

Statistiques Descriptives – 2nde

A) Généralités en Statistiques

1) Vocabulaire statistique

Définitions : On donne les différentes bases de vocabulaire

- **Population :** Ensemble avec lequel on travaille les données
- **Échantillon :** extraction d'individus de la population
- **Caractère :** type d'élément que l'on étudie
 - **qualitatif :** la variable étudiée n'est pas numérique
 - **quantitatif :** la variable étudiée est numérique
 - **discret :** les variables sont des entiers naturels
 - **continu :** les variables sont des nombres réels
- **Effectif :** valeur associée à une variable donnée
- **Effectif total :** ensemble des valeurs de la population

Exemples :

- Le nombre de frères et sœurs d'un élève de seconde : quantitatif discret
- La taille des élèves de seconde : quantitatif continu
- La couleur des yeux des élèves de 2nde : qualitatif
- Le mois de naissance des élèves de 2nde : quantitatif discret
- Le type de loisir des élèves de 2nde : qualitatif

2) Représentations graphiques

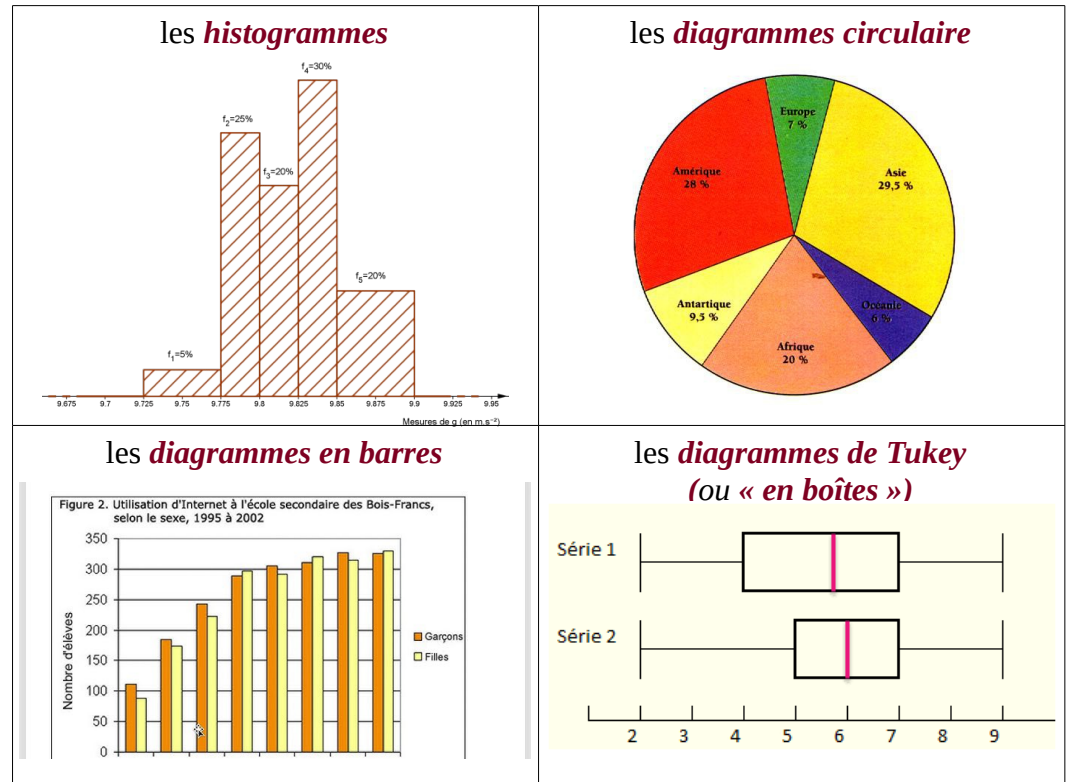
Définition : On donne les différents types de graphiques utilisés en statistique

- Le **diagramme circulaire :** utilisé pour comparer des caractères qualitatifs
- L'**histogramme :** utilisé pour comparer des caractères quantitatifs continus
- Le **diagramme en barres :** utilisé pour comparer des caractères quantitatifs discrets (avec une ou plusieurs séries)
- Le **diagramme de Tukey :** utilisé pour comparer des caractères quantitatifs discrets (avec une ou plusieurs séries)

Exemples : Déterminer quels types de diagrammes est le plus adapté

- Le nombre de frères et sœurs d'un élève de seconde : diagramme en barres
- La taille des élèves de seconde : histogramme
- La couleur des yeux des élèves de 2nde : diagramme circulaire
- Le mois de naissance des élèves de 2nde : diagramme en barres
- Le type de loisir des élèves de 2nde : diagramme de Tukey

Les différents types de graphiques sont :



B) Les paramètres de position

1) Les moyennes

Définition : On étudie ici uniquement les moyennes de type arithmétiques

- Si les valeurs $x_1, x_2, x_3, \dots, x_n$ sont dites simples alors la **moyenne**

arithmétique simple est $\bar{x} = \frac{1}{n} \cdot \sum_{i=1}^n x_i$

- Si les valeurs $x_1, x_2, x_3, \dots, x_p$ sont pondérées par les coefficients $n_1, n_2, n_3, \dots, n_p$ alors la **moyenne arithmétique pondérée** est

$\bar{x} = \frac{1}{N} \cdot \sum_{i=1}^p n_i \cdot x_i$ où $N = \sum_{i=1}^p n_i$ correspond à la somme des coefficients

Exemples : Calculer les moyennes de notes obtenues par 3 élèves :

- Jérôme : 4 ; 6 ; 18 ; 7 ; 17 ; 12 ; 12 ; 18
- Bertrand : 13 ; 13 ; 12 ; 10 ; 12 ; 3 ; 14 ; 12 ; 14 ; 15
- Julie : 15 ; 9 ; 14 ; 13 ; 10 ; 12 ; 12 ; 11 ; 10

exemple : Calculer les moyennes des notes coefficientées par 3 élèves :

- Jérôme : (4;1) ; (6;2) ; (18;1) ; (7;1) ; (17;2) ; (12;1) ; (12;2) ; (18;1)
- Bertrand : (13;1) ; (13;2) ; (12;1) ; (10;2) ; (12;1) ; (3;2) ; (14;1) ; (12;1) ; (14;1) ; (15;1)
- Julie : (15;1) ; (9;2) ; (14;1) ; (13;1) ; (10;2) ; (12;1) ; (12;1) ; (11;1) ; (10;2) ; (11;1)

Comparer ces 3 élèves en calculant leur moyennes arithmétiques respectives

2) Les quartiles


Méthode : Calculer une médiane

Vidéo : <https://youtu.be/kr90dXv0NFY>

Voici les séries de notes obtenues par 3 élèves :

- Jérôme : 4 ; 6 ; 18 ; 7 ; 17 ; 12 ; 12 ; 18
- Bertrand : 13 ; 13 ; 12 ; 10 ; 12 ; 3 ; 14 ; 12 ; 14 ; 15
- Julie : 15 ; 9 ; 14 ; 13 ; 10 ; 12 ; 12 ; 11 ; 10

Calculer la médiane pour Jérôme, Bertrand et Julie.



Définition : Soit $x_1, x_2, x_3, \dots, x_p$ valeurs pondérées par les coefficients

$n_1, n_2, n_3, \dots, n_p$ alors on définit les 3 quartiles de la série :

- le **1er quartile** Q_1 correspond à la valeur de $x_{N/4}$
- le **2eme quartile** Q_2 correspond à la valeur de $x_{N/2}$
- le **3eme quartile** Q_3 correspond à la valeur de $x_{3N/4}$

Rque : On peut par prolongement définir également les **déciles**, les **centiles**, ...
Par ailleurs, il est évident que la médiane est égale au 2eme quartile

exemples : déterminer les quartiles des 4 séries ci-dessous

Série A

x_i	7	8	9	10	12	14	15	17
n_i	2	3	1	4	2	1	3	1

Série B

x_i	7	8	9	10	12	14	15	17
n_i	1	3	4	5	1	1	2	1

Série C

x_i	7	8	9	10	12	14	15	17
n_i	2	4	1	3	1	4	1	3

Série D

x_i	7	8	9	10	12	14	15	17
n_i	3	2	2	3	4	3	2	1

Réponses : on obtient les résultats suivants


- Série A : $Q_1=8$; $Q_2=10$; $Q_3=14,5$
- Série B : $Q_1=9$; $Q_2=10$; $Q_3=12$
- Série C : $Q_1=8$; $Q_2=10$; $Q_3=14$
- Série D : $Q_1=8,5$; $Q_2=10,5$; $Q_3=14$

Rque : le **2eme quartile** s'appelle aussi la **médiane** puisque $\frac{N}{2} = \frac{2N}{4}$


3) Le diagramme de Tukey

Définition : Il existe 2 types de diagrammes « en boîtes »

- Le diagramme en boîtes « sans valeur aberrante »



- Le diagramme en boîtes « avec valeurs aberrantes »




avec $D_1=Q_1-1,5(Q_3-Q_1)$ et $D_9=Q_3+1,5(Q_3-Q_1)$

Exemple : On donne la série statistique suivante ; construire les 2 types de diagrammes de Tukey

x_i	6	7	9	11	12	13	15	18
n_i	2	3	2	4	1	0	0	1

On obtient :



Interprétation : On remarque que le diagramme de Tukey incluant les « Outliers » est beaucoup plus précis car il met en évidence des cas particuliers

C) Les paramètres de dispersion

1) Les écarts de bases

Définition : Soit $x_1, x_2, x_3, \dots, x_p$ valeurs pondérées par les coefficients $n_1, n_2, n_3, \dots, n_p$ alors on a 2 types d'écarts « basiques » :

- l'étendue est : $e = \text{Max}(x_i) - \text{Min}(x_i)$
- l'écart inter-quartile est $IQR = Q_3 - Q_1$

Exemple : On donne la série statistique suivante ; calculer l'étendue et l'écart inter-quartile ; On obtient :

x_i	6	7	9	11	12	13	15	18
n_i	2	3	2	4	1	0	0	1

$$e = 18 - 6 = 12 \quad \text{et} \quad IQR = 11 - 7 = 4$$

2) La Variance & écart-type

Définition : Soit $x_1, x_2, x_3, \dots, x_p$ valeurs pondérées par les coefficients $n_1, n_2, n_3, \dots, n_p$ alors on a :

- la Variance est $V = \frac{1}{N} \cdot \sum_{i=1}^p n_i \cdot (x_i)^2 - (\bar{x})^2$
- l'écart-type est $\sigma = \sqrt{V}$

exemple : Soit la série suivante :

$$V = \frac{2161}{18} - 10,5^2 \approx 9,8056$$

$$\sigma = \sqrt{9,8056} \approx 3,13$$

x_i	6	7	9	11	12	13	15	18
n_i	2	3	2	5	2	2	1	1

Rque : l'écart-type correspond alors à la moyenne quadratique des valeurs de la série $(x_i; n_i)$ soit $\sigma = \sqrt{\frac{1}{N} \cdot \sum_{i=1}^p n_i \cdot (x_i - \bar{x})^2}$; on trouve $\sigma = \sqrt{9,81} \approx 3,13$

exercice : On reprend les 4 Séries **A, B, C, D** précédentes

Série A

x_i	7	8	9	10	12	14	15	17
n_i	2	3	1	4	2	1	3	1

Série B

x_i	7	8	9	10	12	14	15	17
n_i	1	3	4	5	1	1	2	1

Série C

x_i	7	8	9	10	12	14	15	17
n_i	2	4	1	3	1	4	1	3

Série D

x_i	7	8	9	10	12	14	15	17
n_i	3	2	2	3	4	3	2	1

- Calculer les moyennes des 4 séries
- Calculer les variances des 4 séries
- Calculer les écarts-type des 4 séries
- Interpréter les résultats

Réponses :

Série A :	Série B :	Série C :	Série D :
$\bar{x} = 11$	$\bar{x} \approx 10,56$	$\bar{x} \approx 11,53$	$\bar{x} = 11,1$
$V \approx 9,53$	$V \approx 7,60$	$V \approx 12,06$	$V = 8,79$
$\sigma \approx 3,18$	$\sigma \approx 2,77$	$\sigma \approx 3,48$	$\sigma \approx 3,04$

Interprétations : On peut effectuer le classement suivant des 4 séries

- la meilleure série est la série C
- la série la plus régulière (ou homogène) est la série B
- le classement est donc : C - D - B - A

Rque : En statistique comme dans de nombreux domaines on privilégie la qualité de « régularité » au lieu de la qualité de « performance »