

## Chapitre III : Les caractéristiques de dispersion

Les caractéristiques de tendance centrale ne sont pas toujours suffisantes pour caractériser une série statistique, car 2 séries peuvent avoir  $Mo = Me = \bar{x}$  alors qu'elles sont distribuées de façon différente comme le montre l'exemple suivant :

Exemple : on a 2 séries relatives au nombre de pièces mauvaises produites par 2 machines A et B par semaine.

Machine A : 39, 40, 40, 41, 41, 41, 42, 42, 43

Machine B : 1, 21, 21, 41, 41, 41, 61, 61, 81

On constate que ces 2 séries ont :  $Me = Mo = \bar{x} = 41$  pièces mauvaises, cependant les 2 séries sont différentes par la dispersion de leurs valeurs.

Pour la série A : les valeurs se concentrent autour de la valeur centrale tandis que

Pour la série B : les valeurs sont plus dispersées par rapport à la valeur centrale.

Pour mesurer le degré de dispersion de ces valeurs par la valeur centrale on fait appel à quelques caractéristiques de dispersion telles : l'étendue (E) ; les quantiles ; la variance et l'écart type.

### I - L'étendue (E) ou l'intervalle de variation :

L'étendue notée (E) ou l'intervalle de variation d'une série statistique est la différence entre la plus grande valeur et la plus petite valeur de la variable statistique

$$E = \text{Limite finale} - \text{limite initiale}$$

Exemple précédent :

Machine A :  $E = 43 - 39 = 4$

Machine B :  $E = 81 - 1 = 80$

- Remarques :**
- l'étendue est facile à calculer et contient 100% des observations.
  - cette caractéristique n'est pas très fiable car elle dépend des valeurs extrêmes du caractère, valeurs souvent aberrantes ou accidentelles.

### II- Les quantiles :

Ce sont des paramètres qui nous renseignent sur la dispersion des valeurs de la variable par rapport à la médiane.

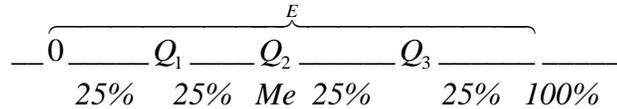
#### A- Les quartiles

**1- Définition :** les quartiles  $Q_i$  sont des valeurs de variables qui partagent la série en 4 parties égales ; on a 3 quartiles notés  $Q_1, Q_2, Q_3$ .

\* Le premier quartile  $Q_1$  est la valeur du caractère tel que 25% des observations de la série ont une valeur inférieure à  $Q_1$  et 75% des observations ont une valeur supérieure à  $Q_1$ .

\*  $Q_2$  c'est le 2<sup>ème</sup> quartile qui correspond à la médiane  $Q_2 = Me$ .

\* Le 3<sup>ème</sup> quartile  $Q_3$  : c'est la valeur du caractère tel que 75% des observations de la série ont une valeur inférieure à  $Q_3$  et 25% des observations ont une valeur supérieure à  $Q_3$ .



**2- L'intervalle interquartile :** c'est la différence entre  $Q_3$  et  $Q_1$  noté :  $Iq = Q_3 - Q_1$   
cet intervalle contient 50% des observations centrales, on peut le comparer à l'étendue pour mesurer son importance par rapport à la série.

**3- Détermination des quartiles  $Q_1$  et  $Q_3$  :**

Comme la médiane  $Me$ , les quartiles se déterminent à partir des  $n_i$  cum  $\nearrow$  ou  $f_i$  cum  $\nearrow$  et ce graphiquement ou par le calcul.

a/ calcul de  $Q_1, Q_3, Me$ .

Exemple : répartition de 100 salariés d'une entreprise se selon le salaire mensuel en (1000 DH)

Salaires	$n_i$	$n_i$ cumulé croissant
8 – 10	22	22
10 – 12	28	50
10 – 14	30	80
14 – 16	15	95
16 - 18	5	100
$\Sigma$	100	-

\* $Q_1$  : le rang de  $Q_1$  :  $\Sigma n_i = 100 = 25 \Rightarrow Q_1 \in [10 - 12[$ . Calcul :

$$Q_1 = L_1 + \left( \frac{\Sigma n_i / 4 - \Sigma_1 n_i}{\Sigma_2 n_i - \Sigma_1 n_i} \times (L_2 - L_1) \right) = 10 + 25 - \left( \frac{22 \times 2}{50 - 22} \right) = 10,21$$

10210 DH: interprétation: 25% des salariés touchent moins de 10210 DH  
75% des salariés touchent plus de 10210 DH

\*La médiane  $Me$  : le rang :  $\Sigma n_i / 2 = 100 / 2 = 50 \Rightarrow Me \in [10 - 12[$ . Calcul de  $Me$  :

$Me = 12$  soit 12000 DH, car le rang apparaît dans le cumul croissant des  $n_i$ , la médiane correspond à la limite supérieure de la classe médiane (même constatation pour les autres quantiles).

\*Le 3<sup>ème</sup> quartiles  $Q_3$  : le rang :  $3 \Sigma n_i = 100 \times 3 = 75 \Rightarrow Q_3 \in [12 - 14[$ . Calcul :

$$Q_3 = L_1 + \left( \frac{L_2 - L_1}{\Sigma_2 n_i - \Sigma_1 n_i} \times 3 \Sigma n_i / 4 - \Sigma_1 n_i \right) = 12 + 2 \times \left( \frac{75 - 50}{80 - 50} \right) = 13,667$$

75% des salariés perçoivent un salaire < à 13667 DH et 25% des salariés ont un salaire  $\geq$  à 13667 DH

4- L'intervalle interquartile  $I_q = Q_3 - Q_1 = 3457$  DH. L'étendue des 50% des observations centrales est de 3457 DH.

### **B- les déciles (Di) et les centiles (Ci)**

**1- les déciles** : on divise la population en 10 parties égales on obtient 9 déciles

$D_1, D_2, \dots, D_9$ .

\* Le premier décile  $D_1$  est la valeur du caractère telle que 10% des observations de la série ont une valeur inférieure à  $D_1$  et 90% des observations ont une valeur supérieure à  $D_1$ .

\* Le 9<sup>ème</sup> décile  $D_9$  : c'est la valeur du caractère tel que 90% des observations de la série ont une valeur inférieure à  $D_9$ , et 10% des observations ont une valeur supérieure à  $D_9$ .

Remarque : l'intervalle interdécile  $D_9 - D_1$  contient 80% des observations

détermination des déciles graphiquement ou par calcul. On utilise les  $n_i$  cumulatif.

\* Calcul de  $D_1$  et  $D_9$ :

Calcul des déciles  $D_1$  et  $D_9$ :

$$*D_1: \text{le rang: } \frac{\sum n_i}{10} = \frac{100}{10} = 10 \Rightarrow D_1 \in [8 - 10[ : D_1 = L_1 + \left( (L_2 - L_1) \times \frac{(\sum n_i)/10 - \sum_1 n_i}{\sum_2 n_i - \sum_1 n_i} \right) = 8 + \left( 2 \times \frac{10 - 0}{22 - 0} \right)$$

$D_1 = 8,909$  soit 8909 DH.

$$* \text{Calcul de } D_9: \text{le rang: } \frac{9 \sum n_i}{10} = \frac{100 \times 9}{10} = 90 \Rightarrow D_9 \in [14 - 16[ : D_9 = L_1 + \left( (L_2 - L_1) \times \frac{9(\sum n_i)/10 - \sum_1 n_i}{\sum_2 n_i - \sum_1 n_i} \right)$$

$$D_9 = 14 + \left( 2 \times \frac{90 - 80}{95 - 80} \right) = 15,333 \text{ soit } 15333 \text{ DH}$$

2- L'intervalle interdécile :  $I_D = D_9 - D_1$  ; il contient 80% des observations centrales.

$I_D = 15333 - 8909 = 6424$  DH. 80% des observations centrales ont des salaires occupant une étendue de 6424 DH. Celle-ci représente  $64,24\% = 6,424 \times 100$  de l'étendue totale ( $E = 18 - 8 = 10$ ).

### **2- Les centiles Ci**

On divise les observations d'une série statistique en 100 parties égales on obtient 99 centiles.

\* Le premier centile  $C_1$  est la valeur du caractère telle que 1% des observations de la série ont une valeur inférieure à  $C_1$  et 99% des observations ont une valeur supérieure à  $C_1$ .

\* Le 99<sup>ème</sup> centile  $C_{99}$  : c'est la valeur du caractère tel que 99% des observations de la série ont une valeur inférieure à  $C_{99}$ . et 1% des observations ont une valeur supérieure à  $C_{99}$ .

Remarque : l'intervalle intercentile  $C_{99} - C_1$  contient 98% des observations

a- Détermination des centiles  $C_1$  et  $C_{99}$ . On utilise les  $n_i$  cumulatifs.

### III - La variance V(x) et l'écart type (σx)

#### A- La variance V(x) :

**1- Définition :** la variance est la moyenne arithmétique des carrés des écarts de la variable  $x_i$  à sa moyenne arithmétique  $\bar{x}$ .

Elle se définit par la quantité suivante :

$$\left. \begin{aligned} \text{si } n_i=1: V(x) &= \frac{\sum (x_i - \bar{x})^2}{n} \\ \text{si } n_i \neq 1: V(x) &= \frac{\sum n_i (x_i - \bar{x})^2}{\sum n_i} \end{aligned} \right\} \text{ formule de définition.}$$

- En développant la formule de définition on obtient une formule développée :

$$V(x) = \frac{\sum n_i (x_i - \bar{x})^2}{\sum n_i} = \frac{\sum n_i x_i^2}{\sum n_i} - \bar{x}^2 = \sum f_i x_i^2 - \bar{x}^2 = \frac{\sum f_i \% x_i^2}{100} - \bar{x}^2 = Q^2 - \bar{x}^2.$$

**2- l'écart type (σx) :** l'écart type est la racine carrée de la variance V(x)

$$\sigma_x = \sqrt{V(x)} = \left[ \frac{\sum n_i (x_i - \bar{x})^2}{\sum n_i} \right]^{1/2}$$

L'écart type montre de combien en moyenne, la variable  $x_i$  s'écarte de sa moyenne  $\bar{x}$ .

#### 3- Le coefficient de variation C.V.

Le C.V. est le rapport de l'écart type à la moyenne qui s'exprime en %

$$C.V. = \frac{\sigma_x}{\bar{x}} \times 100.$$

On utilise le CV pour apprécier l'importance de la dispersion d'une série ou pour comparer deux séries entre elles.

#### B/ Calcul de V(x), σx et C.V.

On reprend l'exemple précédent : le salaire mensuel ( $10^3$  DH)

Exercice d'application : exemple précédent : calculer V(x), δx et C.V.

Salaire $10^3$ DH	$n_i$	Centre de classe $x_i$	$n_i x_i$	$(x_i - \bar{x})$	$n_i (x_i - \bar{x})^2$
8 - 10	22	(8+10)/2= 9	22 x 9 = 198	- 3,06	205,92
10 - 12	28	(10+12)/2=11	308	- 1,06	31,36
12 - 14	30	(12+14)/2=13	390	+ 0,94	26,40
14 - 16	15	(14+16)/2=15	225	+ 2,94	129,60
16 - 18	5	(16+18)/2=17	85	+ 4,94	122,00
Σ	100	—	1206	—	515,28

$$\begin{aligned} \bar{x} &= \frac{\sum n_i x_i}{\sum n_i} = \frac{1206}{100} = 12,06 \\ V(x) &= \frac{\sum n_i (x_i - \bar{x})^2}{\sum n_i} \\ &= \frac{515,28}{100} - (12,06)^2 \\ &= 5,1528 \\ \Rightarrow \delta x &= \sqrt{5,1528} = 2,27 \\ &\text{soit } 2270 \text{ DH} \end{aligned}$$

$$\text{Le C.V.} = \frac{2,27}{12,06} \times 100 = 18,82\%$$

Interprétation : \* δx = 2270 DH : les valeurs  $x_i$  de la variable x s'écartent de leur moyenne  $\bar{x} = 12060$  DH, en moyenne de 2270 DH.

\* le C.V. = 18,82% la dispersion entre les salaires est faible ; salaires homogènes.