

## ***Chapitre 2 : Les Méthodes Statistiques Relatives à la Corrélation***

### **1. Principes fondamentaux**

Les conditions d'application de ces méthodes :

- \* Les deux (2) variables sont indépendantes et ont une distribution normale à 2 dimensions.
- \* Les échantillons sont aléatoires simple et indépendant les uns des autres dans les comparaisons de 2 ou plusieurs coefficient de corrélation.

### **2. Objectifs de la corrélation linéaire (Positionnement):**

\* Variations respectives de plusieurs grandeurs dans une même population. *exp: relation entre poids et taille*

\* Courbe associée à la fonction  $y = f(x)$ .

\* Si la loi est définie, la connaissance de «  $x$  » suffit à déterminer «  $y$  » :  
*Relation fonctionnelle (sciences exactes).*

\* Les fluctuations statistiques à une valeur d'une des variables correspondent une distribution de valeur de l'autre variable.

### **3. Représentation graphique :**

Si on représente les couples de valeurs  $(x, y)$  sur le même repère orthonormé on obtient un nuage de point (**Fig. 1**).




Figure 1. Le nuage de point

#### 4. Corrélation et régression :

La régression permet d'étudier l'association entre deux variables quantitatives, en étudiant les variations de l'une en fonction des valeurs de l'autre.

Le coefficient de corrélation «  $r$  » est une mesure d'association entre deux variables quantitatives faisant jouer des rôles symétriques aux valeurs. Les deux variables peuvent être placées indifféremment en abscisse ou en ordonnées. On cherche à savoir simplement s'il existe une liaison entre ces deux variables et à quantifier l'intensité de la liaison.

$$\mathbf{r_{xy} = \mathbf{COV_{xy} / S_x S_y}}$$

$\mathbf{cov_{xy}}$  : Covariance :  $\mathbf{cov_{xy} = (1/n \sum x_i y_i) - \bar{X} \bar{y}}$

$\mathbf{s_x}$  : Ecart type de la variable «  $x$  »

$\mathbf{s_y}$  : Ecart type de la variable «  $y$  »

Quels que soit l'unité et les ordres de grandeur de «  $x$  » et «  $y$  », le coefficient de corrélation est un nombre sans unité, compris entre  $(-1)$  et  $(+1)$ . Il traduit la plus ou moins grande dépendance linéaire de «  $x$  » et «  $y$  » ou, géométriquement, le plus ou moins grand aplatissement du nuage de points.

#### 4.1. La corrélation :

«  $x$  » et «  $y$  » sont des variables quantitatives. Pour dire que «  $x$  » et «  $y$  » sont corrélées, c'est affirmer qu'il existe une liaison entre ces deux variables.

Plus «  $x$  » varie dans un sens, plus «  $y$  » varie. Si «  $y$  » varie dans le *même sens* que «  $x$  » : *la corrélation est positive*.


Si «  $y$  » varie dans le *sens opposé* de «  $x$  » : *la corrélation est négative*.

Si «  $x$  » et «  $y$  » varient *indépendamment* de l'un de l'autre : *les variables ne sont pas corrélées*.





Quand le coefficient de corrélation est proche de  $1$  ou  $-1$ , les caractères sont dits "*fortement corrélés*".

#### 4.2. Distribution :

Lorsque la corrélation «  $r$  » est nulle ( $r=0$ ) la distribution d'échantillonnage est symétrique et elle est représentée comme suit :



Lorsque le coefficient de corrélation « r » est différent du « 0 », la distribution est *dissymétrique* et elle est représentée comme suit :



Nuage de points diffus = Absence de liaison entre les caractères étudiés