

Statistiques

I - Définitions

1 - La statistique :

La statistique est l'ensemble des méthodes qui ont pour objectif de collecter, de traiter et d'interpréter les données obtenues à partir d'une population constituée d'individus.

2 - Les différents type de variables :

Une variable peut être :

1. **Quantitative** : ce sont des variables à valeurs numériques (âges, poids, tailles, notes, etc...).
On peut les classer en deux catégories : discrètes et continues.
 - (a) *Discrète* : elles ne prennent qu'un nombre fini de valeurs (résultat d'un jet de dé, nombre d'enfant dans une famille).
 - (b) *Continue* : elles prennent leurs valeurs dans un intervalle (par exemple entre 10 et 40 euros).
2. **Qualitative** : ce sont des variables représentées par des qualités. On peut citer par exemple la couleur des yeux, l'appréciation des clients pour un produit, le programme d'études, etc.

II - Série statistique à une variable

Dans tout ce qui suit, on considère une série statistique de taille n , dont les termes (valeurs de la série) x_1, x_2, \dots, x_p sont rangés dans l'ordre croissant : $x_1 \leq x_2 \leq \dots \leq x_p$.

Les valeurs n_1, n_2, \dots, n_p représentent respectivement les effectifs des termes x_1, x_2, \dots, x_p .

On peut représenter toutes ces valeurs dans le tableau (**T**) suivant :

Valeurs de X	x_1	x_2	x_3	...	x_p
Effectifs	n_1	n_2	n_3	...	n_p

Exemple :

On donne dans les tableau ci-dessous le notes obtenues par 25 élèves d'une classe de Seconde en physique.

Notes	4	5	7	8	9	10	12	13	15	17	18
Effectifs	1	3	2	4	3	4	3	1	2	1	1

1 - Les paramètres statistiques :

a - La fréquence

La fréquence d'une valeur est égale à l'effectif de cette valeur divisé par l'effectif total.

Dans le cas du tableau (**T**), la fréquence de la valeur x_i est égale à $f_i = \frac{n_i}{n}$.

La fréquence est donnée sur la troisième ligne du tableau ci-dessous.

Valeurs de X	x_1	x_2	x_3	...	x_p
Effectifs n_i	n_1	n_2	n_3	...	n_p
Fréquence f_i	$\frac{n_1}{n}$	$\frac{n_2}{n}$	$\frac{n_3}{n}$...	$\frac{n_p}{n}$

b - La moyenne

La moyenne de la série, noté \bar{x} , est définie par : $\bar{x} = \frac{n_1x_1 + n_2x_2 + \dots + n_px_p}{n}$ ou $\bar{x} = f_1x_1 + f_2x_2 + \dots + f_px_p$.

c - La variance

La variance de la série, notée V, peut être calculer à partir des effectifs ou des fréquences :

- Avec les effectifs :
$$V = \frac{n_1(x_1 - \bar{x})^2 + n_2(x_2 - \bar{x})^2 + \dots + n_p(x_p - \bar{x})^2}{n}$$

- Avec les fréquences :
$$V = f_1(x_1 - \bar{x})^2 + f_2(x_2 - \bar{x})^2 + \dots + f_p(x_p - \bar{x})^2$$

d - L'écart-type

L'écart-type d'une série statistique, noté σ , est définie par : $\sigma = \sqrt{V}$. C'est la racine carrée de la variance.

Remarque : L'écart-type représente l'écart moyen des valeurs de la série par rapport à la moyenne. Une série statistique dont les valeurs sont très éloignées de la moyenne a un écart-type élevé.

e - La médiane

La médiane d'une série est la valeur séparant les valeurs d'une série en deux groupes de même effectif.

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

Calcul de la médiane :

Premier cas :

Si l'effectif total n est pair, la médiane est la moyenne des deux termes centraux de la série : $M_e = \frac{x_{\frac{n}{2}} + x_{\frac{n}{2}+1}}{2}$.

Deuxième cas :

Si l'effectif n est impair, la médiane est le terme central de la série : $M_e = x_{\frac{n+1}{2}}$.

f - Les quartiles

- Premier quartile : Q_1

Le premier quartile, noté Q_1 , est la plus petite valeur de la série pour laquelle au moins 25 % ($\frac{1}{4}$) des données lui sont inférieures ou égales.

- Troisième quartile : Q_3

Le troisième quartile, noté Q_3 , est la plus petite valeur de la série pour laquelle au moins 75 % ($\frac{3}{4}$) des données lui sont inférieures ou égales.

g - Écart inter-quartile

On définit l'intervalle inter-quartile par : $[Q_1; Q_3]$.

On en déduit alors que l'écart inter-quartile est égal à : $Ec = Q_3 - Q_1$.

h - Étendue de la série

L'étendue de la série statistique est la différence entre la valeur maximale et la valeur minimale de la série.

On a : Étendue = $x_{max} - x_{min}$, avec x_{max} et x_{min} respectivement la valeur maximale et minimale.

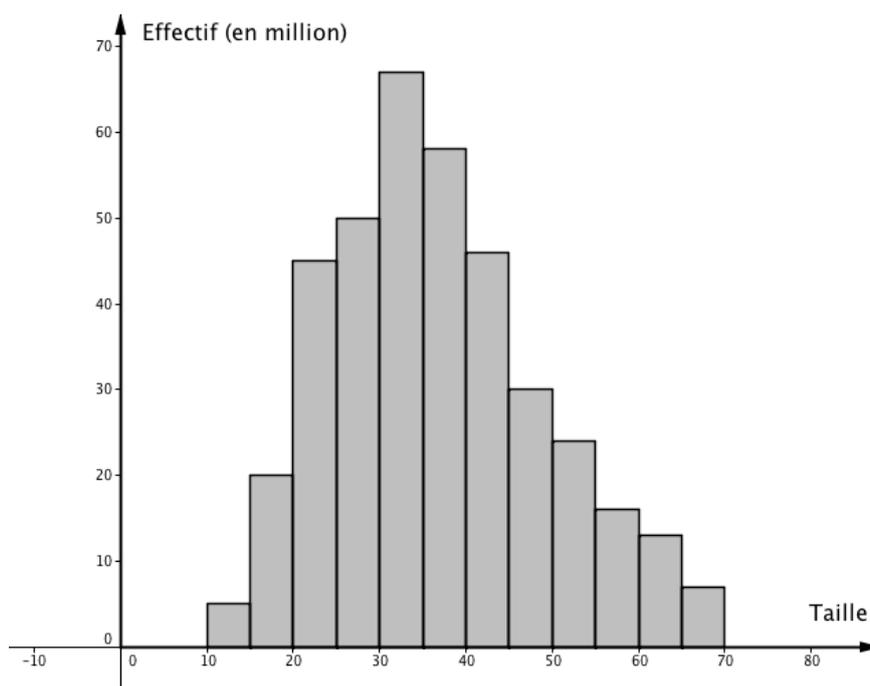
II - Histogramme

L'histogramme est un graphique qui permet de représenter la répartition d'une variable continue.

Voici un exemple de la représentation d'un histogramme :

Taille	[40 ; 45]	[45 ; 50]	[50 ; 55]	[55 ; 60]	[60 ; 65]	[65 ; 70]
Effectif (en million)	46	30	24	16	13	7

Taille	[10 ; 15]	[15 ; 20]	[20 ; 25]	[25 ; 30]	[30 ; 35]	[35 ; 40]
Effectif (en million)	5	20	45	50	67	58

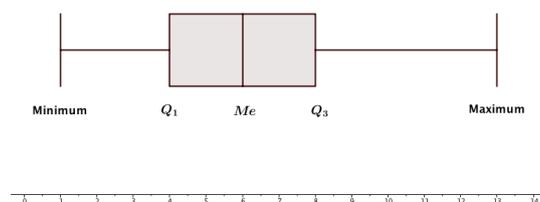


III - Diagramme en boîte

Le diagramme en boîte permet d'avoir une vue d'ensemble de la série statistique étudiée. Il est également appelé *boîte à moustache* ou encore le *diagramme de Tuckey* (nom de l'inventeur, 1977).

Méthode de construction :

Sur l'axe horizontal (ou vertical), on place (dans le même ordre) les valeurs suivantes : le minimum (x_{min}), le premier quartile (Q_1), la médiane (Me), le troisième quartile (Q_3) et le maximum (x_{max}).



Interprétation du diagramme en boîte :

- Si l'intervalle inter-quartiles est petit, les valeurs du "milieu" sont homogènes (proches). Dans le cas contraire les valeurs sont hétérogènes (dispersées).
- Plus les moustaches (l'étendue) sont grandes, plus les valeurs sont dispersées ; plus c'est petit, moins les valeurs sont dispersées.
- L'axe est orienté de gauche à droite. Plus la boîte est à gauche, plus les valeurs sont petites ; plus la boîte est à droite, plus les valeurs sont grandes.
- La symétrie du diagramme en boîte illustre une bonne répartition des valeurs de la série statistique.