

**I. SERIES STATISTIQUES**

Réaliser une étude statistique consiste à classer les **individus** d'une **population** en fonction d'un **caractère** (ou **variable**).

**Exemples :**

- Classer les **élèves** d'une **classe** en fonction de leur **âge**.
- Classer les **voitures** garées sur un **parking** en fonction de leur **couleur**.
- Classer les **joueurs** d'une **équipe de foot** en fonction de leur **poste**.
- Classer des **forfaits** d'un **opérateur téléphonique** en fonction de leur **prix**.

Le caractère étudié peut être **qualitatif** (couleur, poste des joueurs de foot...) ou **quantitatif** (âge, prix...). En regroupant les valeurs du caractère sur toute une population, on obtient une **série statistique**.

Que l'on peut représenter sous forme d'une **liste** ou d'un **tableau**.

**Exemple :** Dans une équipe de football, on demande aux joueurs leur poste sur le terrain et on obtient les résultats suivants (Défenseur, Gardien, Milieu, Avant) :

→ sous forme de liste : D ; A ; G ; D ; A ; M ; M ; D ; M ; A ; D

→ sous forme de tableau :

Poste (caractère)	G	D	M	A	TOTAL
Effectif	<b>1</b>	<b>4</b>	<b>3</b>	<b>3</b>	<b>11</b>
Fréquence (%)	<b>0,091</b> (9,1 %)	<b>0,364</b> (36,4 %)	<b>0,273</b> (27,3 %)	<b>0,273</b> (27,3 %)	<b>1</b> (100 %)

Pour chaque valeur du caractère, on peut indiquer l'**effectif** (le nombre d'individus) ou la **fréquence** (la proportion d'individu par rapport à la totalité de la population).

Cette fréquence peut s'exprimer sous la forme :

- d'un nombre décimal entre 0 et 1 (Exemple : 0,057)
- d'un pourcentage (Exemple : 5,7 %)
- d'une fraction (Exemple :  $\frac{2}{35}$ )

**En règle générale :**

Valeur du caractère	$x_1$	$x_2$	...	$x_p$	TOTAL
Effectif	$n_1$	$n_2$	...	$n_p$	$\sum_{i=1}^p n_i = N$
Effectif cumulé croissant	$n_1$	$n_1 + n_2$	...	$n_1 + n_2 + \dots + n_p$	<del> </del>
Effectif cumulé décroissant	$n_1 + n_2 + \dots + n_p$	$n_2 + \dots + n_p$	...	$n_p$	<del> </del>
Fréquence	$f_1 = \frac{n_1}{N}$	$f_2 = \frac{n_2}{N}$	...	$f_p = \frac{n_p}{N}$	1

**II. CARACTERISTIQUES DE DISPOSITION****a. Moyenne simple :**

Soit  $x$  un caractère qui prend les valeurs  $x_1, x_2, \dots, x_p$ , alors la moyenne de cette série statistique est :

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

**Exemple :** Voici les 8 notes (sur 20) d'un élève ce trimestre : 12 ; 15 ; 12 ; 13 ; 10 ; 19 ; 11 ; 7

Alors :  $\bar{x} = \frac{13 + 11 + 12 + 13 + 10 + 19 + 11 + 7}{8} = \frac{96}{8} = 12$

**b. Moyenne pondérée (coefficientée) :**

Soit  $x$  un caractère qui prend les valeurs  $x_1, x_2, \dots, x_p$ .

Les effectifs respectifs de chaque valeur sont  $n_1, n_2, \dots, n_p$ .

L'effectif total est donc  $\sum_{i=1}^p n_i = N$

Alors la moyenne de cette série statistique est :  $\bar{x} = \frac{\sum_{i=1}^p n_i x_i}{p}$


**Exemple :** Dans une classe, 7 élèves ont eu 12, 3 élèves ont eu 15, 5 élèves ont eu 9 et 1 seul élève a eu 18.

Alors la moyenne de la classe est :  $\bar{x} = \frac{7 \times 12 + 3 \times 15 + 5 \times 9 + 1 \times 18}{7 + 3 + 5 + 1} = \frac{192}{16} = 12$

**c. Médiane :**

C'est la valeur (de l'âge) qui se trouve au MILIEU de la série, qui la partage en deux séries d'effectif égal.

**Exemple :** voici les âges (par ordre croissant) de 22 individus :



La médiane de cette série statistique est de 28 ans.

**Remarques :**

- Dans le cas où l'effectif de la série est impair, la « ligne de partage » est située juste sur une valeur : C'est la valeur médiane.
  - Dans le cas où l'effectif de la série est pair (dans notre exemple), la « ligne de partage » est située juste entre deux valeurs de la série. Si ces deux valeurs sont différentes, on prend leur demi-somme pour valeur médiane.

**III. CARACTERISTIQUES DE DISPERSION**

Deux séries de données peuvent avoir des moyennes et médianes très proches, tout en étant constituées des données très différentes. Pour les comparer, on calcule deux **caractéristiques de dispersion** :

**a. Etendue :**

C'est la différence entre le Maximum et le Minimum de la série.

Dans l'exemple du **II.c.** l'étendue est :  $35 - 21 = 14$  ans

**b. Les quartiles**

Ce sont les valeurs qui partagent la série en quatre séries d'effectif égal. En fait, on ne détermine que le 1<sup>er</sup> et 3<sup>ème</sup> quartile, puisque le 2<sup>ème</sup> quartile est la médiane.

Le 1<sup>er</sup> quartile est le **plus petit nombre  $Q_1$**  tel que **25%** des données sont inférieures ou égales à  $Q_1$ .

Le 3<sup>ème</sup> quartile est le **plus petit nombre  $Q_3$**  tel que **75%** des données sont inférieures ou égales à  $Q_3$ .

Dans l'exemple précédent :

$$1^{\text{er}} \text{ quartile : } 25\% \text{ de } 22 = 22 \times \frac{25}{100} = 22 \times \frac{1}{4} = 5,5 \rightarrow 6^{\text{ème}} \text{ valeur donc } Q_1 = 26$$

$$3^{\text{ème}} \text{ quartile : } 75\% \text{ de } 22 = 22 \times \frac{75}{100} = 22 \times \frac{3}{4} = 16,5 \rightarrow 17^{\text{ème}} \text{ valeur donc } Q_3 = 31$$


**c. L'écart interquartile :**

C'est tout simplement la différence  $Q_3 - Q_1$ .

Dans l'exemple précédent,  $Q_3 - Q_1 = 31 - 26 = 5$  ans


**d. Le diagramme « boîte à moustache » :**

C'est un diagramme qui résume les caractéristiques de position (médiane, quartiles, extrêmes), sous la forme suivante :



Ce diagramme est principalement utilisé pour comparer un même caractère dans deux populations de tailles différentes.

Le diagramme correspondant à l'exemple précédent est :

**e. variance et écart-type :**

**Formules :**  $V(x) = \frac{1}{N} \sum_{i=1}^n n_i (x_i - \bar{x})^2 = \frac{1}{N} \sum_{i=1}^n n_i x_i^2 - (\bar{x})^2$  et  $\sigma_x = \sqrt{V(x)}$

Plus facile à retenir, la variance est « la différence entre la moyenne des carrés et le carré de la moyenne » obtenue

**Exemple**

Voici les 8 notes (sur 20) d'un élève ce trimestre :

									Total
Notes	12	15	12	13	10	19	11	7	99
(Notes) <sup>2</sup>	144	225	144	169	100	361	121	49	1313

Moyenne des notes :  $\frac{12+15+12+13+10+19+11+7}{8} = \frac{99}{8} = 12,375$

donc (Moyenne des notes)<sup>2</sup> :  $12,375^2 = 153,140625$

Moyenne des (notes)<sup>2</sup> :  $\frac{144+225+\dots+49}{8} = \frac{1313}{8} = 164,125$

La variance est donc :  $164,125 - 153,140625 \approx \mathbf{10,984}$

D'après l'exemple précédent :  $\sigma \approx \sqrt{10,984} \approx \mathbf{3,314}$

**L'écart-type peut être interprété comme « l'écart moyen par rapport à la moyenne d'une série de valeurs ».**

**Plus il est grand, plus les valeurs sont dispersées.**

**Plus il est petit, plus les valeurs sont centrées autour de la moyenne.**