

Chapitre 5: Statistique descriptive

I Autour de la médiane:

1. Définition: médiane

Dans une série ordonnée de nombres, la médiane est la valeur qui partage la série en 2 sous-séries de même effectif.

Exemple: Série d'effectif N impair

Exercice 1: a) $1 - 2 - 5 - 5 - 10 - 15 - 29 - 36 - 43$ $N=9$

la série statistique compte autant de valeurs inférieures à 10 que de valeurs supérieures à 10.

b) Série d'effectif N pair

Exemple: $3 - 8 - 9 - 12 - 13 - 15 - 17 - 20 - 23 - 25$ $N=10$ $\frac{N}{2}=5$

$$M_e = \frac{13 + 15}{2} = 14$$

la médiane dans ce cas n'est pas une valeur de la série.

c) $18 - 11 - 2 - 3 - 5 - 21 - 7 - 13$

on commence par ordonner la série: $2 - 3 - 7 - 9 - 11 - 13 - 18 - 21$ $N=8$

$$M_e = \frac{9 + 11}{2} = 10$$

$$\frac{N}{2} = 4$$

2. Quartiles: définition

- On appelle **premier quartile** et on note Q_1 la valeur de la série telle que au moins $\frac{1}{4}$, soit au moins 25% des valeurs de la série lui sont inférieures ou égales.
- On appelle **troisième quartile** et on note Q_3 la valeur de la série telle que au moins $\frac{3}{4}$ soit au moins 75% des valeurs de la série lui sont inférieures ou égales.

• L'**écart interquartiles** d'une série statistique est la différence $Q_3 - Q_1$

Remarque: L'intervalle interquartile $[Q_1; Q_3]$ contient la moitié centrale des valeurs de la série. Plus l'écart interquartile est important, plus les valeurs de la série sont **dispensées** autour de la médiane M_e .

3. Diagramme en boîte (ou boîte à moustade)

On peut résumer graphiquement une série statistique par un diagramme en boîte (boxplot en anglais) sur lequel figurent les indicateurs M_{in} , Q_1 , M_e , Q_3 , M_{ax}

Exemple: construire le diagramme en boîte de la série suivante d'effectif total $N=10$
6; 9; 54; 11; 248; 23; 143; 305; 65; 135

on commence par ordonner la série: x_1 6 - x_2 9 - x_3 11 - x_4 23 - x_5 54 - x_6 65 - x_7 135 - x_8 143 - x_9 248 - x_{10} 305

$$M_e = \frac{54 + 65}{2} = 59,5$$

$$\frac{N}{4} = \frac{10}{4} = 2,5$$


Q_1 est la valeur de la série telle qu'au moins 25% des valeurs de la série lui sont inférieures ou égales.

Au moins 2,5 valeurs, donc au moins 3 valeurs sinon on a moins de 25%. $Q_1 = x_3 = 11$

De même $\frac{3N}{4} = 7,5$ donc $Q_3 = x_8 = 143$.

Au moins 75% des valeurs de la série sont inférieures ou égales à 143.

Min = 6 Max = 305



4. Déciles : définition

on a défini les quantiles en prenant des quarts de l'effectif total de la série.

De la même façon on définit les **déciles** en prenant des dixièmes de l'effectif total.

1^{re} décile, noté D_1 : c'est la valeur de la série telle que **au moins 10%** des valeurs de la série lui sont inférieures ou égales.

9^e décile, noté D_9 : c'est la valeur de la série telle que **au moins 90%** des valeurs de la série lui sont inférieures ou égales.

Exemple: On considère le tableau des salaires mensuels d'une entreprise

Salaires brut x_i (€)	1405	1480	1554	1870	2739	4215	Total
effectifs n_i	40	15	81	35	9	5	$N=185$
ECC	40	55	136	171	180	185	

$$\frac{N}{10} = 18,5 \quad D_1 = x_{19} = 1405$$

$$\frac{9N}{10} = 166,5 \quad \text{donc } D_9 = x_{167} = 1870$$

$$\frac{N}{2} = 92,5 \quad M_e = x_{93} = 1554$$

$$\frac{N}{4} = \frac{185}{4} = 46,25 \quad Q_1 = x_{47} = 1480$$

$$\frac{3N}{4} = 138,75 \quad Q_3 = x_{139} = 1870$$

II Autour de la moyenne :

1. Moyenne : définition

Soit $(x_i; n_i)$ avec $1 \leq i \leq p$ une série statistique quantitative dont les modalités $x_1; x_2; \dots; x_p$ ont pour effectifs respectifs $n_1; n_2; \dots; n_p$ et pour fréquences $f_1; f_2; \dots; f_p$.

Son effectif total est $N = \sum_{i=1}^p n_i = n_1 + n_2 + \dots + n_p$

valeurs x_i	x_1	x_2	\dots	x_p	Total
effectifs n_i	n_1	n_2	\dots	n_p	N
fréquences f_i	f_1	f_2	\dots	f_p	1

La moyenne de la série statistique $(x_i; n_i)$ $1 \leq i \leq p$ est notée \bar{x} et on a :

$$\bar{x} = \frac{\sum_{i=1}^p n_i x_i}{N} = \frac{n_1 x_1 + n_2 x_2 + \dots + n_p x_p}{n_1 + n_2 + \dots + n_p} = \frac{n_1 x_1 + n_2 x_2 + \dots + n_p x_p}{N}$$

$$\bar{x} = f_1 x_1 + f_2 x_2 + \dots + f_p x_p = \sum_{i=1}^p f_i x_i$$

Exemple 1:

En lançant un dé cubique 25 fois on a obtenu la distribution suivante :

1	2	3	4	5	6
2	5	4	5	6	3

La moyenne de cette série statistique est :

$$\bar{x} = \frac{1 \times 2 + 2 \times 5 + 3 \times 4 + 4 \times 5 + 5 \times 6 + 6 \times 3}{25}$$

$$\bar{x} = \frac{92}{25} = 3,68$$

Exemple 2: données réparties en classe.

Le tableau suivant donne la répartition en % des auditeurs d'une radio FM suivant l'âge. Estimons l'âge moyen d'un auditeur de cette radio

Age	$[8; 12[$	$[12; 16[$	$[16; 18[$	$[18; 22[$	$[22; 30[$
fréquence	0,14	0,24	0,24	0,25	0,13

$$\bar{x} = 10 \times 0,14 + 14 \times 0,24 + 17 \times 0,24 + 20 \times 0,25 + 26 \times 0,13$$

$$= 17,22$$

Lorsque les données sont réparties en classe, les calculs s'effectuent avec les centres de classes.

Pour mesurer la dispersion des valeurs de la série $(x_i; n_i)_{1 \leq i \leq p}$ autour d'un réel h , on peut former la moyenne des carrés des écarts à h des valeurs de la série.

$$f(h) = \frac{1}{N} [n_1(x_1 - h)^2 + n_2(x_2 - h)^2 + \dots + n_p(x_p - h)^2]$$

$$f(h) = \frac{1}{N} \sum_{i=1}^p n_i(x_i - h)^2$$

On montre que f admet un minimum pour $h = \bar{x}$ et ce minimum est :

$$f(\bar{x}) = \frac{1}{N} \sum_{i=1}^p n_i(x_i - \bar{x})^2$$

2) Variance et écart type : définition

Soit la série statistique $(x_i; n_i)_{1 \leq i \leq p}$ d'effectif total N et de moyenne \bar{x}

Le réel $V = \frac{1}{N} [n_1(x_1 - \bar{x})^2 + n_2(x_2 - \bar{x})^2 + \dots + n_p(x_p - \bar{x})^2]$ est appelé variance de la série statistique.

$\sigma = \sqrt{V}$ est appelé **écart type** de la série.

Remarque : Les indicateurs V et σ mesurent la dispersion des valeurs de la série autour de sa moyenne ; ils sont donc naturellement associés à \bar{x} .

Exemple : On reprend la distribution des 25 lancers de dé

x_i	1	2	3	4	5	6
n_i	2	5	4	5	6	3

$$\bar{x} = 3,68$$

$$V = \frac{1}{N} [n_1(x_1 - \bar{x})^2 + n_2(x_2 - \bar{x})^2 + n_3(x_3 - \bar{x})^2 + \dots + n_p(x_p - \bar{x})^2]$$

$$V = \frac{1}{25} [2(1 - 3,68)^2 + 5(2 - 3,68)^2 + 4(3 - 3,68)^2 + 5(4 - 3,68)^2 + 6(5 - 3,68)^2 + 3(6 - 3,68)^2]$$

$$V \approx 2,30 \quad \sigma = \sqrt{V} \approx 1,52$$