - (22,22)^2 = 100,72 \Rightarrow \sigma(Y) = 10,03$$

L'ajustement, La corrélation :

- **Nuage de point:**
- Dans un repère cartésien, on représente la série statistique à deux variables par les points M_{ij} de coordonnées (x_i, y_j) .
- L'ensemble de ces points s'appelle le nuage de points de la série statistique.
- C'est une représentation des liens qu'il y a entre les x_i et les y_j



Le point moyen:

- Le point moyen du nuage de la série statistique à deux variables est le point M dont les coordonnées sont les moyennes (\bar{X}, \bar{Y}) des X et Y respectivement.

La covariance:

- **Définition:**
- Si (X,Y) désigne un couple des séries statistiques quantitatives définies sur une même population prenant respectivement les valeurs x_1, x_2, \dots, x_r et y_1, y_2, \dots, y_p
- n_{ij} désigne l'effectif partiel du couple (x_i, y_j)
- On appelle covariance du couple (X,Y) et on note $Cov(X,Y)$

$$Cov(X,Y) = \frac{1}{N} \left(\sum_i \sum_j n_{ij} x_i y_j \right) - \bar{X} \bar{Y} = \sigma_{XY}$$

Propriétés:

- $\text{Cov}(X,Y) = \text{Cov}(Y,X)$
- $\text{Cov}(X,X) = V(X)$
- $\text{Cov}(Y,Y) = V(Y)$
- Si X et Y sont indépendantes, alors: $\text{Cov}(X,Y)=0$

L'ajustement:

- Soit (X,Y) une série statistique double, une représentation graphique consiste à placer les points $M_i(x_i, Y_i)$ par rapport à un repère cartésien (OXY) .
- Ajuster un ensemble de points consiste à déterminer une courbe simple " aussi proche que possible de points $M_i(x_i, Y_i)$