

## 2- Les paramètres de dispersion

### 2-1 L'étendue

L'étendue, noté  $e$ , représente la différence entre les valeurs extrêmes de la distribution :

$$e = x_n - x_1.$$

Exemple : Soit la série suivante : 15 14 18 17 19 12 56 48 47 59

$$e = x_n - x_1 = 59 - 12 = 47.$$

### 2-2 La variance

C'est la moyenne arithmétique des carrés des écarts par rapport à la moyenne.

Symbolisé par le signe ( $s^2$ ) ou dans la littérature par ( $\sigma^2$ ), et elle est donnée par la relation suivante :

$$S_x^2 = 1/n-1 \sum (x_i - m)^2$$

Exemple : Avec la série précédente

$$m = 30,5$$

$$S_x^2 = 1/9 \sum (15-30,5)^2 + (14-30,5)^2 + \dots + (59-30,5)^2$$

$$S_x^2 = 374,05$$

### 2-3 L'écart-type

Aussi appelé déviation standard, c'est la racine carrée de la variance, symbolisé par le

signe ( $S$ ) ou ( $\sigma$ ) et donné par :  $S_x = \sqrt{\text{variance}}$

Avec l'exemple précédent on obtient

$$S_x = \sqrt{374,05} = 19,34$$

### 2-4 Le coefficient de variation

Il permet d'apprécier l'homogénéité des observations dans un échantillon. Symbolisé par le signe  $V$  ou C.V. et donné par la relation suivante :

$$\text{C.V. ou } V = S_x / m \times 100$$

Si le  $V < 5\%$  il s'agit d'observations très homogènes ;

Si  $5\% < V < 10\%$  il s'agit d'observations homogènes ;

Si  $10\% < V < 15\%$  il s'agit d'observations moyennement homogènes ;

Si  $15\% < V < 30\%$  il s'agit d'observations hétérogènes ;

Si le  $V > 30\%$  il s'agit d'observations très hétérogènes.

### **Exemple**

Avec la série précédente, *quel est le degré d'homogénéité entre les observations ?*

### **La solution**

$V = S_x / m \times 100$  implique C.V. =  $19,34 / 30,5 \times 100 = 63,41\%$

Cette dernière valeur indique que les observations de la série sont très hétérogènes

### **Chapitre III. Statistique descriptive à deux dimensions**

L'objectif de cette partie est d'étudier sur une même population de  $n$  individus, deux caractères différents  $X$  et  $Y$  et de rechercher s'il existe un lien entre ces deux variables.

#### **Covariance**

C'est la moyenne des produits des écarts pour chaque série d'observation.

$$\text{Cov}(x,y) = S_{xy} = 1/n \sum (x_i - m) (y_i - \bar{y})$$

#### **La corrélation**

La corrélation est la netteté ou l'intensité de la relation existante entre deux séries de données.

#### **Le coefficient de corrélation (r)**

Le coefficient de corrélation mesure la dépendance linéaire entre les variables  $X$  et  $Y$ .

Le coefficient de corrélation, est précisément le rapport de la covariance sur le produit des écarts-types de deux variables  $X$  et  $Y$ .

$$r = \text{Cov}(x, y) / S_x \cdot S_y$$


On a  $-1 < r < 1$ . Si  $r$  est proche de 1 ou -1, les variables  $X$  et  $Y$  sont dits : fortement corrélés.

#### **Propriétés**

Si le coefficient de corrélation est positif, les points du nuage sont alignés le long d'une droite croissante. Dans ce cas  $X$  et  $Y$  évoluent dans le même sens (**figure 1**).

Si le coefficient de corrélation est négatif, les points sont alignés le long d'une droite décroissante. Dans ce cas  $X$  et  $Y$  évoluent dans des sens opposés (**figure 1**).

Si le coefficient de corrélation est nul ou proche de zéro, il n'y a pas de dépendance linéaire (**figure 1**).



**Figure 1:** Exemples de diagrammes de dispersion avec différentes valeurs de coefficient de corrélation.

### Exemple

L'étude de deux variables (X) le poids de 1000 grains en gramme et le rendement (Y) en quintaux par hectare chez le blé a donné les résultats suivants :

<b>X (g)</b>	43	46	48	50	52	55	56	58	60	62
<b>Y (qx/ha)</b>	30	33	35	36	37	39	39	42	43	45

1. Calculer la covariance  $Cov(xy)$  qui associe X et Y.
2. Calculer le coefficient de corrélation  $r_{xy}$  et quelle est votre conclusion ?

### La solution

$$m = 53 \quad S_x = 6,25$$

$$\bar{y} = 37,5 \quad S_y = 4,65$$

$$Cov(xy) = 28,88.$$

$$r = 0,99.$$

Il existe une forte corrélation positive.