

# Biostatistique

3.3

*L 2.Sc.Biologiques*



MR. LATELI AHCENE

## Légende



Entrée du glossaire



Abréviation



Référence générale

# Table des matières



<b>I - Partie I : Statistiques descriptives</b>	<b>5</b>
A. Définitions et vocabulaires.....	<b>5</b>
B. Statistique descriptive univariée (Statistique descriptive à un caractère).....	<b>10</b>
1. Présentation d'une DS à 1 caractère.....	<b>10</b>
2. Paramètres d'une distribution.....	<b>11</b>



# Partie I : Statistiques descriptives

Définitions et vocabulaires

5

Statistique descriptive univariée (Statistique descriptive à un caractère)

10

## A. Définitions et vocabulaires



### Définition

1. **la statistique** est une **méthode** scientifique qui consiste à réunir des données chiffrées sur des ensembles nombreux, puis à analyser, à commenter et à critiquer ces données.
2. **La statistique** est une méthode qui vise à la description quantitative des ensembles nombreux. (définition donnée par **Gerard-Calot**). C'est une méthode et non une théorie

Le but de la **statistique descriptive** est de structurer et de représenter l'information contenue dans les données.



### Définition : La biostatistique

La **biostatistique** c'est la **statistique appliquée** à la **biologie**.



### Exemple

1. Étude descriptive des poids des étudiants inscrits en première année de biologie à l'université de Constantine 1.
2. Une étude statistique sur l'ensemble des exploitations agricoles dans la région de Constantine.

Comme toute science, la statistique fait appel à un vocabulaire spécialisé :



### Définition : Population

**Une population** statistique **P** est l'ensemble d'individus définis par une propriété commune donnée. C'est un ensemble généralement très grand



### Exemple

- Si l'on veut étudier la durée de vie des ampoules électriques fabriquées par

une compagnie, la population considérée est l'ensemble de toutes les ampoules fabriquées par cette compagnie.

- ensemble de personnes sur lesquelles on mesure la glycémie.
- ensemble de pays pour lesquels on dispose de données géographiques ou économiques, ...



### Définition : Échantillon

Un **échantillon E** est une partie de la population **P**.



### Exemple

Pour établir la durée de vie des ampoules électriques produites par une machine, on peut prélever au hasard un certain nombre d'ampoules - un échantillon - parmi toutes les celles produites par cette machine.



### Définition : Individu ou unité statistique

Chaque élément de la population ou de l'échantillon appelé **individu** ou **unité statistique**.



### Exemple

Dans l'exemple précédant, chaque ampoule constitue un individu ou une unité statistique.



### Définition : La taille

Représente le nombre d'individus d'un échantillon ou d'une population. Elle est symbolisée par « $n$ » dans le cas d'un échantillon et par « $N$ » dans le cas d'une population.



### Définition : Le caractère

C'est l'aspect particulier que l'on désire étudier.



### Exemple

Concernant un groupe de personnes, on peut s'intéresser à leur âge, leur sexe leur taille...



### Définition : Les modalités

Les différentes manières d'être que peut présenter un caractère.



### Exemple

1. Le sexe est un caractère qui présente deux modalités : féminin ou masculin.
2. Quant au nombre d'enfants par famille, les modalités de ce caractère peuvent être 0,1,2,3...,20.




Figure 1 : Un échantillon  $E$  est une partie de la population  $P$




Figure 2 : Ex: dans une population  $P$  de 35 pays, un pays particulier est l'unité statistique = l'individu ou l'élément



### Définition : Caractère qualitatif

Ses modalités ne s'expriment pas par un nombre



### Exemple

la religion, le sexe, l'opinion...



### *Définition : Caractère quantitatif*

---

Ses modalités sont numériques.



### *Définition : La variable statistique*

---

chaque attribut (ou caractère ou caractéristique) a des modalités, ou peut s'exprimer selon une mesure, celles-ci varient d'un individu à l'autre ou d'un groupe d'individus à un autre groupe d'individus. La variable statistique est le nom que l'on donne à ces caractères (attributs, caractéristiques).

### *Explicitation de variable en biologie*

---

Caractéristique mesurable ou observable sur un élément (variable propre) ou dans son environnement (variable associée).



### *Définition*

---

On distingue **quatre types de variables** selon leurs valeurs possibles :

- **Les variables qualitatives nominales** sont celles dont les valeurs sont des attributs sans ordre naturel (ex. sexe, csp).
- **Les variables qualitatives ordinales** sont celles dont les valeurs sont des attributs avec un ordre naturel (ex. activité faible, moyenne, forte).
- **Les variables quantitatives discrètes** sont celles dont les valeurs sont le résultat d'un dénombrement (ex. nombre d'enfants dans une famille, pouls, nombre d'oiseaux nichant dans une falaise).
- **Les variables quantitatives continues** sont celles dont les valeurs sont des mesures (ex. taille, poids).




Figure 3 : Typologie des caractères pour une approche statistique

## B. Statistique descriptive univariée (Statistique descriptive à un caractère)

### 1. Présentation d'une DS à 1 caractère


Deux types de présentations: **en tableau** et **représentation graphique**

- Une **présentation en tableau** est une présentation des effectifs et ou/ fréquences des individus en fonction des modalités (valeurs ou intervalles de classes du caractère étudié).
- La **représentation graphique** dépend du type de caractère et d'effectifs (cumulés ou non).

Situation familiale $A_i$	Nombre de personnes dans cette situation $n_i$	Fréquences $f_i = n_i/n$	$f_i$ en % $100 f_i$
célibataire	150	150/360	
marié	120	.	
divorcé	10	.	
veuf	80	.	
Total	360 = n	1	100%

**Présentation en tableau d'un caractère qualitatif**

Image 1 Figure 4 : Ex: Situation familiale dans un groupe de 360 individus



**Représentation graphique du caractère « Situation familiale »**

Image 2 Figure 5 : Représentation en secteurs ou en camemberts

GROUPE	$n_i$
A	35
B	9
O	40
AB	16




Figure 6 : groupage de 100 personnes

## 2. Paramètres d'une distribution

### a) Les paramètres de position



#### Définition : Moyenne arithmétique (mean)

$E(x)$  = moyenne de la distribution théorique des éléments  $x$ .

$\bar{X} = \frac{1}{N} \sum_{i=1}^N x_i$  désigne **la moyenne arithmétique d'une population** finie comportant  $N$  éléments ( $N$  = effectif). Mêmes unités physiques que  $x$ .

$\bar{x} = \frac{1}{n} \sum_{i=1}^K n_i \cdot x_i = \sum_{i=1}^K f_i \cdot x_i$  désigne **la moyenne arithmétique** de  $n$  éléments ( $n$  = effectif) tirés d'une population finie ou infinie. Mêmes unités que  $x$ , où  $n_i$  et  $f_i$  désignent respectivement l'effectif et la fréquence de la modalité  $x_i$  (ou le centre de la classe dans le cas d'une **variable classée**).



#### Exemple

- Soit la série de chiffres {8, 5, 9, 13, 25}. La moyenne arithmétique de cette série de chiffres se calcule ainsi :

$$\bar{x} = \frac{8 + 5 + 9 + 13 + 25}{5} = \frac{60}{5} = 12$$

- Calcul de la moyenne arithmétique quand les valeurs sont groupées par classes par exemple :

Calculons la taille moyenne des 20 individus :

La taille moyenne est donc :  $\bar{x} = \frac{3410}{20} = 170.5cm$



### Remarque

- Soient plusieurs populations d'effectifs  $n_1, n_2, \dots, n_k$ , de moyennes respectives  $\bar{x}_1, \bar{x}_2, \dots, \bar{x}_k$ . La moyenne globale est la moyenne des moyennes i.e.  $\bar{\bar{x}} = \frac{1}{n} \sum_{i=1}^K n_i \cdot \bar{x}_i$ .
- **La moyenne arithmétique conserve les changements d'échelle et d'origine** i.e. pour  $a, b \in \mathbb{R}; ax + b = a\bar{x} + b$ .
- La somme algébrique des écarts de tous les termes de la série à la moyenne est nulle: i.e.  $\sum_{i=1}^N (x_i - \bar{x}) = 0$ .
- La somme des carrés des différences de tous les termes d'une série statistique à un nombre quelconque est **minimal** lorsque ce nombre es la moyenne arithmétique de cette série: i.e.  $\sum_{i=1}^K n_i \cdot (x_i - x)^2$  est minimale si et seulement si  $x = \bar{x}$ .



### Définition : Médiane (median)

Symbole:  $Me_x$ ; Mêmes unités physiques que  $x$ .

**La médiane** est la valeur de la variable qui se situe au centre de la série statistique, classée en ordre croissant. La médiane sépare la série en deux groupes d'égale importance.

- Si le nombre d'observations  $n$  est **impair** alors la médiane est la valeur de la série ordonnée située à la position  $\frac{n+1}{2}$  i.e.  $Me = x_{(n+1)/2}$ .
- Si  $n$  est **pair** :  $Me$  est la **moyenne arithmétique** des deux observations centrales.i.e.  $Me = \frac{x_{n/2} + x_{(n/2)+1}}{2}$ .



### Remarque

Si **la variable est continue**, pour **calculer la médiane**, on repère d'abord la classe dans laquelle elle se trouve : c'est celle dont l'effectif cumulé est immédiatement supérieur à  $\frac{n}{2}$ , notons la  $]x_1; x_2]$  ;

notons  $n_2$  l'effectif cumulé de cette classe et  $n_1$  l'effectif cumulé de la classe qui précède . En faisant l'hypothèse que les valeurs sont **uniformément réparties** à l'intérieur des classes, on a d'après le **théorème de Thalès** l'expression suivante :

$$Me \approx x_1 + (x_2 - x_1) \cdot \frac{\frac{n}{2} - n_1}{n_2 - n_1}$$

Ce calcul fournit **une valeur approchée de la médiane**.



### Exemple

1. **pour la série: [1, 32, 128, 129, 1000235], Me = 128.**
2. **pour la série [1, 32, 128, 129, 532, 1000235], Me = 128,5.**



### Définition : Mode (mode)

Symbole:  $Mo_x$  Mêmes unités physiques que  $x$ .

**Le mode** est la valeur de la variable statistique la **plus fréquente**.

Dans le cas d'une variable statistique continue, on parle plutôt de **classe modale**.



### Remarque

1. **Le mode** peut être calculé pour tous les types de variable, **quantitative et qualitative**.
2. Pour les **variables qualitatives**, le mode correspond à la **classe** ayant la **plus forte fréquence**.
3. **Le mode ou la classe modale n'est pas obligatoirement unique**.

### b) Les paramètres de dispersion

**Les paramètres de dispersion renseignent sur l'étalement de la distribution de fréquence autour de la moyenne.**



### Définition : Étendue de variation (range)

Synonyme: **plage** de variation; Mêmes unités physiques que  $x$ .

**L'étendue** notée  $e$ , est la **différence** entre la **plus grande** (maximum) et la **plus petite** (minimum) des valeurs observées. i.e.  $e = x_{Max} - x_{Min}$ .



### Définition : Variance (variance)

C'est la caractéristique de dispersion la plus utilisée avec l'écart quadratique moyen.

Symboles:  $s_x^2$  pour un échantillon, et  $\sigma^2$  ("sigma<sup>2</sup>") ou  $Var(x)$  pour une population ou distribution théorique.

Pour une population statistique d'effectif  $N$  dont la moyenne vraie  $\mu$  est connue par théorie ou par hypothèse, on utilise la formule suivante:

$$\text{1<sup>er</sup> cas : série non classée} \quad Var(x) = \sigma^2 = \frac{1}{N} \sum_{i=1}^N (x_i - \bar{\mu})^2$$

$$\text{2<sup>ème</sup> cas : série classée} \quad Var(x) = \sigma^2 = \frac{1}{N} \sum_{i=1}^K n_i \cdot (x_i - \bar{\mu})^2 = \sum_{i=1}^K f_i \cdot (x_i - \bar{\mu})^2$$

Dans le cas d'une variable statistique continue,  $x_i$  représente le centre de la  $i$ ème classe.



### Méthode : Autre expression de la variance : Théorème de KOENIG

$$\text{1<sup>er</sup> cas : série non classée} \quad Var(x) = \left( \frac{1}{N} \sum_{i=1}^N x_i^2 \right) - \bar{\mu}^2$$

$$\text{2<sup>ème</sup> cas : série classée} \quad Var(x) = \left( \frac{1}{N} \sum_{i=1}^K n_i \cdot x_i^2 \right) - \bar{\mu}^2 = \left( \sum_{i=1}^K f_i \cdot x_i^2 \right) - \bar{\mu}^2$$



### Définition : L'écart type (standard deviation)

**L'écart type** est la racine carrée de la variance.

**Symboles:**  $\sigma$  pour une population ou une distribution théorique  $s_x$  pour un échantillon,  $s_x = \sigma(x) = \sqrt{Var(x)}$ .



**Remarque**

1. **La variance (ou écart-type)** est toujours **positive ou nulle**.
2. **L'écart-type** a l'avantage d'être un **nombre de même dimension** que les données (contrairement à la variance qui en est le carré).
3. **l'écart type** (tout comme **la variance**) est sensible aux **valeurs extrêmes**.



**Définition : Coefficient de variation (coefficient of variation)**

**Le coefficient de variation**  $C_v$  d'un caractère statistique  $X$  est égal à l'écart type divisé par la moyenne. i.e.

$$C_v(X) = \frac{\sigma(X)}{\bar{X}} \cdot 100$$


**Définition : L'écart moyen absolu**

**L'écart moyen absolu** est la somme des valeurs absolues des écarts à la moyenne divisée par le nombre d'observations :

$$e_{moy} = \frac{1}{N} \sum_{i=1}^N |x_i - \bar{x}|$$


**Définition : L'écart médian absolu**

**L'écart médian absolu** est la somme des valeurs absolues des écarts à la médiane divisée par le nombre d'observations :

$$e_{med} = \frac{1}{N} \sum_{i=1}^N |x_i - Me|$$


**Définition : L'écart interquartile**

- **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  $\frac{n}{4}$ .
- **Le troisième quartile**  $Q_3$  de la série est la valeur  $x_j$  dont l'indice  $j$  est le plus petit entier supérieur ou égal à  $\frac{3n}{4}$ .
- La médiane est parfois appelée **second quartile**, c'est-à-dire  $Q_2 = Me$ .
- L'intervalle  $]Q_1; Q_3[$  est appelé **intervalle interquartile**
- Le nombre  $Q_3 - Q_1$  est appelé **écart interquartile**.




Image 3 Diagramme en boîte

Un **diagramme en boîte**, ou pour utiliser le terme anglais, un **boxplot**, est une **alternative à l'histogramme** pour **résumer graphiquement** la distribution en terme de paramètres de position et de dispersion



**Remarque**

Dans l'intervalle interquartile on trouve **50%** de la population.

**Les moments d'une distribution (moments)**

- On appelle **moment à l'origine d'ordre**  $r \in \mathbb{N}$  le paramètre:  $m'_r = \frac{1}{N} \sum_{i=1}^N x_i^r$

- On appelle **moment centré d'ordre**  $r \in \mathbb{N}$  le paramètre :

$$m_r = \frac{1}{N} \cdot \sum_{i=1}^N (x_i - \bar{x})^r$$