

## Statistique descriptive à une variable

### 3) Etude du cas d'une variable statistique continue :

Soit  $X$  une variable statistique continue définie sur une population de  $n$  individus et dont les observations sont regroupés en  $k$  classes :  $[e_0, e_1[$ ,  $[e_1, e_2[$ , ...,  $[e_{k-1}, e_k[$  dont les effectifs respectifs  $n_1, n_2, \dots, n_k$ .

**Exemple :** Un échantillon de 50 poissons de la même espèce a fourni les poids suivants (en g) :

Poids (g)	Ampl. $a_i$	Centre $x_i$	Effectif $n_i$	Fréq. $f_i$
[70; 80[	10	75	8	0,16
[80; 90[	10	85	8	0,16
[90; 100[	10	95	12	0,24
[100; 110[	10	105	17	0,34
[110; 120[	10	115	5	0,10
total			50	1


$a_i = e_i - e_{i-1}$  : Amplitude de la classe  $[e_{i-1}, e_i[$ .

$x_i = \frac{e_i + e_{i-1}}{2}$  : centre de la classe  $[e_{i-1}, e_i[$ .

$n_i = \frac{n_i}{n}$  : effectif de la classe  $[e_{i-1}, e_i[$ .

### 3.1 Représentation graphique : Histogramme

A chaque classe  $[e_{i-1}, e_i[$ , on fait correspondre un rectangle de base égale à son amplitude et hauteur proportionnelle à sa fréquence  $f_i$ .



**Remarque :** En reliant les points de coordonnées  $(x_i, f_i)$  par des segments de droites dans l'histogramme, on obtient une courbe dite Polygone des fréquences.

### 3.2 Fréquences cumulées et courbes cumulatives :

$F_i \uparrow = f_1 + \dots + f_i$  dite fréquence cumulée croissante, correspondante à  $[e_{i-1}, e_i[$ , est la proportion des observations inférieure à  $e_i$ .

$F_i \downarrow = f_1 + \dots + f_i$  dite fréquence cumulée décroissante, correspondante à  $[e_{i-1}, e_i[$ , est la proportion des observations supérieur ou égale à  $e_{i-1}$ .

### COURBES CUMULATIVES :

La courbe cumulative croissante (respectivement décroissante) de la variable statistique  $X$  est la représentation graphique de la fonction  $F \uparrow(x) : \mathbb{R} \rightarrow [0,1]$  (respectivement  $F \downarrow(x) : \mathbb{R} \rightarrow [0,1]$ ) définie par

$$F \uparrow(x) = \begin{cases} 0 & \text{si } x < e_0 \\ \frac{f_i}{a_i}(x - e_{i-1}) + F_{i-1} \uparrow & \text{si } x \in [e_{i-1}, e_i[ \\ 1 & \text{si } x \geq e_k \end{cases}$$

$$\text{(Respectivement } F \downarrow(x) = \begin{cases} 1 & \text{si } x \leq e_0 \\ \frac{f_i}{a_i}(e_i - x) + F_{i+1} \downarrow & \text{si } x \in [e_{i-1}, e_i[ \\ 0 & \text{si } x > e_k. \end{cases}$$

### Remarque :

- 1)  $F \uparrow$  et  $F \downarrow$  sont appelées fonctions de répartition de la variable statistique  $X$ .
- 2)  $F \uparrow(x)$  : représente la proportion d'observations qui sont inférieure à  $x$ .
- 3)  $F \uparrow(e_i) = F_i \uparrow$  pour tout  $i = 1, 2, \dots, k$ .
- 4)  $F \downarrow(e_i) = F_{i+1} \downarrow$  pour tout  $i = 0, 1, \dots, (k-1)$ .

### 3.3 Représentation numérique des données :

#### 3.3.1 Paramètres de tendance centrale :

i) **Le MODE :** noté  $M_o$ .

La classe dont la fréquence est la plus élevée est dite classe modale.


Soit  $[e_{i-1}, e_i[$  la classe modale, alors  $M_o \in [e_{i-1}, e_i[$ .

La valeur du mode  $M_o$  peut-être approchée de deux manières :

**Première méthode :**  $M_o = \frac{e_{i-1} + e_i}{2}$  centre de la classe modale.

**Deuxième méthode :** En utilisant la règle de Thales on obtient

$$M_o = e_{i-1} + a_i \frac{\Delta_1}{\Delta_1 + \Delta_2} \quad \text{Où : } \Delta_1 = f_i - f_{i-1} \\ \Delta_2 = f_i - f_{i+1}.$$



**ii) La MEDIANE :** Notée  $M_e$ . Elle vérifie  $F \uparrow (M_e) = F \downarrow (M_e) = \frac{1}{2}$ .

La classe  $[e_{i-1}, e_i[$  est dite classe médiane si  $M_e \in [e_{i-1}, e_i[$ .

**Calcul de la médiane :** soit  $F_{i-1} \uparrow \leq \frac{1}{2} < F_i \uparrow \Rightarrow M_e \in [e_{i-1}, e_i[$ . D'après

la courbe cumulative croissante on obtient :  $\frac{F_i \uparrow - F_{i-1} \uparrow}{e_i - e_{i-1}} = \frac{F \uparrow (M_e) - F_{i-1} \uparrow}{M_e - e_{i-1}} \Rightarrow$

$$\frac{f_i}{a_i} = \frac{0.5 - F_{i-1} \uparrow}{M_e - e_{i-1}} \Rightarrow$$

$$M_e = \frac{a_i}{f_i} (0.5 - F_{i-1} \uparrow) + e_{i-1}$$

En particulier si  $\exists i$  tel que  $F_i \uparrow = 0.5$  alors  $M_e = e_i$ .

**iii) La MOYENNE ARITHMETIQUE :** notée  $\bar{x}$ .

$$\bar{x} = \frac{1}{n} \sum_{i=1}^k n_i x_i$$

où  $x_i = \frac{e_{i-1} + e_i}{2}$  centre de la classe  $[e_{i-1}, e_i[$

et  $n_i$  : l'effectif correspondant à la classe  $[e_{i-1}, e_i[$ .

### 3.3.2 Paramètre de dispersions :

**i) VARIANCE et ECART TYPE :**

$$V(X) = \frac{1}{n} \sum_{i=1}^k n_i (x_i - \bar{x})^2 \quad \text{ou encore } V(X) = \left( \frac{1}{n} \sum_{i=1}^k n_i x_i^2 \right) - \bar{x}^2$$

où  $x_i = \frac{e_{i-1} + e_i}{2}$  centre de la classe  $[e_{i-1}, e_i[$  et  $n_i$  : l'effectif correspondant à la classe  $[e_{i-1}, e_i[$ .  $\bar{x}$  : Moyenne arithmétique de X.

L'écart type de X est défini par :

$$\sigma_X = \sqrt{V(X)}.$$

**ii) INTERVALLE INTERQUARTILES :**

Les quartiles notés,  $Q_1, Q_2, Q_3$  vérifient :

$F \uparrow (Q_1) = 0.25, F \uparrow (Q_2) = F \uparrow (M_e) = 0.5, F \uparrow (Q_3) = 0.75$ .

L'intervalle interquartile est donné par :  $[Q_1, Q_3]$ , il mesure la dispersion des observations autour de la médiane  $M_e$ .

**Calcul du quartile  $Q_1$  :** soit  $F_{i-1} \uparrow \leq 0.25 < F_i \uparrow \Rightarrow Q_1 \in [e_{i-1}, e_i[$ . En procédant de même que pour le cas de la médiane, on obtient :

$$Q_1 = \frac{a_i}{f_i} (0.25 - F_{i-1} \uparrow) + e_{i-1}$$

**Calcul du quartile  $Q_3$  :** soit  $F_{i-1} \uparrow \leq 0.75 < F_i \uparrow \Rightarrow Q_3 \in [e_{i-1}, e_i[$ . En procédant de même que pour le cas de la médiane, on obtient :

$$Q_3 = \frac{a_i}{f_i} (0.75 - F_{i-1} \uparrow) + e_{i-1}$$