

Fiche n°6

**INTERPRETER, REPRESENTER et TRAITER
DES DONNEES STATISTIQUES****I. Introduction : de l'importance des statistiques et des probabilités ?**

Les **statistiques** représentent le domaine des mathématiques qui permet d'**étudier des données réelles** que l'on a obtenues :

- soit par un **recensement** (recueil complet de toutes les données, sur toute la population étudiée) : ceci permet une image précise de ce que l'on désire observer mais pose des problèmes techniques évident s'il y a un grand nombre de données ;
- soit par l'étude d'**échantillons** (recueil de données que sur une partie seulement de la population à étudier : par exemple, sondages...) : ceci présente donc quelques possibilités d'erreur (incertitude) qu'il faut minimiser.

A ne pas confondre avec les **probabilités** qui proposent des modèles **pour prévoir sans avoir expérimenté** le résultat d'expérience dans lequel intervient le **hasard**...

Quelques repères dans le temps...

- Les premiers relevés d'hommes et de bien ont eu lieu **vers 3000 ans avant J.-C. en Mésopotamie** ;
- **L'Égypte des pharaons** organisait régulièrement des recensements notamment pour les impôts ;
- **Tycho Brahe** (1546-1601), astronome danois, utilise la moyenne arithmétique pour réduire les erreurs d'observations ;
- Premières analyses de situation de probabilité vers le XVII^e siècle : **Pierre de Fermat, Blaise Pascal**... ;
- Au XVIII^e et XIX^e siècle se développe la **théorie des erreurs** ;
- Essor à partir XX^e siècle :
 - En statistiques, les **ordinateurs** permettent de **nombreuses simulations**...
 - En probabilités, développement de la théorie actuelles des probabilités...

Quelle utilité dans le monde contemporain ?

- **Pour trouver et décrire une relation** : en médecine, on établit le risque cardiovasculaire lié au tabac en étudiant le pourcentage de fumeurs chez les cardiaques et le pourcentage de cardiaques chez les fumeurs et les non-fumeurs ;
- **Prendre une décision** : l'amélioration annuelle des semences de céréales par croisements successifs, les contrôles de fabrication et de fiabilité dans l'industrie, d'efficacité d'un médicament, etc. sont très dépendants des tests statistiques ;
- **Prévoir et planifier** : de nombreuses statistiques économiques sont publiques (INSEE) et servent par exemple de base aux négociations syndicales ou intergouvernementales.

Exemples de questions d'actualités :

- **Climat** : assiste-t-on à un réchauffement de la planète ?
- **Santé** : faut-il encore vacciner les enfants contre la variole ? faut-il mettre en quarantaine une population lors d'une pandémie comme le « Coronavirus Covid-19 » ?
- **Paris sportifs** : une activité à risques ?
- **Qualité industrielle** : comment faire pour être « sûr » que dans un lot de 1000 piles électriques vendues, il y en a au moins 995 qui fonctionnent correctement ?
- **Météo** : fera-t-il beau dimanche ?
- **Population** : quel pays aura le plus d'habitant en 2020 ?

II. Graphiques : comment choisir une bonne représentation ?





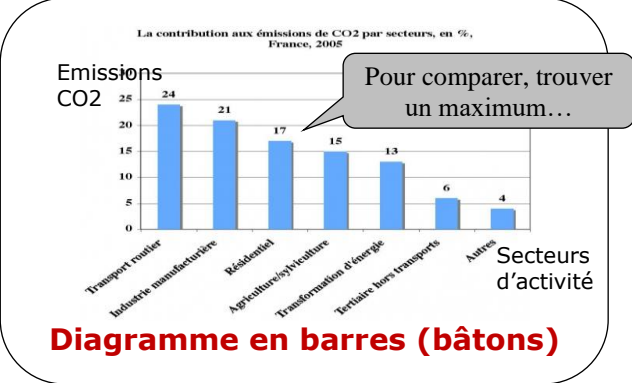

On peut représenter des données avec plusieurs graphiques selon :

- ce que l'on souhaite observer : le **caractère** ;
- ce que l'on souhaite montrer grâce au graphique : pour comparer des **effectifs**, pour répartir des **fréquences** ou pour **regrouper des données** (histogramme).


Quel type de **caractère** dois-je étudier et observer ?

Caractères numériques
(nombres ordonnés > axe des abscisses)
Exemples : âge, temps ou durée, masse, notes d'un contrôle, prix ou salaires, etc.

Caractères qualitatifs
Exemples : couleur des yeux, boisson préférée, langue parlée, secteurs d'activités, jours de la semaine, etc.



Remarque On peut parfois comparer deux caractères sur un même graphique. Par exemple, ce graphique ci-contre permet de comparer des populations entre proies (campagnols) et prédateurs (belettes).



III. Effectifs et fréquences


1. Effectifs

Le tableau ci-contre donne la répartition des **effectifs** des élèves dans un collège dont l'**effectif total** est de 607 élèves.

	6 ^{ème}	5 ^{ème}	4 ^{ème}	3 ^{ème}	Total
Effectifs	162	181	163	101	607

Exemple L'effectif des 5^{èmes} est de 181 élèves.

Graphique On peut représenter ces effectifs par un diagramme en barres où la hauteur de chaque barre est proportionnelle à l'effectif qu'elle représente.



2. Fréquences (et pourcentages)

Définition

$$\text{Fréquence} = \frac{\text{effectif}}{\text{effectif total}}$$

	6 ^{ème}	5 ^{ème}	4 ^{ème}	3 ^{ème}	Total
Effectifs	162	181	163	101	607
Fréquences	0,267	0,298	0,268	0,167	1

Exemple

La fréquence des élèves de 3^{ème} dans ce collège est 0,167 environ car $\frac{101}{607} \approx 0,167$

A savoir ✕ Une fréquence est un nombre compris entre 0 et 1.

✕ **Fréquence en %** = $\frac{\text{effectif}}{\text{effectif total}} \times 100$

On obtient alors :

	6 ^{ème}	5 ^{ème}	4 ^{ème}	3 ^{ème}	Total
Effectifs	162	181	163	101	607
Fréquences (en %)	26,7	29,8	26,8	16,7	100


Exemple

Le pourcentage de 4^{ème} dans ce collège est 26,8 % environ car $\frac{163}{607} \times 100 \approx 26,8$

A savoir Dans un **diagramme circulaire**, la mesure de chaque angle est proportionnelle à l'effectif ou la fréquence qu'il représente.

Mesure d'un angle (en degrés) = $\frac{\text{effectif}}{\text{effectif total}} \times 360$

	6 ^{ème}	5 ^{ème}	4 ^{ème}	3 ^{ème}	Total
Effectifs	162	181	163	101	607
Mesures (en degrés)	96	107	97	60	360



Exemple

L'angle représentant les 5^{èmes} mesure 107° environ car $\frac{181}{607} \times 360 \approx 107$

IV. Moyenne pondérée d'une série statistique

EXERCICE TYPE 1

On a interrogé plusieurs personnes sur leur taille : les résultats ont été reportés sur un tableur dans la feuille de calcul suivante.

	A	B	C	D	E	F
1	Taille (en m)	1,70	1,75	1,80	1,85	Total
2	Effectif	3	6	4	2	15
3	Fréquence (en %)					100

- Quelle formule permet de calculer le nombre total de personnes interrogées ?
- Quel est le pourcentage de personnes mesurant au moins 1m80 ?
 - Dans la cellule B3, quelle formule permet de calculer le pourcentage de personne mesurant 1m70 ?
- La formule « =MOYENNE(B1:E1) » permet-elle de calculer la taille moyenne pour ce groupe de personnes ?
 - Calculer la taille moyenne pour ce groupe de personnes.

Solution

- La formule permettant de calculer le nombre total de personnes interrogées est :

=SOMME(B2:E2)

Sur tableur, dans une formule, le symbole « : » (deux points) signifie « jusqu'à ».

Par exemple, **B2:E2** signifie de **B2** jusqu'à **E2**...

- Il y a $4+2 = 6$ personnes mesurant au moins 1m80 (c'est-à-dire 1m80 ou plus).

$$\frac{\text{effectif}}{\text{effectif total}} \times 100 = \frac{6}{15} \times 100 = 40.$$

40 % des personnes interrogées mesurent au moins 1m80.

- La formule permettant de calculer le pourcentage de personne mesurant 1m70 est : **=B2/15*100**
- Non, la formule « =MOYENNE(B1:E1) » ne permet pas de calculer la taille moyenne pour ce groupe de personnes car elle ne prend pas en compte les effectifs.
 - $1,70 \times 3 + 1,75 \times 6 + 1,80 \times 4 + 1,85 \times 2 = 26,5$ et $26,5 \div 15 \approx 1,766$
La taille moyenne de ce groupe de personnes est **environ 1,77 m.**

EXERCICE TYPE 2

Tailles entre 1,80 m compris et 2 m non compris

Déterminer la taille moyenne des élèves de cette classe :

Taille (en m)	[1,50 ; 1,60[[1,60 ; 1,70[[1,70 ; 1,80[[1,80 ; 2[Total
Centre	$(1,50 + 1,60) \div 2 = 1,55$	$(1,60 + 1,70) \div 2 = 1,65$	$(1,70 + 1,80) \div 2 = 1,75$	$(1,80 + 2) \div 2 = 1,90$	
Effectif	3	13	8	2	26

Solution Pour des données regroupées, on utilise le **centre** de l'intervalle pour calculer la moyenne (voir les calculs dans le tableau)

$$1,55 \times 3 + 1,65 \times 13 + 1,75 \times 8 + 1,90 \times 2 = 43,9 \text{ et } 43,9 \div 26 \approx 1,69$$

La taille moyenne des élèves de la classe est **environ 1,69 m.**

V. Médiane d'une série statistique

Définition La **médiane** d'une série ordonnée est **une valeur** telle qu'il y ait **autant de valeurs inférieures** ou égales **que de valeurs supérieures** ou égales.

EXERCICE TYPE 3 Déterminer les médianes des séries de notes suivantes.

- série A : 13, 13, 20, 19, 18, 15, 15
- série B : 8, 8, 9, 12, 15, 17, 12, 11, 14, 14
- série C : 17, 14, 3, 16, 5, 17

Solution Pour déterminer une médiane, **il faut d'abord ordonner la série.**

- série A : $13 \leq 13 \leq 15 \leq \boxed{15} \leq 18 \leq 19 \leq 20$. La médiane de cette série est **15**.
 $\xleftarrow{3 \text{ notes}} \qquad \qquad \qquad \xleftarrow{3 \text{ notes}}$

- série B : $8 \leq 8 \leq 9 \leq 11 \leq \boxed{12 \leq 12} \leq 14 \leq 14 \leq 15 \leq 17$. La médiane est **12**.
 $\xleftarrow{5 \text{ notes}} \qquad \qquad \qquad \xleftarrow{5 \text{ notes}}$

- série C : $3 \leq 5 \leq \boxed{14 \leq 16} \leq 17 \leq 17$.
 $\xleftarrow{3 \text{ notes}} \qquad \qquad \qquad \xleftarrow{3 \text{ notes}}$

La médiane de cette série est entre 14 et 16. Par habitude, on prendra alors la valeur centrale : la médiane de cette série C est donc **15**.

- Remarques**
- ✕ Deux séries peuvent avoir la même moyenne mais pas la même médiane (séries B et C).
 - ✕ Deux séries peuvent avoir la même médiane mais pas la même moyenne (séries A et C).

	Série A	Série B	Série C
Médiane	15	12	15
Moyenne	$\approx 16,1$	12	12

VI. L'étendue

Définition L'**étendue** d'une série est la différence entre les deux valeurs extrêmes.

EXERCICE TYPE 4 Déterminer l'étendue des séries A, B et C de l'exercice type 3.

- Solution**
- série A : $20 - 13 = 7$. L'étendue de cette série est 7.
 - série B : $17 - 8 = 9$. L'étendue de cette série est 9.
 - série C : $17 - 3 = 14$. L'étendue de cette série est 14.

Remarque

- ✕ La moyenne et la médiane donnent des informations sur la **position** et la répartition des valeurs.
- ✕ L'étendue donne uniquement des informations sur la **dispersion**, mais pas sur la répartition entre la valeur minimale et la valeur maximale.

VII. SITUATIONS STATISTIQUES (EXERCICES BILAN CYCLE 4)

EXERCICE TYPE 5

Une enquête a été réalisée dans une classe de 4^e : ses résultats sont indiqués dans le diagramme ci-contre.

1. Déterminer le nombre de personnes :

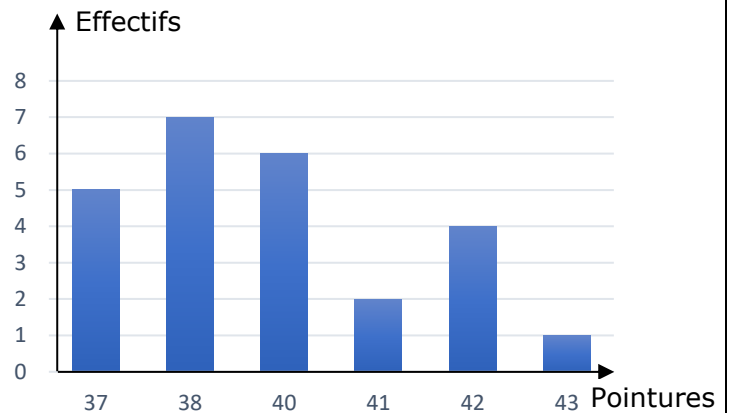
- chaussant moins de 40.
- chaussant au moins du 41.

2. Quel est le pourcentage de personnes chaussant du 38 ?

3. Déterminer la pointure moyenne de ce groupe de personnes.

4. Thibaut affirme que, dans cette étude, la médiane est 39.

A-t-il raison ? Justifier.



Solution

- Les personnes chaussant moins de 40 sont celles dont la pointure est 37, 38 ou 39 : il y a donc $5 + 7 =$ **12 personnes chaussant moins de 40**.
 - Les personnes chaussant au moins du 41 sont celles dont la pointure est 41, 42 ou 43 : il y a donc $2 + 4 + 1 =$ **7 personnes chaussant au moins du 41**.

2. Il y a 7 de personnes chaussant du 38.

Au total, il y a $5 + 7 + 6 + 2 + 4 + 1 = 25$ collégiens interrogés.

$$\frac{\text{effectif}}{\text{effectif total}} \times 100 = \frac{7}{25} \times 100 = 28.$$

28 % des personnes interrogées chaussent du 38.

3. Pour calculer la pointure moyenne de ce groupe de personnes, il faut absolument tenir compte des effectifs dans chaque pointure...

$$37 \times 5 + 38 \times 7 + 40 \times 6 + 41 \times 2 + 42 \times 4 + 43 \times 1 = 984$$

$$984 \div 25 = 39,36$$

La pointure moyenne de ce groupe de personnes est 39,36.

4. Thibaut affirme que, dans cette étude, la médiane est 39. D'après la définition de la médiane, cela signifierait qu'il y a autant de personnes ayant une pointure inférieure ou égale à 39 que de personnes ayant une pointure supérieure ou égale à 39...

Comme il y a 12 personnes ayant une pointure inférieure ou égal à 39 mais 13 ayant une pointure supérieure ou égal à 39, **la pointure 39 ne peut pas être une médiane de cette série statistique.**

Remarque : dans cet exemple, la médiane de la série est la pointure 40. En effet, comme il y a 25 personnes interrogées et que $25 \div 2 = 12,5$, la médiane devra être la 13^{ème} valeur de la série ordonnée pour qu'il y ait 12 valeurs inférieures ou égal et 12 valeurs supérieures ou égales... La médiane de cette série est donc 40.

EXERCICE TYPE 6

Une enquête a été réalisée auprès de 2 500 personnes à partir de la question suivante :

« A quel âge avez-vous trouvé un emploi correspondant à votre qualification ? ».

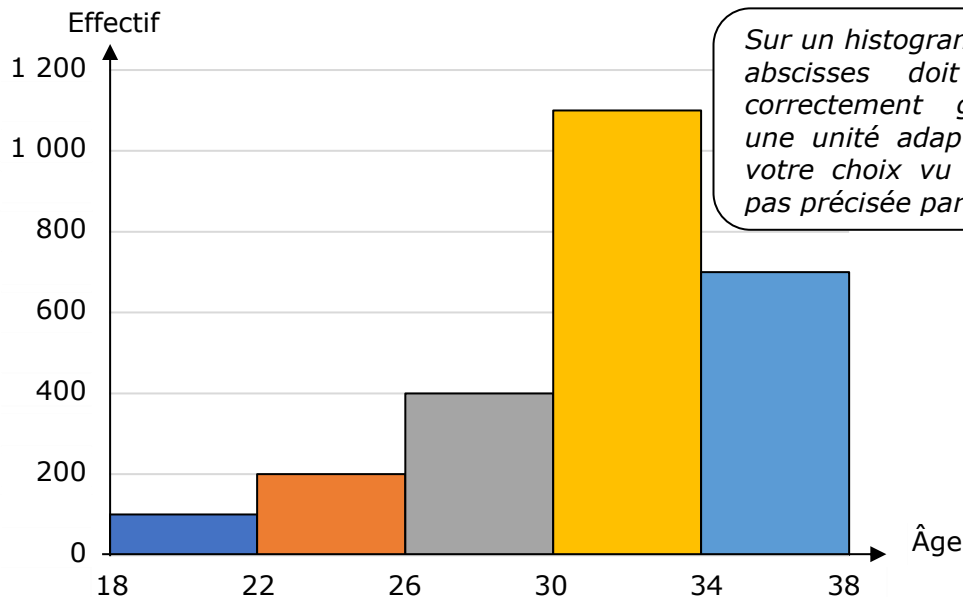
Les résultats de l'enquête ont été reportés sur un tableur dans la feuille de calcul suivante.

	A	B	C
1	Âge	Centre	Effectif
2	[18 ; 22[100
3	[22 ; 26[200
4	[26 ; 30[400
5	[30 ; 34[1 100
6	[34 ; 38[700
7	Total		2 500

- Représenter les résultats de cette enquête par un histogramme.
- Dans la cellule C7, quelle formule permet de calculer le nombre total de personnes interrogées ?
- Compléter la colonne B de cette feuille de calcul.
 - La formule « =MOYENNE(B2:B6) » permet-elle de calculer l'âge moyen de ce groupe de personnes ?
 - Calculer cet âge moyen.
- Est-il vrai que la médiane de cette série statistique est inférieure à 30 ans ? Justifier.

Solution

1.



2. Dans la cellule C7, on calcule le nombre total de personnes interrogées grâce à la formule :

=SOMME(C2:C6)

3. a. On obtient la feuille de calcul ci-contre.

- Non, la formule « =MOYENNE(B2:B6) » ne permet pas de calculer l'âge moyen de ce groupe de personnes car elle ne prend pas en compte les effectifs pour chaque classe d'âge.

c. $20 \times 100 + 24 \times 200 + 28 \times 400 + 32 \times 1100 + 36 \times 700 = 78\,400$

$78\,400 \div 2\,500 = 31,36$

L'âge moyen de ce groupe de personnes est 31,36 ans.

4. Il y a 2 500 personnes interrogées : la moitié des personnes interrogées représente donc 1 250 personnes.

Le nombre de personnes dont l'âge est inférieur à 30 ans est $100+200+400 = 700$.

La médiane de cette série statistique n'est donc pas inférieure à 30 ans puisque 700 ne représente pas la moitié des effectifs (voir définition de la médiane si besoin...).

	A	B	C
1	Âge	Centre	Effectif
2	[18 ; 22[20	100
3	[22 ; 26[24	200
4	[26 ; 30[28	400
5	[30 ; 34[32	1 100
6	[34 ; 38[36	700
7	Total		2 500