

## Table des matières

<b>I Vocabulaire</b>	<b>2</b>
<b>II Représentations graphiques</b>	<b>3</b>
II.1 Séries à caractère quantitatif discret	3
II 1.1 Diagramme en bâtons	3
II 1.2 Diagramme circulaire	4
II 1.3 Nuage de points	5
II.2 Séries à caractère quantitatif continu	6
II 2.1 Histogramme	6
II 2.2 Polygone d'effectifs ou de fréquences cumulés	6
<b>III Paramètres statistiques</b>	<b>7</b>
III.1 Paramètres de position	7
III 1.1 Mode	7
III 1.2 Moyenne	8
III 1.3 Médiane	8
III.2 Paramètres de dispersion	10
III 2.1 Étendue	10
III 2.2 Quartiles	10
III 2.3 Écart interquartile	10

# I Vocabulaire

Une étude statistique commence par un recueil de données. On utilise le vocabulaire suivant pour décrire cette étude :

- **Série statistique** : Ensemble des valeurs collectées.
- **Population** : Ensemble sur lequel porte l'étude statistique.
- **Individus** : Éléments qui composent la population.
- **échantillon** : Partie de la population.
- **Caractère étudié** : Propriété que l'on observe sur les individus. Les différentes valeurs obtenues sont appelées **valeurs du caractère** ou **modalités**, souvent notées  $x_1, x_2, \dots, x_p$ . On distingue deux types de caractères.
  - ◇ Un caractère peut être **qualitatif** (situation de famille, sexe, couleur des yeux, type d'habitation...).
  - ◇ Un caractère peut être **quantitatif**. Il est dit **discret** lorsqu'il ne prend que des valeurs isolées (nombre d'enfants, notes dans une classe...).Il est dit **continu** lorsqu'il peut prendre théoriquement toutes les valeurs d'un intervalle (taille, temps d'écoute...); dans ce cas, les valeurs sont regroupées en intervalles appelés des **classes**.

- **Effectif** : Pour une valeur du caractère (modalité ou classe), on appelle effectif le nombre d'individus de la population ayant cette valeur. On note souvent  $n_1, n_2, \dots, n_p$  les effectifs respectifs des modalités  $x_1, x_2, \dots, x_p$ .
- **Effectif total** : Nombre total d'individus de la population (ou de l'échantillon). Il est égal à  $n_1 + n_2 + \dots + n_p$ , souvent noté  $N$ .
- **Fréquence** : Pour une valeur du caractère (modalité ou classe), on appelle fréquence le quotient de l'effectif de cette valeur par l'effectif total. On note souvent  $f_1, f_2, \dots, f_p$  les fréquences respectives des modalités  $x_1, x_2, \dots, x_p$ , donc :

$$f_1 = \frac{n_1}{N}, f_2 = \frac{n_2}{N}, \dots, f_p = \frac{n_p}{N}.$$

On en déduit que  $0 \leq f_1 \leq 1, 0 \leq f_2 \leq 1, \dots, 0 \leq f_p \leq 1$ , et  $f_1 + f_2 + \dots + f_p = 1$ .

- **Valeurs extrêmes** : Valeurs minimales et maximales d'un caractère quantitatif.
- **Effectif cumulé** : Pour une valeur  $x$  d'une série statistique quantitative, l'effectif cumulé croissant (respectivement décroissant) de  $x$  est la somme des effectifs des valeurs inférieures (respectivement supérieures) ou égales à  $x$ .
- **Fréquence cumulée** : Pour une valeur  $x$  d'une série statistique quantitative, la fréquence cumulée croissante (respectivement décroissante) de  $x$  est la somme des fréquences des valeurs inférieures (respectivement supérieures) ou égales à  $x$ .

## Exemple avec des notes :

Dans le tableau suivant sont regroupées les notes obtenues par les élèves d'une seconde lors du contrôle n° 1 (éventuellement arrondies pour simplifier l'étude) :

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

Dans cet exemple :

- La série statistique est l'ensemble des notes collectées.
- La population est l'ensemble des élèves de seconde .
- Les individus sont chacun des élèves de seconde Turner.
- Le caractère étudié est le résultat obtenu au contrôle n° 1.
- Les modalités sont les valeurs chiffrées des notes obtenues au contrôle n° 1.
- L'effectif total est le nombre d'élèves de la classe, à savoir 34.
- Les valeurs extrêmes sont 4 et 19.

**Exemple avec des notes :** 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

### Remarque

Dans le tableau précédent, la somme des fréquences est supérieure à 1 à cause des arrondis.

**Exemple : série continue** On a interrogé en 2008 un échantillon de 4812 Français concernant la durée hebdomadaire d'écoute de la télévision (en heures) :

<b>Durée</b>	[0 ; 10[	[10 ; 15[	[15 ; 20[	20 ; 30[	30 ; 50]
<b>Effectif</b>	972	924	826	1069	1021

Le caractère étudié, à savoir la durée d'écoute, est quantitatif continu : il peut prendre théoriquement toutes les valeurs de l'intervalle [0 ; 50]. Les données sont regroupées en classes [0 ; 10], [10 ; 15[, [15 ; 20[, [20 ; 30[ et [30 ; 50].


## II Représentations graphiques

### II.1 Séries à caractère quantitatif discret

#### II 1.1 Diagramme en bâtons

Dans un **diagramme en bâtons**, on représente une série statistique discrète par des segments dont la hauteur est proportionnelle à l'effectif de la valeur qu'ils représentent.

**Exemple** On continue à travailler avec les données de l'exemple sur les notes. Voici le diagramme en bâtons de cette série :



## II 1.2 Diagramme circulaire

### Exemple :


Dans une compétition d'athlétisme, quatre pays s'affrontent : la France, l'Allemagne, la Suède et la Norvège. On note le pourcentage de médailles obtenues par chacun des pays :

Pays	France	Allemagne	Suède	Norvège
Pourcentage de médailles	25 %	10 %	40 %	25 %

Représenter le diagramme circulaire associé à cette série statistique :

Pays	Total	France	Allemagne	Suède	Norvège
Pourcentage de médailles	100 %	25 %	10 %	40 %	25 %
Angle en °	360	90	36	144	90


Pour cela, nous avons besoin des angles ; nous les calculons par proportionnalité, sachant que 100 % correspondent à 360°.



## II 1.3 Nuage de points

Dans un **nuage de points**, on représente une série statistique discrète par des points dont les abscisses sont les valeurs du caractère, et les ordonnées sont les effectifs correspondants, parfois reliés par des segments.

**Exemple** On travaille toujours avec les données de l'exemple sur les notes. Voici le nuage de points de cette série :



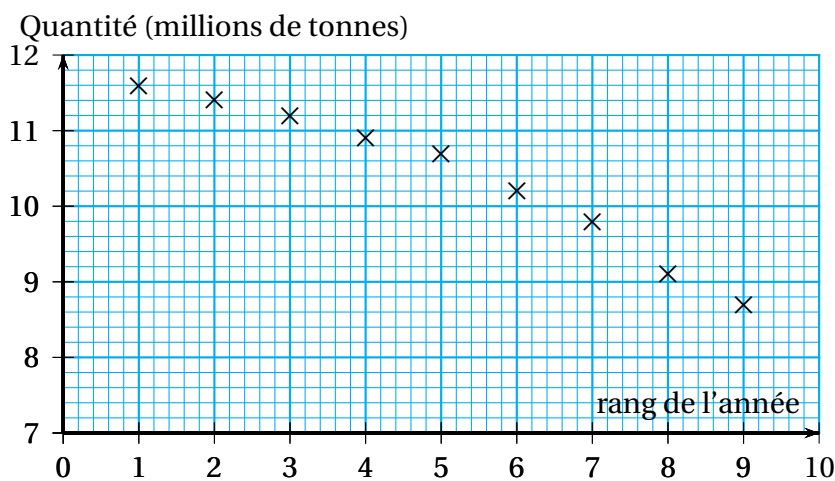
**Autre exemple**, tiré du sujet de baccalauréat ES Polynésie juin 2012 :

Le tableau ci-dessous donne les quantités de super sans plomb livrées et vendues en France de 2001 à 2009 (les quantités sont exprimées en millions de tonnes).

Année	2001	2002	2003	2004	2005	2006	2007	2008	2009
Rang de l'année $x_i$	1	2	3	4	5	6	7	8	9
Quantité (millions de tonnes) $y_i$	11,6	11,4	11,2	10,9	10,7	10,2	9,8	9,1	8,7

Source : INSEE

On représente alors les données sous forme de nuage de points en mettant en abscisses le rang de l'année et en ordonnées les quantités en (millions de tonnes)




## II.2 Séries à caractère quantitatif continu

### II.2.1 Histogramme

Dans un **histogramme**, on représente une série statistique continue par des rectangles dont la largeur correspond à l'amplitude de chaque classe et dont l'**aire est proportionnelle à l'effectif de la classe**.

#### Exemple

On travaille avec les données de l'exemple sur la durée d'écoute de la télévision. (voir [ici](#))  
Voici l'histogramme de cette série :



#### Remarque

Lorsque les classes ont toutes la même amplitude, la hauteur de chaque rectangle est proportionnelle à l'effectif de la classe qu'il représente. On dit alors que l'histogramme est à **pas constant**.

### II.2.2 Polygone d'effectifs ou de fréquences cumulés

- Le **polygone des effectifs cumulés croissants** (respectivement **décroissants**) d'une série statistique continue est la ligne brisée qui joint les points du plan dont les abscisses sont les bornes de chaque classe et dont les ordonnées sont les effectifs cumulés croissants (respectivement décroissants) de ces valeurs.
- Le **polygone des fréquences cumulées croissantes** (respectivement **décroissantes**) d'une série statistique continue est la ligne brisée qui joint les points du plan dont les abscisses sont les bornes de chaque classe et dont les ordonnées sont les fréquences cumulées croissantes (respectivement décroissantes) de ces valeurs.


Ces représentations donnent l'allure de la répartition des valeurs de la série.

#### Exemple

La situation est toujours celle de l'exemple I. Le tableau des effectifs cumulés croissants est le suivant :

<b>Durée &lt;</b>	0	10	15	20	30	50
<b>Effectif</b>	0	972	1896	2722	3791	4812

D'où le polygone des effectifs cumulés croissants :



Traisons à présent le cas des fréquences cumulées décroissantes :

<b>Durée <math>\geq</math></b>	0	10	15	20	30	50
<b>Effectif</b>	4812	3840	2916	2090	1021	0
<b>Fréquence</b>	1	0,8	0,61	0,43	0,21	0

D'où le polygone des fréquences cumulées décroissantes :



## III Paramètres statistiques

### III.1 Paramètres de position

#### III 1.1 Mode

**Définition :**

Un **mode** d'une série statistique est une valeur de la série dont l'effectif est strictement supérieur à celui des autres valeurs.

### Remarque

Dans une série statistique, il peut y avoir plusieurs modes.

### Exemple

Dans l'exemple sur les notes, le mode est 16.

## III 1.2 Moyenne

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

$$\bar{x} = \frac{n_1 x_1 + n_2 x_2 + \dots + n_p x_p}{n_1 + n_2 + \dots + n_p} = \frac{n_1 x_1 + n_2 x_2 + \dots + n_p x_p}{N}$$

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 :

$$\bar{x} = x_1 f_1 + x_2 f_2 + \dots + x_p f_p.$$

### Exemple

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

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

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

## III 1.3 Médiane

### 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,  $N = 2p$ ,  $M$  est la moyenne des deux valeurs « centrales » de la série, c'est-à-dire 
$$M = \frac{x_N + x_{N+1}}{2}.$$
- Si  $N$  est impair,  $N = 2p + 1$ ,  $M$  est la valeur centrale de la série, c'est-à-dire  $x_{p+1}$ .

### Exemple

Dans l'exemple I, 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 12, et qu'au moins la moitié des notes est supérieure ou égale à 12 .

### Exemple

En France, en 2005, dans le secteur privé et semi-public (SNCF, Poste, Caisse d'épargne...), le salaire net mensuel médian est de 1528 €, (ce qui signifie que la moitié des salariés de ces entreprises touchent moins que cette valeur) alors que le salaire net mensuel moyen est de 1903,5 €. (somme de tous les salaires divisée par le nombre de salariés)

Source : .

## III.2 Paramètres de dispersion

### III 2.1 Étendue

#### Définition

L'**étendue** d'une série statistique est la différence entre sa plus grande et sa plus petite valeur.

#### Exemple

Dans l'exemple sur les notes, l'étendue est égale à  $19 - 4 = 15$ .

### III 2.2 Quartiles

#### 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 I.

- $34 \times \frac{25}{100} = 8,5$  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'amoin-drir lors d'une étude sur une population plus importante avec un caractère dont les modalités sont plus disparates.

### III 2.3 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 I, l'intervalle interquartile est  $[10 ; 16]$  et l'écart interquartile est  $Q_3 - Q_1 = 16 - 10 = 6$ .