

1 Notions de base

1.1 Contexte

Les statistiques descriptives ont pour but de décrire de manière synthétiques les caractéristiques d'un ensemble d'individus. Les individus peuvent être des personnes, mais aussi des objets ou des faits.

1.2 Vocabulaire

Population : ensemble de tous les individus que l'on souhaite étudier.

Chaque élément d'une population s'appelle une **unité statistique**.

Echantillon : ensemble des individus que l'on interroge, ou dont on connaît les informations.

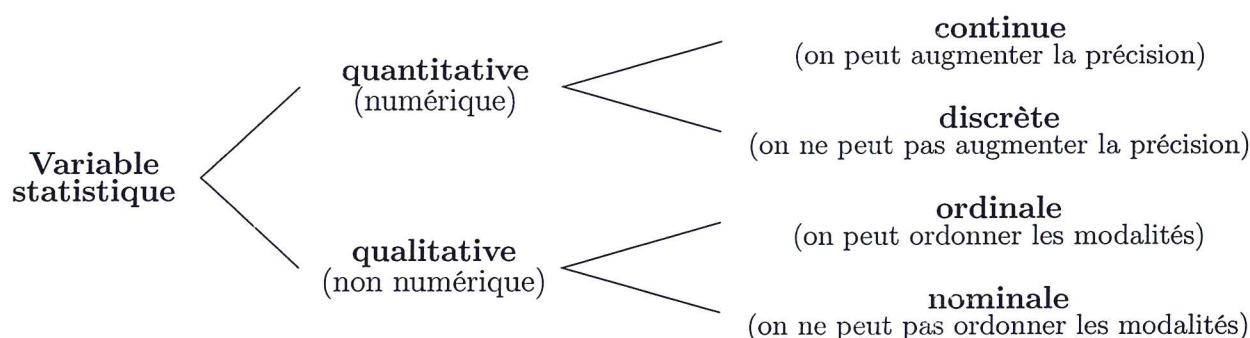
Si l'échantillon est égal à la population entière, on parle d'un **recensement**. Si l'échantillon n'est formé que d'une partie de la population, on parle d'un **sondage**.

Variable statistique : caractéristique que l'on souhaite étudier.

Une variable statistique est dite **quantitative** si les valeurs qu'elle peut prendre sont des nombres. Dans le cas contraire, elle est **qualitative**, et ses valeurs s'appellent des **modalités** ou des **catégories**.

Si les valeurs que peut prendre une variable statistique quantitative peuvent être listées (par exemple 0, 1, 2, 3, ...) et leur précision ne peut pas être augmentée, on dit que la variable est **discrète**. Si la précision des valeurs peut être modifiée (par exemple 2.3 ou 2.31 ou 2.314), on dit qu'elle est **continue**.

Si les valeurs que peut prendre une variable statistique qualitative peuvent être ordonnées (mise dans un certain ordre, par exemple *jamais, parfois, souvent, toujours*), la variable est dite **ordinaire**. Dans le cas contraire, elle est **nominale**.



Exemples

- a) On demande à 200 passagers pris au hasard dans un aéroport de donner leur nationalité.

Population : les passagers d'un aéroport

Echantillon : les 200 passagers

Unité statistique : 1 passager

S'agit-il d'un recensement ou d'un sondage? sondage

Variable statistique : nationalité

Type de variable : qualitative nominale

Modalités ou valeurs : suisse, français, allemand, etc...

- b) Durant tout le mois d'avril, on mesure la température maximale de la journée à la Tour-de-Peilz.

Population : Les jours du mois d'avril

Echantillon = population

Unité statistique : 1 jour

S'agit-il d'un recensement ou d'un sondage? recensement

Variable statistique : température max à la Tour-de-Peilz

Type de variable : quantitative continue

Modalités ou valeurs : $[0^\circ; 30^\circ]$ par exemple

- c) On demande à 5'000 familles résidant en Suisse le nombre d'enfants de leur foyer.

Population : les familles résidant en Suisse

Echantillon : les 5'000 familles interrogées

Unité statistique : 1 famille

S'agit-il d'un recensement ou d'un sondage? sondage

Variable statistique : nombre d'enfants

Type de variable : quantitative discrète

Modalités ou valeurs : 0, 1, 2, 3, ...

- d) A la fin d'une période de révision, un enseignant demande à ses élèves de répondre à la question suivante :

Cette période de révision a-t-elle été utile? pas du tout, un peu beaucoup

Population : les élèves de la classe

Echantillon = population

Unité statistique : 1 élève

S'agit-il d'un recensement ou d'un sondage? recensement

Variable statistique : l'utilité de la période

Type de variable : qualitative ordinale

Modalités ou valeurs : pas du tout, un peu, beaucoup

1.3 Echelles de mesure

On distingue quatre types d'échelles de mesure.

Echelle nominale

Exemple : 0 (homme) 1 (femme) .

- s'utilise pour une variable **qualitative** nominale
- sert uniquement à différencier les catégories d'une variable ($=$, \neq)
- ne permet pas d'établir une relation d'ordre ($<$, $>$)
- ne permet pas d'effectuer d'opération arithmétique ($+$, $-$, \cdot , $:$)

Echelle ordinale

Exemple : 0 (pas du tout) 1 (un peu) 2 (beaucoup)

- s'utilise pour une variable **qualitative** ordinale ou **quantitative**
- sert à différencier les catégories d'une variable ($=$, \neq)
- permet d'ordonner les catégories ($<$, $>$)
- ne permet pas d'effectuer d'opération arithmétique ($+$, $-$, \cdot , $:$)

Echelle d'intervalle

Exemple : les degrés Celsius

- s'utilise pour une variable **quantitative**
- sert à différencier les valeurs d'une variable ($=$, \neq)
- permet d'ordonner les valeurs ($<$, $>$)
- permet d'effectuer des additions / soustractions, mais pas des multiplications / divisions
- la valeur 0 ne signifie pas l'absence de la caractéristique

Echelle de rapport

Exemple : nombre d'enfants dans une famille : 0, 1, 2, ...

- s'utilise pour une variable **quantitative**
- sert à différencier les valeurs d'une variable ($=$, \neq)
- permet d'ordonner les valeurs ($<$, $>$)
- permet d'effectuer les quatre opérations arithmétiques ($+$, $-$, \cdot , $:$)
- la valeur 0 signifie une absence de la caractéristique mesurée

Exemple

Voici quatre manières différentes de mesurer la consommation de cigarettes dans un questionnaire :

1. Fumez-vous des cigarettes?
1. Oui 2. Non

Echelle : nominale

2. A quelle fréquence fumez-vous des cigarettes?
0. Jamais 1. Rarement 2. Occasionnellement 3. Régulièrement

Echelle : ordinale

($1 < 2 \Rightarrow$ rarement $<$ occasionnellement)

3. En moyenne, combien de cigarettes fumez-vous par jour?
1. 0 2. De 1 à 5 3. de 6 à 10 4. de 11 à 20 5. Plus de 20

Echelle : ordinale

6 à 10 $<$ 11 à 20 ✓

$2 + 2 \neq 4 : (1 \text{ à } 5 + 1 \text{ à } 5 \neq 11 \text{ à } 20)$

4. Combien de cigarettes fumez-vous par jour?
.....

Echelle : de rapport

0 : ne fume pas

6 cigarettes/jour est bien le double de 3 cigarettes/jour

1.4 Tableau de distribution

Une fois les données récoltées, on les regroupe par modalité dans un tableau de distribution.

Exemples

- a) On a demandé à tous les élèves d'une classe quelle était leur matière préférée parmi les matières suivantes : français, anglais, maths et musique.

musique français français anglais français
 anglais musique maths musique musique
 musique musique musique français français
 français anglais musique anglais maths

Tableau de distribution :

Répartition des élèves selon leur matière préférée

| | matière | nombre d'élèves | fréquence |
|--|----------|-----------------|-----------------------|
| | français | 6 | $\frac{6}{20} = 30\%$ |
| | anglais | 4 | 20% |
| | maths | 2 | 10% |
| | musique | 8 | 40% |
| | Total | 20 | 100% |

- b) On a demandé à ces mêmes élèves leur dernière note d'anglais.

5 4.5 3.5 5 6 3.5 4 2.5 4 4.5
 4 4.5 4.5 4.5 3 4 4.5 5 3.5 4

Tableau de distribution :

Répartition des élèves selon leur note d'anglais

| note | effectif | fréquence |
|-------|----------|-----------|
| 1 | 0 | 0% |
| 1,5 | 0 | 0% |
| 2 | 0 | 0% |
| 2,5 | 1 | 5% |
| 3 | 1 | 5% |
| 3,5 | 3 | 15% |
| 4 | 5 | 25% |
| 4,5 | 6 | 30% |
| 5 | 3 | 15% |
| 5,5 | 0 | 0% |
| 6 | 1 | 5% |
| Total | 20 | 100% |

c) Enfin, on a demandé à ces élèves leur taille en centimètre.

172 157 162 156 167 179 173 173 178 160
 168 171 165 166 184 170 165 164 160 175

plus petite

plus grande

Il s'agit d'une variable continue, donc il est très rare d'obtenir plusieurs fois la même valeur.

⇒ on regroupe les données par classes.

Tableau de distribution :

Répartition des *élèves* selon *leur taille*.

155 est dans cette classe

160 non

| | taille | nbre d'élèves | fréquence |
|------|------------|---------------|-----------|
| II | [155; 160[| 2 | 10% |
| IIII | [160; 165[| 4 | 20% |
| IIII | [165; 170[| 5 | 25% |
| IIII | [170; 175[| 5 | 25% |
| III | [175; 180[| 3 | 15% |
| I | [180; 185[| 1 | 5% |
| | Total | 20 | 100% |

Aide pour le choix du nombre de classes : Table de Sturges

| Nombre de données | Nombre approximatif de classes |
|-------------------|---------------------------------------|
| Entre 10 et 22 | 5 |
| Entre 23 et 44 | 6 |
| Entre 45 et 90 | 7 |
| Entre 91 et 180 | 8 |
| Entre 181 et 360 | 9 |
| Entre 361 et 720 | 10 |

on a pris 6 classes pour avoir des classes pratiques (4 irait aussi...)

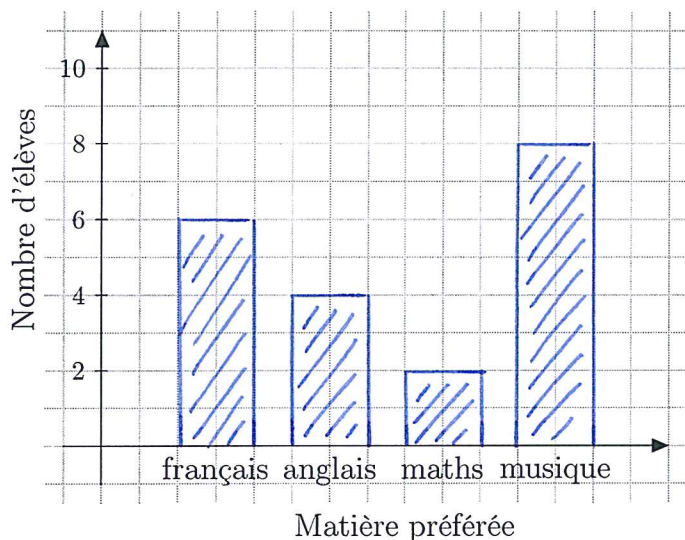
(Formule : $1 + \log_2(n)$)

2 Représentations graphiques

2.1 Représentation graphique d'une variable qualitative


Répartition des 20 élèves d'une classe selon leur matières préférées (exemple p.5).

Diagramme à rectangles




⚠ toujours laisser un espace entre les rectangles !

Diagramme circulaire



| | |
|----------|--------------------------------|
| français | $30/100 = 108^\circ/360^\circ$ |
| anglais | $20/100 = 72^\circ/360^\circ$ |
| maths | $10/100 = 36^\circ/360^\circ$ |
| musique | $40/100 = 144^\circ/360^\circ$ |

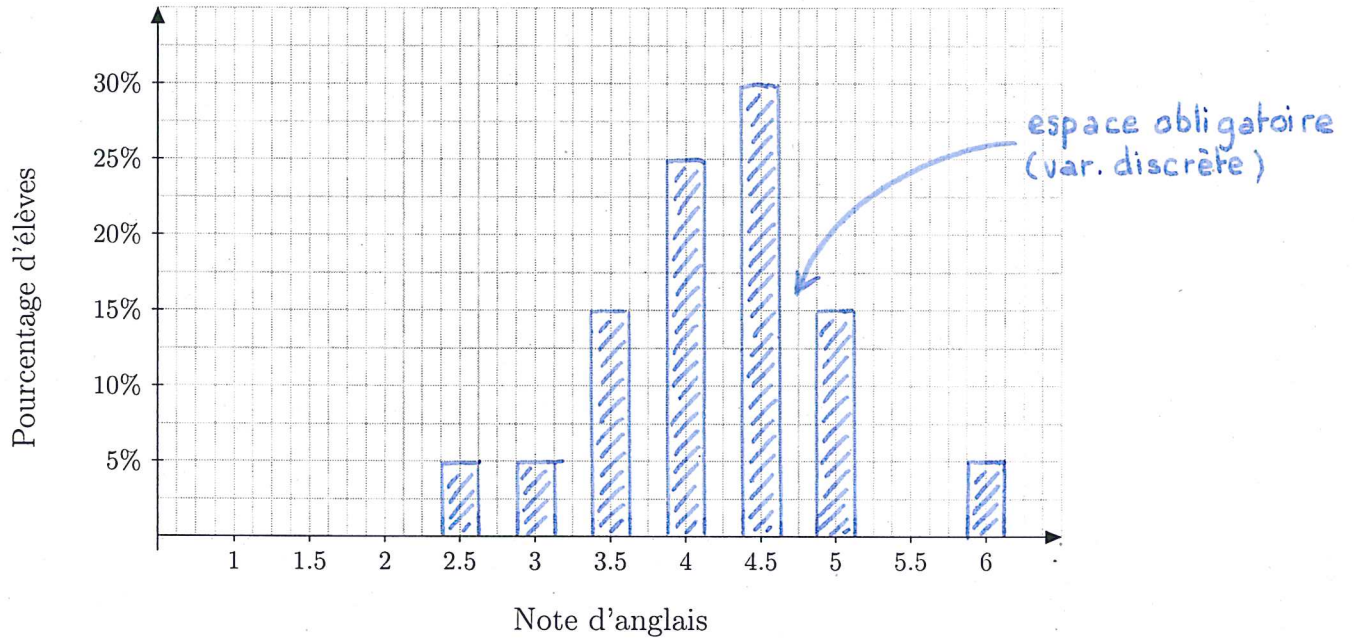
Diagramme linéaire



2.2 Représentation graphique d'une variable quantitative discrète

Répartition des 20 élèves d'une classe selon leur note d'anglais (exemple p.5).

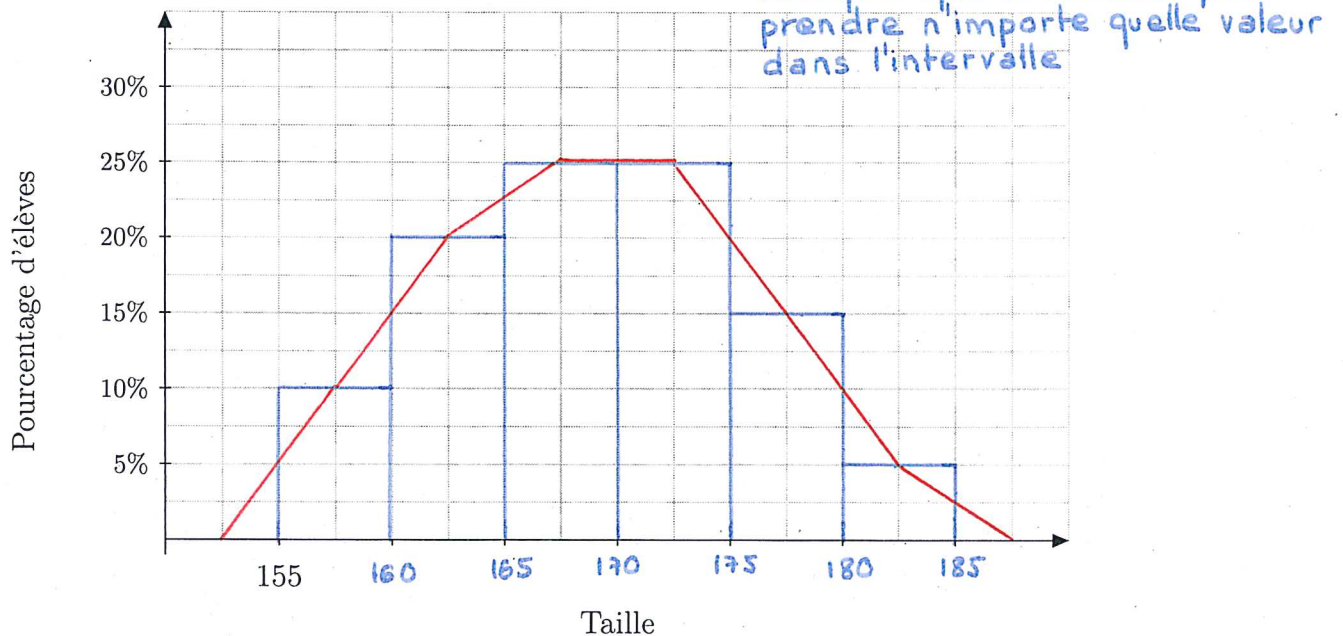
Diagramme en bâtons (ou rectangles)



2.3 Représentation graphique d'une variable quantitative continue

Répartition des 20 élèves d'une classe selon leur taille (exemple p.6).

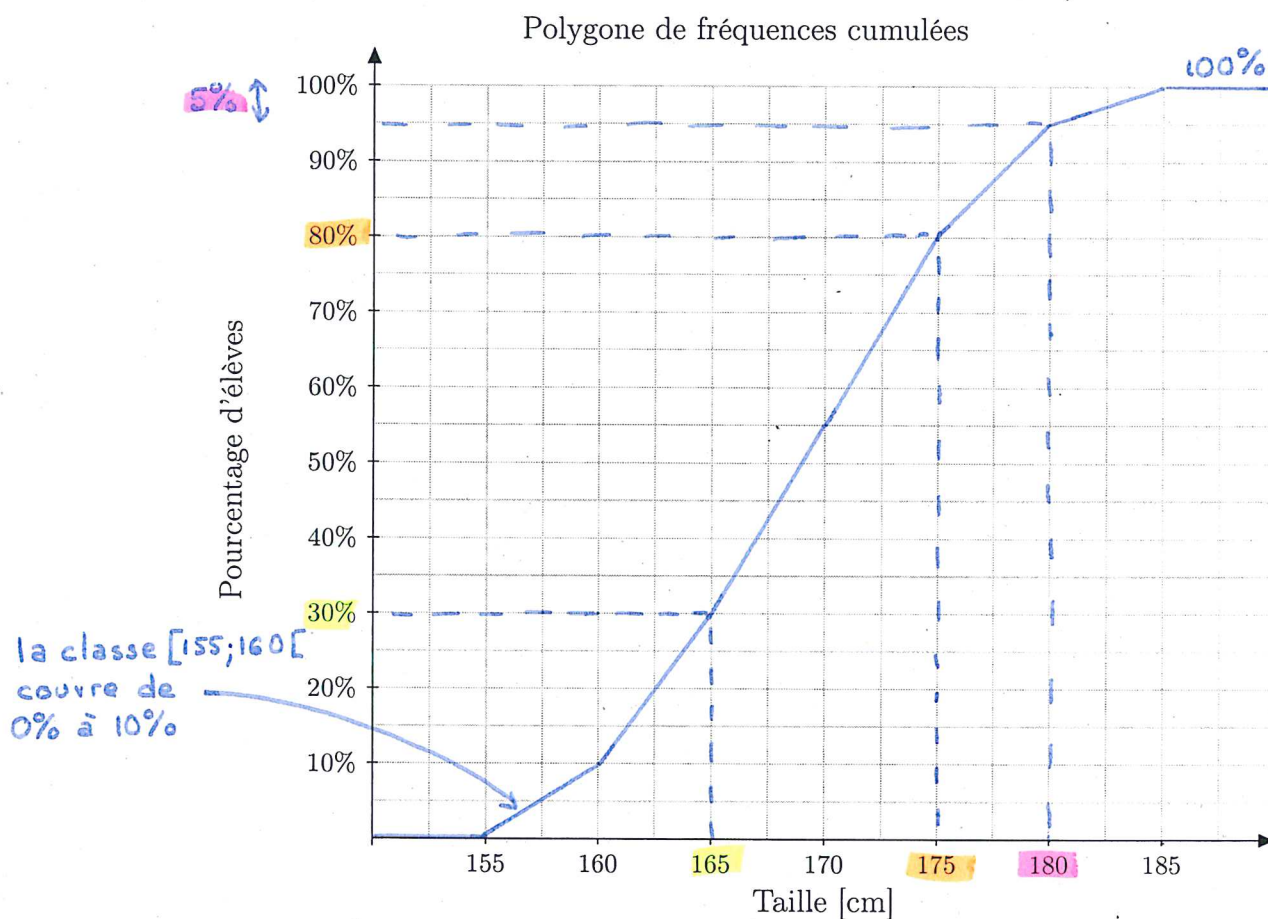
Histogramme et polygone de fréquences



Polygone de fréquences cumulées (ou courbe de fréquences cumulées)

Répartition des élèves selon leur taille

| taille | effectif | fréquence | fréquence cumulée |
|-------------|----------|-----------|-------------------|
| [155 ; 160[| 2 | 10% | 10% |
| [160 ; 165[| 4 | 20% | 10% + 20% = 30% |
| [165 ; 170[| 5 | 25% | 30% + 25% = 55% |
| [170 ; 175[| 5 | 25% | 80% |
| [175 ; 180[| 3 | 15% | 95% |
| [180 ; 185[| 1 | 5% | 100% |
| Total | 20 | 100% | //// |



30% des élèves mesurent moins de 165 cm, ou 1,65 mètre.

80% des élèves mesurent moins de 1,75 mètre.

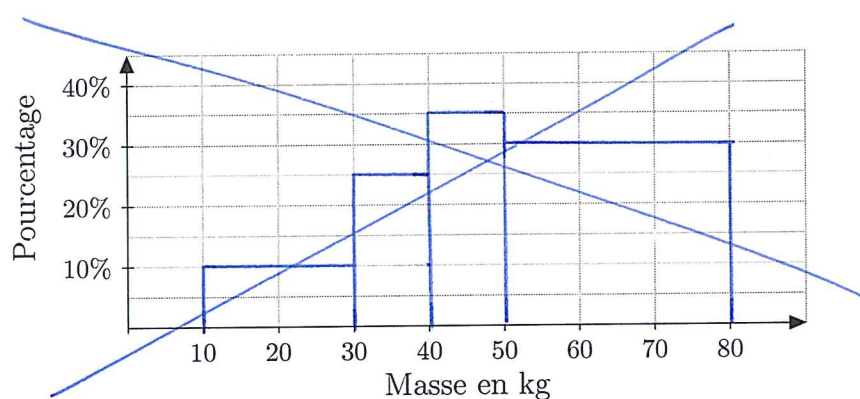
5% des élèves mesurent au moins 180 cm, ou 1,80 mètre.

Histogramme dans le cas de classes inégales

On veut représenter par un histogramme la répartition des roches dans une rocaille de fleurs selon leur masse. Cette répartition est donnée par le tableau suivant :

| masse en kg | pourcentage de roches |
|-------------|-----------------------|
| [10 ; 30[| 10% |
| [30 ; 40[| 25% |
| [40 ; 50[| 35% |
| [50 ; 80[| 30% |
| Total | 100% |

Histogramme obtenu en utilisant directement les fréquences données dans le tableau :

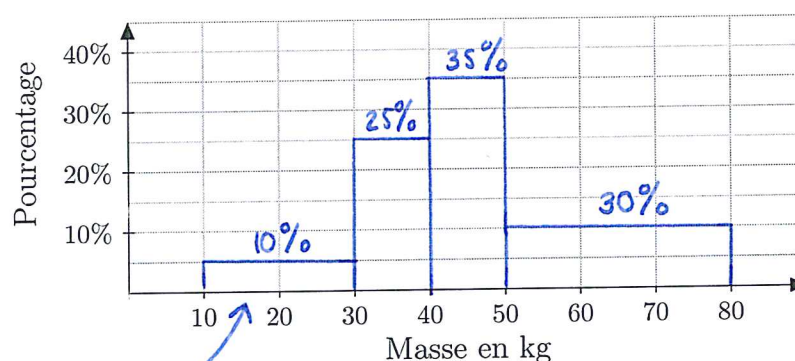


Cet histogramme donne-t-il une information correcte ou faussée? *faussée*.....

Principe de proportionnalité des aires :

*L'aire d'un rectangle doit être proportionnelle au pourcentage.
 (et non la hauteur).....*

Histogramme correct (respectant le principe de proportionnalité des aires) :



*classe 2x plus longue
 => hauteur divisée par 2*

3 Mesures de tendance centrale

But : résumer une série statistique par une seule valeur.

3.1 Moyenne

$$\bar{x} = \frac{x_1 + x_2 + x_3 + \dots + x_n}{n}$$

Exemple 1

On reprend les dernières notes d'anglais des 20 élèves d'une classe (exemple p.5).

5 4.5 3.5 5 6 3.5 4 2.5 4 4.5
4 4.5 4.5 4.5 3 4 4.5 5 3.5 4

Calcul de la moyenne : $\frac{5+4+4,5+4,5+3,5+\dots+4,5+4}{20} = 4,2$

Calculatrice : 5 $\Sigma+$ 4 $\Sigma+$ 4,5 $\Sigma+$... 4 $\Sigma+$ (affiche n=20)
 $\boxed{2nd}$ $\boxed{x^2}$ \bar{x} \Rightarrow donne bien 4,2

Calcul de la moyenne à partir du tableau de distribution (formule plus rapide) :

Répartition des 20 élèves d'une classe selon leur note d'anglais

| note | effectif | fréquence |
|-------------|----------|-----------|
| 1 / 1.5 / 2 | 0 | 0% |
| 2.5 | 1 | 5% |
| 3 | 1 | 5% |
| 3.5 | 3 | 15% |
| 4 | 5 | 25% |
| 4.5 | 6 | 30% |
| 5 | 3 | 15% |
| 5.5 | 0 | 0% |
| 6 | 1 | 5% |
| Total | 20 | 100% |

n: effectif

c: catégorie/valeur/
modalité

$$\bar{x} = \frac{n_1 \cdot c_1 + n_2 \cdot c_2 + \dots + n_k \cdot c_k}{n} = f_1 \cdot c_1 + f_2 \cdot c_2 + \dots + f_k \cdot c_k$$

$$\bar{x} = \frac{1 \cdot 2,5 + 1 \cdot 3 + 3 \cdot 3,5 + \dots + 1 \cdot 6}{20} = 4,2 \quad \text{ou} \quad \bar{x} = 0,05 \cdot 2,5 + 0,05 \cdot 3 + 0,15 \cdot 3,5 + \dots + 0,05 \cdot 6 = 4,2$$

Calculatrice : 2,5 $\boxed{2nd}$ $\boxed{\frac{FRQ}{x}}$ 1 $\boxed{\Sigma+}$...
fréq.

Exemple 2

On reprend les tailles des 20 élèves d'une classe (exemple p.6).

172 157 162 156 167 179 173 173 178 160
168 171 165 166 184 170 165 164 160 175

Calcul direct de la moyenne (à partir des données brutes) :

$$\bar{x} = \frac{172 + 168 + 157 + \dots + 160 + 175}{20} = 168,25 \quad (\cong 168 \text{ cm})$$

Calcul de la moyenne à partir du tableau de distribution :

Répartition des 20 élèves d'une classe selon leur taille

| taille | valeur centrale | effectif | fréquence | fréqu. cum. |
|-------------|-----------------|----------|-----------|-------------|
| [155 ; 160[| 157,5 | 2 | 10% | 10% |
| [160 ; 165[| 162,5 | 4 | 20% | 30% |
| [165 ; 170[| 167,5 | 5 | 25% | 55% |
| [170 ; 175[| 172,5 | 5 | 25% | 80% |
| [175 ; 180[| 177,5 | 3 | 15% | 95% |
| [180 ; 185[| 182,5 | 1 | 5% | 100% |
| Total | | 20 | 100% | |

n : effectif

c : valeur centrale

$$\bar{x} = \frac{n_1 \cdot c_1 + n_2 \cdot c_2 + \dots + n_k \cdot c_k}{n} = f_1 \cdot c_1 + f_2 \cdot c_2 + \dots + f_k \cdot c_k$$

$$\bar{x} = \frac{2 \cdot 157,5 + 4 \cdot 162,5 + 5 \cdot 167,5 + \dots + 1 \cdot 182,5}{20} = 169$$

ou alors

$$\bar{x} = 0,1 \cdot 157,5 + 0,2 \cdot 162,5 + 0,25 \cdot 167,5 + \dots + 0,05 \cdot 182,5 = 169$$

Remarque

La valeur de la moyenne n'est pas la même selon la méthode utilisée. Dans le deuxième cas, on ne dispose plus des données brutes, et on doit donc estimer la valeur de \bar{x} avec l'information disponible.