

## 1. Moyenne et écart-type

### Compléments sur la moyenne

#### 1.1. Moyenne pondérée

##### Exemple avec des notes :

Dans le tableau suivant sont regroupées les notes obtenues par les élèves d'une seconde lors d'un contrôle

4	5	6	6	6	8	8	9	10	11	11	11	12	12	12	12	13
13	14	14	16	16	16	16	16	16	16	17	17	17	17	19	19	19

La série statistique est l'ensemble des notes collectées. La population est l'ensemble des élèves de seconde .

L'effectif total est le nombre d'élèves de la classe, à savoir 34. Les valeurs extrêmes sont 4 et 19.

Pour une meilleure lisibilité et pour simplifier l'étude, on peut commencer par compter le nombre d'individus ayant obtenu chaque note :

<b>Note</b>	4	5	6	8	9	10	11	12	13	14	16	17	19
<b>Effectif</b>	1	1	3	2	1	1	3	4	2	2	7	4	3
<b>Fréquence à <math>10^{-2}</math> près</b>	0,03	0,03	0,09	0,06	0,03	0,03	0,09	0,12	0,06	0,06	0,21	0,12	0,09

On considère une série statistique donnée par le tableau suivant :

<b>Valeur</b>	$x_1$	$x_2$	$x_3$	...	$x_{p-1}$	$x_p$
<b>Effectif</b>	$n_1$	$n_2$	$n_3$	...	$n_{p-1}$	$n_p$
<b>Fréquence</b>	$f_1$	$f_2$	$f_3$	...	$f_{p-1}$	$f_p$

**Définition** La **moyenne** de cette série statistique est le réel noté  $\bar{x}$  défini par

$$\bar{x} = \frac{n_1x_1 + n_2x_2 + \dots + n_px_p}{n_1 + n_2 + \dots + n_p} = \frac{n_1x_1 + n_2x_2 + \dots + n_px_p}{N}$$

en notant  $N = n_1 + n_2 + \dots + n_p$  l'effectif total de la série.

**Propriété** On peut également calculer la moyenne à l'aide des fréquences :

$$\bar{x} = x_1f_1 + x_2f_2 + \dots + x_pf_p.$$

##### Exemple avec les notes

Avec les données de l'exemple , la moyenne de la classe est :

$$\bar{x} = \frac{1 \times 4 + 1 \times 5 + 3 \times 6 + 2 \times 8 + 1 \times 9 + 1 \times 10 + 3 \times 11 + 4 \times 12 + 2 \times 13 + 2 \times 14 + 7 \times 16 + 4 \times 17 + 3 \times 19}{34} = \frac{434}{34}$$

$$\bar{x} = \frac{1}{34} \times 4 + \frac{1}{34} \times 5 + \frac{3}{34} \times 6 + \frac{2}{34} \times 8 + \frac{1}{34} \times 9 + \frac{1}{34} \times 10 + \frac{3}{34} \times 11 + \frac{4}{34} \times 12 + \frac{2}{34} \times 13 + \frac{2}{34} \times 14 + \frac{7}{34} \times 16 + \frac{4}{34} \times 17 + \frac{3}{34} \times 19$$

Une valeur approchée de  $\bar{x}$  à  $10^{-2}$  près est 12,76.

#### 1.2. Linéarité de la moyenne

##### Exemple avec des notes :

Multiplier les notes de chaque élève par 1,5, que devient la moyenne de la classe ?

Ajouter 2 points à la moyenne de chaque élève, que devient la moyenne de la classe ?

**Propriété** Soit  $S$  une série statistique de données  $x_i$  de moyenne  $\bar{x}$ . Pour tout réel  $m$  et  $p$ , la nouvelle série  $y_i = mx_i + p$  (obtenue en multipliant chaque valeur par  $m$  et en ajoutant  $p$  à chacune des valeurs) a pour moyenne  $\bar{y} = m\bar{x} + p$ .

*Démonstration page 315.*

### 1.3. Ecart-type

On considère une série statistique  $S$ , de moyenne  $\bar{x}$ , donnée par le tableau suivant :

Valeur	$x_1$	$x_2$	$x_3$	$\dots$	$x_{p-1}$	$x_p$
Effectif	$n_1$	$n_2$	$n_3$	$\dots$	$n_{p-1}$	$n_p$
Fréquence	$f_1$	$f_2$	$f_3$	$\dots$	$f_{p-1}$	$f_p$

#### Définition

- La **variance**, notée  $V$ , est la moyenne des carrés des écarts des valeurs avec la moyenne soit :

$$V = \frac{\sum_{i=1}^p n_i (x_i - \bar{x})^2}{\sum_{i=1}^p n_i} = \frac{n_1(x_1 - \bar{x})^2 + \dots + n_p(x_p - \bar{x})^2}{n_1 + \dots + n_p} = f_1(x_1 - \bar{x})^2 + \dots + f_p(x_p - \bar{x})^2$$

- L'**écart-type** de  $S$ , noté  $\sigma$  est la racine carrée de la variance :  $\sigma = \sqrt{V}$ . ( de même unité que les  $x_i$ .)

#### Exemple avec les notes

La variance vaut :

$$V = \frac{1 \times \left(4 - \frac{434}{34}\right)^2 + 1 \times \left(5 - \frac{434}{34}\right)^2 + 3 \times \left(6 - \frac{434}{34}\right)^2 + 2 \times \left(8 - \frac{434}{34}\right)^2 + 1 \times \left(9 - \frac{434}{34}\right)^2 + 1 \times \left(10 - \frac{434}{34}\right)^2}{34} + \frac{3 \times \left(11 - \frac{434}{34}\right)^2 + 4 \times \left(12 - \frac{434}{34}\right)^2 + 2 \times \left(13 - \frac{434}{34}\right)^2 + 2 \times \left(14 - \frac{434}{34}\right)^2 + 7 \times \left(16 - \frac{434}{34}\right)^2 + 4 \times \left(17 - \frac{434}{34}\right)^2}{34} + \frac{3 \times \left(19 - \frac{434}{34}\right)^2}{34} = \frac{5254}{289} \approx 18,18.$$

L'écart-type vaut :

$$\sigma = \sqrt{\frac{5254}{289}} \approx 4,26$$

**Propriété** L'écart-type mesure un écart moyen à la moyenne d'une série : pour deux séries de même moyenne, celle dont l'écart-type est le plus faible a ses données plus homogènes.

**Remarque** Le couple  $(\bar{x}, \sigma)$  permet de résumer la série. Il utilise toutes les valeurs de la série et est donc sensible aux valeurs extrêmes.

## 2. Médiane et écart interquartile

### 2.1. Médiane

**Rappel : Définition** La **médiane**  $M$  d'une série statistique est un réel qui partage cette série en deux parties telles que :

- Au moins 50 % des valeurs sont inférieures ou égales à la médiane ;
- Au moins 50 % des valeurs sont supérieures ou égales à la médiane.

**Propriété** En pratique, on adopte la démarche suivante pour déterminer la médiane  $M$  d'une série statistiques d'effectif total  $N$  :

- On range d'abord les  $N$  valeurs du caractère par ordre croissant.
- Si  $N$  est pair,  $N = 2k$ ,  $M$  est la moyenne des deux valeurs « centrales » de la série, c'est-à-dire  $M = \frac{x_k + x_{k+1}}{2}$ .
- Si  $N$  est impair,  $N = 2k + 1$ ,  $M$  est la valeur centrale de la série, c'est-à-dire  $x_{k+1}$ .

## Exemple

Note	4	5	6	8	9	10	11	12	13	14	16	17	19
Effectif	1	1	3	2	1	1	3	4	2	2	7	4	3
Effectifs Cumulés Croissants	1	2	5	7	8	9	12	16	18	20	27	31	34

Dans l'exemple, l'effectif total est 34, c'est-à-dire pair.  $34 = 2 \times 17$ .

La médiane est donc la moyenne des deux valeurs centrales de la série, à savoir les 17<sup>e</sup> et 18<sup>e</sup> valeurs. Donc  $M = \frac{13 + 13}{2} = 13$ , ce qui signifie qu'au moins la moitié des notes est inférieure ou égale à 13, et qu'au moins la moitié des notes est supérieure ou égale à 13.

**Définition** On considère une série statistique.

- Le premier **quartile**  $Q_1$  est la plus petite valeur de la série telle qu'au moins 25 % des données soient inférieures ou égales à  $Q_1$ .
- Le troisième **quartile**  $Q_3$  est la plus petite valeur de la série telle qu'au moins 75 % des données soient inférieures ou égales à  $Q_3$ .

## Exemple

On considère toujours les données de l'exemple des notes.

- $34 \times \frac{25}{100} = 8,5$  donc le premier quartile  $Q_1$  de la série est la 9<sup>e</sup> valeur, d'où  $Q_1 = 10$ , ce qui signifie qu'au moins un quart des notes sont inférieures ou égales à 10 (en réalité 9 notes, soit environ 26 %).
- $34 \times \frac{75}{100} = 25,5$  donc le troisième quartile  $Q_3$  de la série est la 26<sup>e</sup> valeur, d'où  $Q_3 = 16$ , ce qui signifie qu'au moins trois quarts des notes sont inférieures ou égales à 16 (en réalité 27 notes, soit environ 79 %).

## Remarque

Le fait que le partage théorique en 25 %, 50 % et 75 % de la série statistique à l'aide des indicateurs  $Q_1$ ,  $M$  et  $Q_3$  ne soit pas tout à fait exact provient du fait que la série comporte des valeurs identiques. Ce phénomène a tendance à s'amoinrir lors d'une étude sur une population plus importante avec un caractère dont les modalités sont plus disparates.

## 2.11 Écart interquartile

**Définition** On considère une série statistique de premier quartile  $Q_1$  et de troisième quartile  $Q_3$ .



- On appelle **intervalle interquartile** l'intervalle  $[Q_1 ; Q_3]$ .
- On appelle **écart interquartile** la différence  $Q_3 - Q_1$ .

## Exemple

Dans l'exemple, l'intervalle interquartile est  $[10 ; 16]$  et l'écart interquartile est  $Q_3 - Q_1 = 16 - 10 = 6$ .

On peut représenter graphiquement les valeurs extrêmes, les quartiles et la médiane par un diagramme en boîte, appelé aussi boîte à moustaches, conçue de la manière suivante :

- au centre une boîte allant du premier au troisième quartile, séparée en deux par la médiane ;
- de chaque côté une moustache allant du minimum au premier quartile pour l'une, et du troisième quartile au maximum pour l'autre.



Les diagrammes en boîte permettent une interprétation visuelle et rapide de la dispersion des séries statistiques. Ils permettent également d'apprécier des différences entre des séries (lorsqu'elles ont des ordres de grandeurs comparables).