

# Chapitre 4 – Statistiques

## I – Un symbole pour écrire une somme

En statistiques, on calcule souvent des sommes.

Pour ceci, on utilise un symbole afin d'écrire une somme en évitant les pointillés : par exemple, comment noter simplement  $1+2+3+4+\dots+20$  ?

Cette somme comporte 20 termes, on peut noter cette somme ainsi, avec un symbole *sigma* ( $\Sigma$ ) :

$$\sum_{i=1}^{20} i = 1+2+3+\dots+20. \text{ Cela se lit « somme pour } i \text{ allant de 1 à 20 des } i \text{ ».}$$

$$\text{De la même manière, on a : } 1^2+2^2+3^2+\dots+100^2 = \sum_{i=1}^{100} i^2.$$

$$\text{Cette écriture est bien appropriée pour des indices : } a_3+a_4+a_5+\dots+a_{71} = \sum_{i=3}^{71} a_i.$$

## II – Indicateurs statistiques

On s'intéresse à un caractère prenant différentes valeurs. On suppose que le caractère prend  $p$  valeurs différentes. Les différentes valeurs du caractère sont  $x_1, x_2, \dots, x_p$  d'effectifs respectifs  $n_1, n_2, \dots, n_p$ .  $n_i$  est donc l'effectif de la valeur  $x_i$ .

On peut donc résumer la série par un tableau statistique :

Valeur du caractère	$x_1$	$x_2$	...	$x_p$
Effectif	$n_1$	$n_2$	...	$n_p$

$$\text{Effectif total : } N = n_1 + n_2 + \dots + n_p = \sum_{i=1}^p n_i \quad \text{Fréquence de la valeur } x_i : f_i = \frac{n_i}{N}$$

Exemple : Pour toute cette partie, on considère les âges d'un groupe de personnes.

Âge (ans)	0	1	2	3	4	5	6	7	8	9	10
Effectif	1	2	1	3	5	6	7	4	1	2	2
Effectif Cumulé Croissant	1	3	4	7	12	18	25	29	30	32	34

L'effectif total est  $N = 1+2+1+3+5+6+7+4+1+2+2 = 34$  (c'est le dernier effectif cumulé croissant).

### a) Indicateurs de tendance centrale

**Mode :** C'est la valeur la plus fréquente.

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

$$\text{Théorème : On a aussi } \bar{x} = f_1 x_1 + f_2 x_2 + \dots + f_p x_p = \sum_{i=1}^p f_i x_i$$

$$\text{Preuve : } \bar{x} = \frac{\sum_{i=1}^p n_i x_i}{N} = \sum_{i=1}^p \frac{n_i}{N} x_i \text{ or } f_i = \frac{n_i}{N} \text{ donc } \bar{x} = \sum_{i=1}^p f_i x_i$$

**Médiane :** On suppose que les valeurs de la série d'effectif  $N$  sont rangées par ordre croissant (chacune d'elles étant répétée autant de fois que son effectif) :  $x_1 \leq x_2 \leq \dots \leq x_N$ .

- Si  $N$  est impair,  $Me = x_{\frac{N+1}{2}}$  (c'est le terme de rang  $\frac{N+1}{2}$ ).
- Si  $N$  est pair,  $Me = \frac{x_{\frac{N}{2}} + x_{\frac{N}{2}+1}}{2}$  (c'est la moyenne des termes de rang  $\frac{N}{2}$  et  $\frac{N}{2} + 1$ ).

Exemple : Avec l'exemple précédent,

- Le **mode** est 6 ans (car 7 personnes ont 6 ans).
- La **moyenne** est
$$\bar{x} = \frac{0 \times 1 + 1 \times 2 + 2 \times 1 + 3 \times 3 + 4 \times 5 + 5 \times 6 + 6 \times 7 + 7 \times 4 + 8 \times 1 + 9 \times 2 + 10 \times 2}{34} \approx 5,26 \text{ ans.}$$
- La **médiane** est la valeur qui sépare la série statistique en deux parties de même effectif. Ici, il y a 34 valeurs, donc la médiane est la moyenne de la 17<sup>ème</sup> et la 18<sup>ème</sup> valeur. Grâce aux effectifs cumulés croissant, la 17<sup>ème</sup> valeur est 5 ans, la 18<sup>ème</sup> valeur est 5 ans. La médiane est  $Me = \frac{5+5}{2} = 5 \text{ ans.}$

### b) Indicateurs de position : Les quartiles

Les valeurs de la série d'effectif  $N$  sont rangées par ordre croissant (chacune d'elles étant répétée autant de fois que son effectif) :  $x_1 \leq x_2 \leq \dots \leq x_N$ .

**Premier quartile :** Le premier quartile  $Q_1$  de la série est la valeur  $x_i$  dont l'indice  $i$  est le plus petit entier supérieur ou égal à  $\frac{N}{4}$ .

**Troisième quartile :** Le troisième quartile  $Q_3$  de la série est la valeur  $x_i$  dont l'indice  $i$  est le plus petit entier supérieur ou égal à  $\frac{3N}{4}$ .

Remarque : On prend souvent comme deuxième quartile la médiane.

Exemple : Avec l'exemple précédent,


- $\frac{N}{4} = \frac{34}{4} = 8,5$ , donc  $Q_1$  est la 9<sup>ème</sup> valeur :  $Q_1 = 4$  ans.
- $\frac{3N}{4} = \frac{3 \times 34}{4} = 25,5$ , donc  $Q_3$  est la 26<sup>ème</sup> valeur :  $Q_3 = 7$  ans.

### c) Boîtes-à-moustaches

**Pour résumer notre série statistique, on construit un diagramme en boîte.**

- Les valeurs du caractère sont résumées sur un axe.
- On construit un rectangle (la boîte), parallèlement à l'axe, dont la longueur est l'intervalle interquartile  $[Q_1; Q_3]$ .
- Un trait symbolise la médiane  $Me$ .
- On place les moustaches au niveau des valeurs extrêmes.

Exemple : Avec l'exemple précédent, on a cette boîte-à-moustaches pour les âges du groupe de personnes :



### d) Indicateurs de dispersion

**Variance :** 
$$V = \frac{n_1(x_1 - \bar{x})^2 + n_2(x_2 - \bar{x})^2 + \dots + n_p(x_p - \bar{x})^2}{N} = \frac{\sum_{i=1}^p n_i(x_i - \bar{x})^2}{N}$$

**Théorème admis :** On a aussi 
$$V = \frac{n_1 x_1^2 + n_2 x_2^2 + \dots + n_p x_p^2}{N} - \bar{x}^2 = \frac{\sum_{i=1}^p n_i x_i^2}{N} - \bar{x}^2$$

**Écart-type :**  $\sigma = \sqrt{V}$

**Écart interquartile :**  $E_i = Q_3 - Q_1$

**Étendue :** C'est la différence entre les valeurs extrêmes de la série : la plus grande moins la plus petite.

Exemple : Avec l'exemple précédent, comme  $\bar{x} \approx 5,26$  on a :

- $$V = \frac{1(0-\bar{x})^2 + 2(1-\bar{x})^2 + 1(2-\bar{x})^2 + 3(3-\bar{x})^2 + \dots + 1(8-\bar{x})^2 + 2(9-\bar{x})^2 + 2(10-\bar{x})^2}{34} \approx 5,72 .$$

On a également 
$$V = \frac{1 \times 0^2 + 2 \times 1^2 + 1 \times 2^2 + 3 \times 3^2 + \dots + 1 \times 8^2 + 2 \times 9^2 + 2 \times 10^2}{34} - \bar{x}^2 \approx 5,72 .$$

- $\sigma = \sqrt{V} \approx 2,39$  ans.
- $E_i = Q_3 - Q_1 = 7 - 4 = 3$  ans.
- Étendue :  $10 - 0 = 10$  ans.

### **e) Résumer une série statistique**

Résumer une série statistique, c'est indiquer la répartition des données en utilisant différents indicateurs, notamment un indicateur de tendance centrale et un indicateur de dispersion.

Paramètre de tendance centrale	Paramètre de dispersion	Propriété
Médiane : $Me$	Écart interquartile : $E_i$	Peu sensible aux valeurs extrêmes
Moyenne : $\bar{x}$	Écart-type : $\sigma$	Sensible aux valeurs extrêmes