

# Statistiques

## Chapitre 15

### Vocabulaire

---

#### Définition — Termes de base

- Une *population* est l'ensemble étudié.
- Un élément de la population est un *individu*.
- On étudie un *caractère* (ou *variable*) commun aux individus. Il peut être :
  - *qualitatif* (couleur, sexe, sport pratiqué) ;
  - *quantitatif* : valeurs numériques. Discret (nombre d'enfants par famille, note) ou continu (taille, poids).
- L'*effectif*  $n_i$  d'une valeur  $x_i$  est le nombre d'individus correspondant.
- L'*effectif total* est  $N = \sum_i n_i$ .
- La *fréquence* de la valeur  $x_i$  est  $f_i = \frac{n_i}{N}$ , souvent exprimée en pourcentage.

**Exemple.** Note d'une classe de 25 élèves :

8, 12, 15, 10, 12, 14, 9, 11, 13, 12, 16, 10, 11, 12, 14, 13, 9, 15, 11, 12, 13, 10, 14, 12, 11.

Effectif total  $N = 25$ . Effectif de la note 12 :  $n_{12} = 6$ . Fréquence :  $f_{12} = \frac{6}{25} = 0.24 = 24\%$  (soit 0,24).

### Organisation des données

---

#### Tableau d'effectifs et de fréquences

Une série discrète se présente sous forme de tableau :

$x_i$	8	9	10	11	12	...
$n_i$	1	2	3	4	6	...
$f_i$	0.04	0.08	0.12	0.16	0.24	...

#### Données regroupées en classes

Pour une variable continue, on regroupe les valeurs en *classes* (intervalles). On note  $[a, b[$  une classe de centre  $\frac{a+b}{2}$  et d'amplitude  $b - a$ .

#### Effectifs / fréquences cumulés

L'effectif cumulé croissant en  $x_i$  est la somme des effectifs des valeurs  $\leq x_i$ . Idem pour les fréquences cumulées.

## Représentations graphiques

- **Diagramme en bâtons** : pour une variable discrète, hauteur proportionnelle à l'effectif (ou la fréquence).
- **Histogramme** : pour une variable continue, aire de chaque rectangle proportionnelle à l'effectif de la classe.
- **Polygone des fréquences** : ligne brisée joignant les milieux des hauteurs des bâtons / sommets des rectangles.
- **Diagramme circulaire** : angles proportionnels aux fréquences.
- **Courbe des effectifs cumulés croissants** : utile pour lire la médiane et les quartiles.

## Mesures de tendance centrale

### Mode

#### Définition

Le *mode* est la (ou les) valeur(s) du caractère ayant l'effectif le plus élevé. Pour des données regroupées, on parle de *classe modale*.

### Médiane

#### Définition — Médiane (série discrète)

La *médiane*  $Me$  est la valeur qui partage la série rangée en deux parties d'effectif égal :

- Si  $N$  est impair : la médiane est la valeur de rang  $\frac{N+1}{2}$ .
- Si  $N$  est pair : la médiane est la moyenne des valeurs de rang  $\frac{N}{2}$  et  $\frac{N}{2} + 1$ .

**Exemple.** Série : 5, 8, 10, 12, 14 ( $N = 5$ ). Médiane = 10 (3<sup>e</sup> valeur).

Série : 5, 8, 10, 12, 14, 18 ( $N = 6$ ). Médiane =  $\frac{10+12}{2} = 11$ .

### Moyenne arithmétique

#### Définition

La *moyenne* d'une série  $(x_1, x_2, \dots, x_p)$  d'effectifs  $(n_1, \dots, n_p)$  est :

$$\bar{x} = \frac{\sum_{i=1}^p n_i x_i}{N} = \sum_{i=1}^p f_i x_i.$$

Pour des classes, on utilise les centres de classe.

**Exemple.** Si  $x_i \in \{8, 12, 16\}$  avec effectifs  $(2, 5, 3)$  et  $N = 10$  :  $\bar{x} = \frac{2 \times 8 + 5 \times 12 + 3 \times 16}{10} = \frac{16 + 60 + 48}{10} = 12.4$  (soit 12, 4).

## Mesures de dispersion

### Étendue

#### Définition

L'*étendue* est la différence entre la plus grande et la plus petite valeur observée.

### Variance et écart-type

#### Définition — Variance et écart-type

La *variance* de la série est :

$$V = \left(\frac{1}{N}\right) \sum_{i=1}^p n_i (x_i - \bar{x})^2 = \sum_{i=1}^p f_i (x_i - \bar{x})^2.$$

L'*écart-type* est  $\sigma = \sqrt{V}$ .

L'écart-type mesure la dispersion autour de la moyenne, dans la même unité que les données.

#### Théorème — Formule de König-Huygens

$$V = \left(\frac{1}{N}\right) \sum_{i=1}^p n_i x_i^2 - \bar{x}^2.$$

Cette formule est souvent plus pratique pour le calcul.

**Exemple.** Pour la série  $x_i \in \{8, 12, 16\}$  d'effectifs  $(2, 5, 3)$  et  $\bar{x} = 12.4$  :  $\sum n_i x_i^2 = 2 \times 64 + 5 \times 144 + 3 \times 256 = 128 + 720 + 768 = 1,616$ .  $V = \frac{1616}{10} - 12.4^2 = 161.6 - 153.76 = 7.84$ .  $\sigma = \sqrt{7.84} \approx 2.8$ .

### Écart absolu moyen

#### Définition

L'*écart absolu moyen* est :

$$\text{EAM} = \left(\frac{1}{N}\right) \sum_i n_i |x_i - \bar{x}|.$$

### Quartiles, écart interquartile

**Définition**

Le 1<sup>er</sup> quartile  $Q_1$  est la plus petite valeur telle qu'au moins 25% des observations sont  $\leq Q_1$ .  
Le 3<sup>e</sup> quartile  $Q_3$  est défini de manière analogue avec 75%. L'*écart interquartile* est  $Q_3 - Q_1$ .

## Interprétation des indicateurs

---

- La **moyenne** est sensible aux valeurs extrêmes ; la **médiane** l'est moins. Pour des salaires d'entreprise, la médiane est souvent plus représentative que la moyenne.
- L'**écart-type** est petit quand les données sont concentrées autour de la moyenne, grand quand elles sont dispersées.

**Exemple.** Deux séries  $A$  et  $B$  ont la même moyenne 10, mais  $\sigma_A = 1$  et  $\sigma_B = 5$ . La série  $B$  est beaucoup plus dispersée — par exemple,  $A : 9, 10, 11$  et  $B : 5, 10, 15$ .