

STATISTIQUES DESCRIPTIVES

Table des matières

I	Définitions et vocabulaire des statistiques	1
II	Caractéristiques de position	2
II.1	Moyenne	2
II.2	Médiane	3
II.3	Quartiles	4
III	Caractéristiques de dispersion	4



I Définitions et vocabulaire des statistiques

La **population** est l'ensemble des individus sur lesquels portent l'étude statistique. (Par exemple classe de seconde ISI, hommes, habitants de la France ...)

Le **caractère** (ou **variable**) d'une série statistique est une propriété étudiée sur chaque individu :

- ⇨ Lorsque le caractère ne prend que des valeurs (ou **modalités**) numériques, il est **quantitatif** :
 - **discret** s'il ne peut prendre que des valeurs isolées (**notes, âge ...**)
 - **continu** dans le cas contraire (**poids, taille ...**). Dans ce cas on effectue souvent un regroupement des valeurs par **classes**.
- ⇨ Sinon, on dit qu'il est **qualitatif** (**couleur des yeux, sport pratiqué ...**) : les modalités ne sont pas des nombres.

A chaque valeur (ou classe) est associée un **effectif** n : c'est le nombre d'individus associés à cette valeur.

Faire des **statistiques**, c'est recueillir, organiser, synthétiser, représenter et exploiter des données, numériques ou non, dans un but de comparaison, de prévision, de constat...

Les plus gros "consommateurs" de statistiques sont les **assureurs** (risques d'accidents, de maladie des assurés), les **médecins** (épidémiologie), les **démographes** (populations et leur dynamique), les **économistes** (emploi, conjoncture économique), les **météorologues** ...

Définition 1

On considère une série statistique à caractère quantitatif, dont les p valeurs sont données par : x_1, x_2, \dots, x_p d'effectifs associés n_1, n_2, \dots, n_p avec $n_1 + n_2 + \dots + n_p = N$.

- A chaque valeur (ou classe) est associée une fréquence f_i : c'est la proportion d'individus associés à cette valeur.
- $f_i = \frac{n_i}{N}$ est un nombre compris entre 0 et 1, que l'on peut écrire sous forme de pourcentage.
- L'ensemble des fréquences de toutes les valeurs du caractère s'appelle la distribution des fréquences de la série statistique.

Exemple 1

Voici les notes obtenues à un contrôle dans une classe de 30 élèves : (**Série A**)

2-3-3-4-5-6-6-7-7-7-8-8-8-8-8-9-9-9-9-9-10-10-11-11-11-13-13-15-16

On peut représenter cette série par un tableau d'effectifs, et le compléter par la distribution des fréquences :

Notes	1	2	3	4	5	6	7	8	9	10	11	12	13	14	15	16	17	18	19
Eff.	0	1	2	1	1	2	3	5	6	2	3	0	2	0	1	1	0	0	0
Fréq. en %	0	3	7	3	3	7	10	17	20	7	10	0	7	0	3	3	0	0	0

Remarque 1

On peut vérifier que la somme des fréquences est égale à 1 (ou à 100 si on les exprime en pourcentages).

On peut aussi faire un regroupement par classe, ce qui rend l'étude moins précise, mais qui permet d'avoir une vision plus globale.

Exemple 2

Toujours pour la **série A**, si on regroupe les données par classes d'amplitude 5 points, on obtient :

Notes	[0 ; 5 [[5 ; 10 [[10 ; 15 [[15 ; 20 [total
Effectif	4	17	7	2	30
Fréquence	0,13	0,57	0,23	0,07	1

II Caractéristiques de position**II.1 Moyenne****Définition 2**

Soit une série statistique à caractère quantitatif, dont les p valeurs sont données par x_1, x_2, \dots, x_p d'effectifs associés n_1, n_2, \dots, n_p avec $n_1 + n_2 + \dots + n_p = N$.

La moyenne pondérée de cette série est le nombre noté \bar{x} qui vaut

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

Remarque 2

Lorsque la série est regroupée en classes, on calcule la moyenne en prenant pour valeurs x_i le **centre de chaque classe** ; ce centre est obtenu en faisant la moyenne des deux extrémités de la classe.

Exemple 3

→ Dans la **série A**, la moyenne du contrôle est égale à $\bar{m} = \frac{2 \times 1 + 3 \times 2 + \dots + 16 \times 1}{30} = \frac{254}{30} \approx 8,47$,

→ si on regroupe par classe d'amplitude 5 points, une estimation de la moyenne est :

$$\frac{\bar{m}}{30} = \frac{2,5 \times 4 + 7,5 \times 17 + \dots + 17,5 \times 2}{30} = \frac{260}{30} \approx 8,67.$$

Remarque 3

On peut aussi calculer une moyenne à partir de la distribution de fréquences :

$$\bar{x} = f_1x_1 + f_2x_2 + \cdots + f_px_p = \sum_{i=1}^p f_ix_i.$$

Propriété 1 (Linéarité de la moyenne)

- ◆ Si on ajoute (ou soustrait) un même nombre k à toutes les valeurs d'une série, alors la moyenne de cette série se trouve augmentée (resp. diminuée) de k .
- ◆ Si on multiplie (ou divise) par un même nombre non nul k toutes les valeurs d'une série, alors la moyenne de cette série se trouve multipliée (resp. divisée) par k .

Exemple 4

On considère la **série A** :

- Si on ajoute 1,5 points à chaque note du contrôle, alors la moyenne de classe devient $\bar{m} = 8,47 + 1,5 = 9,97$.
- Si on augmente chaque note de 10%, cela revient à multiplier chaque note par 1,1, ce qui donne $\bar{m} = 8,47 \times 1,1 = 9,32$.

Propriété 2 (Moyenne par sous-groupes)

Soit une série statistique, d'effectif total N , de moyenne \bar{x} .

Si on divise cette série en deux sous-groupes **disjoints** d'effectifs respectifs p et q (avec $p + q = N$) de moyennes respectives \bar{x}_1 et \bar{x}_2 , alors on a :

$$\bar{x} = \frac{p}{N} \times \bar{x}_1 + \frac{q}{N} \times \bar{x}_2.$$

Exemple 5

On suppose par exemple que les 12 garçons de la classe de la **série A** ont obtenu une moyenne globale de 8 sur 20.

- La moyenne du groupe formé par les filles de la classe vérifie : $9,47 = \frac{12}{30} \times 8 + \frac{18}{30} \times \bar{m}_f$.
- Soit $\bar{m}_f = \frac{30}{18} \left(9,47 - \frac{12}{30} \times 8 \right) = 10,45$.

II.2 Médiane**Définition 3**

Soit une série statistique ordonnée dont les n valeurs sont $x_1 \leq x_2 \leq x_3 \leq \cdots \leq x_n$.

La médiane est un nombre M qui permet de diviser cette série en deux sous-groupes de même effectif.

- Si n est impair, n est la valeur de cette série qui est située au milieu, à savoir la valeur dont le rang est $\frac{n+1}{2}$, notée $x_{\frac{n+1}{2}}$.
- Si n est pair, n est le centre l'intervalle médian, qui est l'intervalle formé par les deux nombres situés « au milieu » de la série, à savoir $x_{\frac{n}{2}}$ et $x_{\frac{n}{2}+1}$.

Exemple 6

- La médiane de la série « 2 – 5 – 6 – 8 – 9 – 9 – 10 » est 8.
- La médiane de la série « 2 – 5 – 6 – 8 – 9 – 9 » est 7.
- La médiane de la série « 2 – 5 – 6 – 6 – 9 – 10 » est 6.

II.3 Quartiles**Définition 4**

Soit une série statistique, on appelle quartiles de la série un triplet de réels $(Q_1 ; Q_2 ; Q_3)$ qui sépare la série en quatre groupes de même effectif.

Remarque 4

Par définition, si X est une série statistique, $Q_2 = Med(X)$.

La calculatrice donne les valeurs de Q_1 , Med et Q_3 .

Nous verrons dans un prochain chapitre d'autres façons de trouver la médiane et les quartiles.

Exemple 7

Pour la **série A**, la calculatrice nous donne $Q_1 = 7$, $Med = 8,5$ et $Q_3 = 10$.

III Caractéristiques de dispersion**Définition 5**

On appelle étendue d'une série discrète X le réel défini par $E(X) = \max(X) - \min(X)$.

Il s'agit de la première mesure de la dispersion d'une série statistique. Son principal mérite a longtemps été d'exister, et de fournir une information sur la dispersion très simple à obtenir.

Exemple 8

L'étendue de la **série A** est de $E(A) = 16 - 2 = 14$.

Définition 6

On appelle intervalle inter-quartiles l'intervalle $[Q_1 ; Q_3]$.
L'amplitude de cet intervalle est appelée écart inter-quartiles.

Exemple 9

- Dans la **série A**, l'intervalle inter-quartile est l'intervalle $[7 ; 10]$ dont l'écart vaut $10 - 7 = 3$.
- Cet intervalle comprend donc la moitié des notes de la série située au centre de celle-ci.