

Statistiques

- Chapitre 1: Séries statistiques – Généralités
 - Chapitre 2: Paramètres de position et de dispersion
 - Chapitre 3: Ajustement de séries statistiques
 - Chapitre 4: Indices
 - Chapitre 5: Statistiques à 2 caractères
 - Chapitre 6: Séries chronologiques
-

Chapitre 1 : Séries statistiques – Généralités

1) Définitions

Population : Ensemble d'éléments faisant l'objet d'une étude statistique

- exemples : ensemble des élèves d'un amphi (âge, lieu d'habitation...)
ensemble des pièces produites par une machine (taille/qualité...)
ensemble d'assurés (nombre de voiture, nombre d'accidents...)

Echantillon : Partie de la population

- exemples : groupe A des élèves de l'amphi
pièces fabriquées un jour donné
assurés d'un département donné

Unité statistique : Un élément de la population étudiée dont on veut examiner un ou plusieurs caractères.

Caractère qualitatif : Non mesurable

- exemples : qualité : bon ou mauvais, lieu d'habitation...

Caractère quantitatif : Mesurable à l'aide d'une variable statistique

- exemples : nombre d'individus, longueur d'une pièce fabriquée...

Variable statistique :

Discrètes : Prend des valeurs isolées

- exemple : nombre d'individus

Continues : Prend toutes les valeurs sur un intervalle

- exemple : longueur

Série statistique : Ensemble des valeurs prises par une variable statistique sur l'ensemble de la population ou sur un échantillon

2) Séries statistiques d'un caractère quantitatif discret

Soit un échantillon de taille n (x_1, x_2, \dots, x_p) les valeurs possibles du caractère x .

Série statistique : les valeurs prises par les n membres de l'échantillon.

Effectif total : n

Effectif partiel de x_i : c'est le nombre n_i de fois qu'apparaît la valeur x_i .

$$n_1 + n_2 + n_3 + \dots + n_p = n$$

Fréquence relative de x_i :

$$f_i = \frac{n_i}{n}$$


Remarque : $f_1 + f_2 + f_3 + \dots + f_p = 1$

Etendue de la série : Ecart entre la plus grande et la plus faible des valeurs de x_i .


exemple : On considère 100 familles de 4 enfants.

On va étudier le caractère : nombre de garçon(s)

Série statistique : 3,1,3,2,4,0,1,2,...




Ou avec les fréquences relatives :



ici, la somme de la hauteur des bâtons vaut 1

❖ Polygone des effectifs et des fréquences absolues

On va joindre l'extrémité des bâtons par des segments de droite. Si l'on reprend l'ensemble précédent :



ici, la somme de la hauteur des bâtons vaut 1

❖ Polygone des fréquences relatives

Même chose que le graph précédent sauf que n_i est remplacé par f_i

b) Cas des variables continues

Diagramme en bâtons impossible car il y a trop de valeurs de x_i .

=> histogrammes

Deux cas possibles:

*classes égales : on va partager le domaine des valeurs de x_i en classes = intervalles d'où la représentation :

Exemple avec les nourrissons

2,2	2,5	2,8	3,1	3,4	3,7	4,0	4,3	4,6
----- ----- ----- ----- ----- ----- ----- ----- -----								
Classes:1	2	3	4	5	6	7	8	
Effectif: 5	11	24	40	42	20	13	6	

Remarques:

- Aire d'un rectangle = $l \cdot n_i$
- Aire totale sous l'histogramme :

$$\sum_{i=1}^p l \cdot n_i = l \sum_{i=1}^p n_i = l \cdot n$$

(avec n = effectif total)

✓ classes inégales :

classes	5-6	6-7	7-8	8-10
ni effectifs	12	13	16	6

Il faut corriger l'effectif de la classe 8-10 :

$$6/2=3$$

d'où l'histogramme :

Voir graph A

Il est à remarquer que l'on conserve l'aire totale : $1 \cdot 47 = 47$

❖ Polygone des effectifs et des fréquences :

Ligne brisée joignant les milieux de sommets des rectangles.

Ligne brisée joignant les points (x_i, n_i) avec x_i centre des classes

❖ Polygone des effectifs cumulés :

exemple des nourrissons :

Voir graph B

❖ Polygones des fréquences relatives cumulés

Même chose que les graphes précédents sauf que l'on remplace $\sum n_i$ par $\sum f_i$

Chapitre 2 : Paramètres de position et de dispersion

Objectif : On veut obtenir des paramètres pour condenser l'information contenue dans la série statistique étudiée.

- Paramètres de
 - position : donnent un ordre de grandeur des mesures et l'existence de valeurs centrales autour desquelles se groupent les mesures
 - dispersion : donnent la dispersion des valeurs de la série autour de la valeur centrale.

I. Paramètres de position :

1. Moyenne arithmétique :

Définition :

$$\bar{x} = \frac{x_1 + x_2 + \dots + x_n}{n} = \frac{1}{n} \sum_{i=1}^n x_i$$

- Série à caractère discret :

On va avoir p valeurs x_1, x_2, \dots, x_p et n_i est l'effectif de x_i (fi sera la fréquence relative de x_i)

alors :

$$\bar{x} = \frac{n_1 \cdot x_1 + n_2 \cdot x_2 + \dots + n_p \cdot x_p}{n} = \frac{1}{n} \sum_{i=1}^p n_i \cdot x_i$$

ou encore

$$\bar{x} = \sum_{i=1}^p \frac{n_i}{n} \cdot x_i = \sum_{i=1}^p f_i \cdot x_i$$

Exemple : famille de 4 enfants, x_i =nombre de garçons

x_i	0	1	2	3	4
n_i effectif	7	20	43	25	5
f_i (en %) f relative	7	20	43	25	5

Série statistique étudiée : 100 familles

On veut calculer la moyenne arithmétique

$$\begin{aligned} \bar{x} &= \frac{x_1 + x_2 + \dots + x_n}{n} \\ &= \frac{x_1 + x_2 + \dots + x_{100}}{100} \\ &= \frac{0+2+3+2+4+2+3+\dots (100 \text{ valeurs})}{100} \text{ trop long} \\ &= \frac{n_1 \cdot x_1 + n_2 \cdot x_2 + \dots + n_p \cdot x_p}{100} \\ &= \frac{7 \cdot 0 + 20 \cdot 1 + 43 \cdot 2 + 25 \cdot 3 + 5 \cdot 4}{100} = \frac{1}{100} (20 + 86 + 75 + 20) = \frac{201}{100} = 2,01 \end{aligned}$$

plus rapide!

Remarque : On parle de moyenne arithmétique pondérée par les fréquences relatives f_i par la relation :

$$\bar{x} = \sum_{i=1}^p f_i \cdot x_i$$

- Série à caractère continu :

On a une série statistique avec p classes de centre x_i et d'effectif n_i
alors :

$$\bar{x} = \frac{n_1 \cdot x_1 + n_2 \cdot x_2 + \dots + n_p \cdot x_p}{n}$$

(avec x_i , centre des classes)

ou encore

$$\bar{x} = \frac{1}{n} \sum_{i=1}^p n_i \cdot x_i = \sum_{i=1}^p f_i \cdot x_i$$

Même formule que dans le cas des séries à caractère discret. D'une certaine façon, on rend la variable x_i discrète en considérant que x ne peut prendre comme valeurs que le centre des classes.

Exemple des nourrissons :

classes	1	2	3	4	5	6	7	8
centre	2,35	2,65	2,95	3,25	3,55	3,85	4,15	4,45
effectif n_i	5	11	24	40	42	20	13	6
f_i (en %) $\frac{n_i}{n}$	3,1	6,8	14,9	24,8	26,1	12,4	8,1	3,7

d'où

$$\bar{x} = \sum_{i=1}^8 f_i \cdot x_i = \frac{3,1}{100} \cdot 2,35 + \frac{6,8}{100} \cdot 2,65 + \dots = 3,406 \text{ kg}$$

(avec x_i centre des classes)

Remarque : calcul plus rapide sur l'exemple des nourrissons

On va utiliser la moyenne sur le numéro de la classe

On remarque que :

$$x_i = M + a \cdot z_i$$

(avec z_i numéro de la classe)

Dans cet exemple : $M=2,05 \text{ kg}$; $a=0,3 \text{ kg}$

ou $x_1 = 2,05 + 0,3 \cdot 1 = 2,35 \text{ kg}$

$x_2 = 2,05 + 0,3 \cdot 2 = 2,65 \text{ kg}$

...

alors

$$\bar{x} = \frac{1}{n} \sum_{i=1}^8 n_i \cdot x_i = \frac{1}{n} \sum_{i=1}^8 n_i (M + a \cdot z_i)$$

$$\bar{x} = \frac{1}{n} \sum_{i=1}^8 n_i \cdot M = \frac{1}{n} \sum_{i=1}^8 n_i \cdot a \cdot z_i$$

$$\bar{x} = \frac{M}{n} \sum_{i=1}^8 n_i \cdot \frac{a}{n} \sum_{i=1}^8 n_i \cdot z_i$$

d'où

$$\bar{x} = M + a \bar{z}$$

moyenne arithmétique du numéro des classes

Donc ici,

$$\bar{z} = \frac{5 \cdot 1 + 11 \cdot 2 + 24 \cdot 3 + \dots}{161}$$

2. Médiane :

On va ordonner les valeurs de la série statistique et on va prendre la valeur du milieu (médiane). On va ainsi trouver la médiane notée Me.

- Série à caractère discret :

Exemples : Série 3,3,4,5,7,7,9 (7 valeurs, valeur médiane : 5)

Série 3,3,4,5,6,7,7,9 (8 valeurs, valeur médiane : $\frac{5+6}{2} = 5,5$)

- Série à caractère continu :


On va considérer que la série est déjà ordonnée par classes et la médiane Me va tomber dans une certaine classe [l1 , l2]

Cette classe correspond à la moitié de l'effectif total.



où F1 effectif cumulé en l1
 F2 effectif cumulé en l2
 n effectif total
 $n_0 = F2 - F1 =$ effectif de la classe

On suppose les n_0 valeurs de la classe [l1 , l2] uniformément répartis dans cette classe. Si l'on reprend le diagramme cumulé :



On veut calculer Me = ?

-détermination graphique par rapport au diagramme cumulatif

-on a $tg \alpha = \frac{h}{Me - l1} = \frac{n_0}{l2 - l1}$

Or : $\frac{n}{2} = F1 + h = F1 + \frac{F2 - F1}{l2 - l1} (Me - l1)$

d'où $\frac{n}{2} - F1 = \frac{F2 - F1}{l2 - l1} (Me - l1)$

$\Leftrightarrow Me - l1 = \left(\frac{n}{2} - F1 \right) \frac{l2 - l1}{F2 - F1}$

$\Leftrightarrow Me = l1 + \left(\frac{n}{2} - F1 \right) \frac{l2 - l1}{F2 - F1}$

Exemple des nourissons :

classes	2,2 à 2,5	2,5 à 2,8	2,8 à 3,1	3,1 à 3,4	3,4 à 3,7	3,7 à 4,0	4,0 à 4,3	4,3 à 4,6	TOTAL
ni	5	11	24	40	42	20	13	6	161
Σni	5	16	40	80	122	142	155	161	

Dans quelle classe se trouve la médiane?

Si $n = 161 \Rightarrow n/2 = 80,5$

Donc on a :

$l1 = 3,4 \quad l2 = 3,7 \quad F1 = 80 \quad F2 = 122 \quad n/2 = 80,5$

d'où $Me = 3,4 + (80,5 - 80) \cdot \frac{3,7 - 3,4}{122 - 80}$

$Me = 3,4 + 0,5 \left(\frac{0,3}{42} \right) = 3,403 \text{ kg}$

Remarque : Graphiquement sur le polygone des fréquences relatives cumulées, la médiane correspond à l'abscisse qui a $\frac{1}{2}$ en ordonnée.

3. Quartiles:

La médiane sépare la série en 2 groupes de même effectif
Les quartiles séparent la série en 4 groupes de même effectif

- Cas des séries à caractère discret :

Exemples : 4,5,6,11,13,14,16
 Q1 Q2 Q3

A gauche de Q1 : $\frac{7}{4}=1,75$ termes

On prend 1

A droite de Q1 : on aura aussi un seul terme

Exemples : 4,5,6,7,11,13,14,15,16
 Q1 Q2 Q3

A gauche de Q1 : $\frac{9}{4}$ termes = 2,25 Donc on va prendre 2 termes
Pour Q3 on prend deux termes au dessus.

- Cas des séries à caractère continu :

On peut se servir du polygone des fréquences relatives cumulées.

Pour la médiane on regarde la valeur à 0,5

Pour les quartiles, on va regarder à $\frac{1}{4}$ et $\frac{3}{4}$.

Ou on peut utiliser les formules :

$$Q1 = l1 + \left(\frac{n}{4} - F1\right) \frac{l2-l1}{F2-F1}$$

Ici la classe $[l1 , l2 [$ est celle où se situe le premier quartile.

Pour Q3, on va prendre $\frac{3n}{4}$

Remarque : on peut définir aussi des déciles (10) et des quantiles/centiles (100)

4. Mode ou valeur dominante :

Le mode est la valeur la plus fréquente (effectif le plus important).

- Cas des séries à caractère discret :

Exemple : 2,2,5,7,9,9,9,10,10,11
 valeur dominante ou mode : 9

notation : $M_0=9$

Remarque : on peut avoir plusieurs modes possibles


Exemple : 2,2,5,7,9,9,9,10,10,10,11
 $M_0 = 9$ et 10

- Cas des séries à caractère continu :

On va parler de classe modale ou dominante. Il s'agit de la classe avec l'effectif le plus important.

On veut calculer la valeur du mode.

Si on trace l'histogramme et on représente la classe modale (la classe où se trouve le mode)



Le mode est défini de la façon suivante :

On considère que les deux segments de droite en rouge ont la même pente en valeur absolue.

Si la pente est identique, alors : $\left| \frac{\Delta 1}{Mo - l1} \right| = \left| \frac{\Delta 2}{l2 - Mo} \right|$

On va calculer Mo en fonction de l1 , l2 , Δ1 , Δ2 .

A partir de la relation précédente, on a :

$$\begin{aligned} \Delta 1 (l2 - Mo) &= \Delta 2 (Mo - l1) \\ \Leftrightarrow \Delta 1 . l2 - \Delta 1 . Mo &= \Delta 2 . Mo - \Delta 2 . l1 \\ \Leftrightarrow \Delta 1 . l2 + \Delta 2 . l1 &= Mo (\Delta 1 + \Delta 2) \\ \Leftrightarrow Mo &= \frac{\Delta 1 . l2 + \Delta 2 . l1}{\Delta 1 + \Delta 2} \end{aligned}$$

d'où $Mo = l1 + \frac{\Delta 1}{\Delta 1 + \Delta 2} (l2 - l1)$

avec [l1 , l2 [classe modale et dominante

Δ1 = excédent d'effectif de la classe modale par rapport à la classe inférieure

Δ2 = excédent d'effectif de la classe modale par rapport à la classe supérieure

Exemple des nourrissons :

classe modale : [3,4 - 3,7 [, n5=42

$$\Delta 1 = 42 - 40 = 2$$

$$\Delta 2 = 42 - 20 = 22$$

$$\text{d'où } Mo = 3,4 + \frac{2}{2+22} (3,7 - 3,4)$$


$$Mo = 3,4 + \frac{2}{24} (0,3)$$

$$Mo = 3,425$$

Remarques :


- Séries unimodales :

Histogramme :



Une seule classe dominante
donc série unimodale!

- Séries plurimodales :



▪ Si série symétrique :
On peut montrer que

$$\bar{x} = Me = Mo$$