

TP : 02

Ce TP vise d'affirmé l'existence d'une relation entre deux variables, on utilisant la corrélation ensuite déterminé la relation entre les deux variable on pratiquant la régression simple.

Rappel sur la corrélation entre deux variables.

La corrélation de Pearson ou de Bravais – Pearson est une mesure de la liaison linéaire existant entre deux variables quantitatives normales.

$$r_{xy} = \frac{\text{Cov. } xy}{S_x * S_y} = \frac{\sum xy - \frac{\sum x \sum y}{n}}{\sqrt{\text{SCE}_x * \text{SCE}_y}}$$

Toutes les valeurs de $r_{x,y}$ sont comprises entre -1 et +1. $r = -1$ ou $+1$ si tous les points du diagramme de dispersion sont situés sur une ligne droite et $r = 0$ lorsque le nuage de dispersion ne montre aucune tendance de relation entre les deux variables. Aussi, si r est positif \Rightarrow les deux variables augmentent au même temps et si r est négatif \Rightarrow l'une des variables augmente quand l'autre diminue.

Application numérique : On désire vérifier la corrélation entre la taille (en cm) et le poids (en kg) des enfants de 2 ans sur un échantillon de 15 individus.

Taille (X)	82.9	83.4	82.4	82.1	84.8	86.7	84.0	89.0	85.0	85.4	87.7	87.7	86.4	86.4	86.9
Poids (Y)	8.7	9.2	9.5	10.1	10.4	10.5	10.8	11.0	11.5	11.6	12.4	13.6	13.8	13.9	14.6

Calcul de $r_{x,y}$

XY	721.23	767.28	782.8	829.21	881.92	910.35	907.2	979	977.5	990.64	1087.5	1192.3
$\sum x = 1280.8$	$\sum y = 171.6$					$\sum xy = 14689.4$						
$\text{SCE}_x = 62.1$	$\text{SCE}_y = 47.9$											

$$r_{xy} = \frac{\text{Cov. } xy}{S_x * S_y} = \frac{\sum xy - \frac{\sum x \sum y}{n}}{\sqrt{\text{SCE}_x * \text{SCE}_y}} = \frac{14689.4 - \frac{1280.8 * 171.6}{15}}{\sqrt{62.1 * 47.9}} = \frac{37}{54.5} = 0.68$$

Test de signification du coefficient de corrélation de Pearson

on estime r et on vérifie si l'estimation obtenue est suffisamment distante de 0 pour rejeter l'hypothèse d'indépendance ($r = 0$). $H_0 : r = 0$ Les variables ne sont pas corrélées

:

$$t_r = \frac{r \sqrt{n-2}}{\sqrt{1-r^2}} \text{ et comparer cette valeur à } t_{1-\alpha/2} \text{ pour un ddl} = n-2.$$

Si $t_r > t_{1-\alpha/2} \Rightarrow H_0$ est rejetée \Rightarrow la liaison est significative.

Si $t_r \leq t_{1-\alpha/2} \Rightarrow H_0$ est acceptée \Rightarrow la liaison n'est pas significative.

Régression linéaire simple

On parle de régression linéaire simple lorsqu'on désire calculer une fonction du premier degré liant les variables « x » et « y ». Cette fonction linéaire est de la forme :

$$y = ax + b$$

Elle correspond à l'équation d'une ligne droite qui traverse au mieux le nuage de points et permet de calculer une valeur estimée « \hat{y} » pour chaque point de l'axe des x correspondant à la variable prédictive. Cette droite porte le nom de droite d'estimation ou droite de régression de « y » en « x ». Cette droite est obtenue par la méthode des moindres carrés dont le principe consiste à choisir la pente « a » et l'ordonnée à l'origine « b » de la droite qui minimisent la somme des carrés des erreurs. L'erreur est représentée par l'écart entre la valeur observée « y_i » et la valeur prédite par la droite « \hat{y}_i ». Cet écart « $e_i = y_i - \hat{y}_i$ » est appelé également « résidu ». La méthode des moindres carrés consiste à réduire au maximum la somme des carrés des écarts (résidus) :

$$\sum_{i=1}^n e_i^2 = \sum_{i=1}^n (y_i - \hat{y}_i)^2.$$

$$b = \bar{y} - a \bar{x} \quad \text{et} \quad a = \frac{S_{xy}}{S_x^2} \quad \text{avec} \quad S_{xy} = \frac{n \sum xy - (\sum x)(\sum y)}{n(n-1)}$$

Application numérique :

Hauteur	Diamètre	Hauteur	Diamètre	Hauteur	Diamètre	Hauteur	Diamètre
10	65	14	72	19	82	23	92
11	68	15	75	20	86	24	98
12	67	16	76	20	84	24	101
12	69	17	80	21	85	25	105
13	69	18	82	22	88	25	109

Déterminons l'équation de régression linéaire qui permet de prédire le diamètre du tronc à partir de la hauteur des arbres et calculons le coefficient de corrélation linéaire « r ».

L'estimation des coefficients « a » et « b » de la droite de régression et le calcul du coefficient de corrélation « r » nécessitent les calculs suivants : 4.84 12.78

$$N = 20 \text{ arbres} \quad \sum x = 361 \quad \sum x^2 = 6985 \quad \bar{x} = 18.05 \quad S_x = 4.97 \quad S_x^2 = 24.7$$

$$\sum y = 1653 \quad \sum y^2 = 139889 \quad \bar{y} = 82.65 \quad S_y = 13.11 \quad S_y^2 = 171.87 \quad \sum xy = 31033$$

$$S_{xy} = \frac{n \sum xy - (\sum x)(\sum y)}{n(n-1)} = \frac{20 * 31033 - 361 * 1653}{20(19)} = \frac{620660 - 596733}{380} = 62.96$$

$$r = \frac{S_{xy}}{S_x * S_y} = \frac{62.96}{65.15} = 0.96$$

La pente de la droite de régression « a » est égale à :


$$a = \frac{S_{xy}}{S_x^2} = \frac{62.96}{24.70} = 2.55$$

L'ordonnée à l'origine « b » est égale à :

$$b = \bar{y} - a \bar{x} = 82.65 - 2.55(18.05) = 36.62$$

On aura ainsi l'équation de régression suivante :

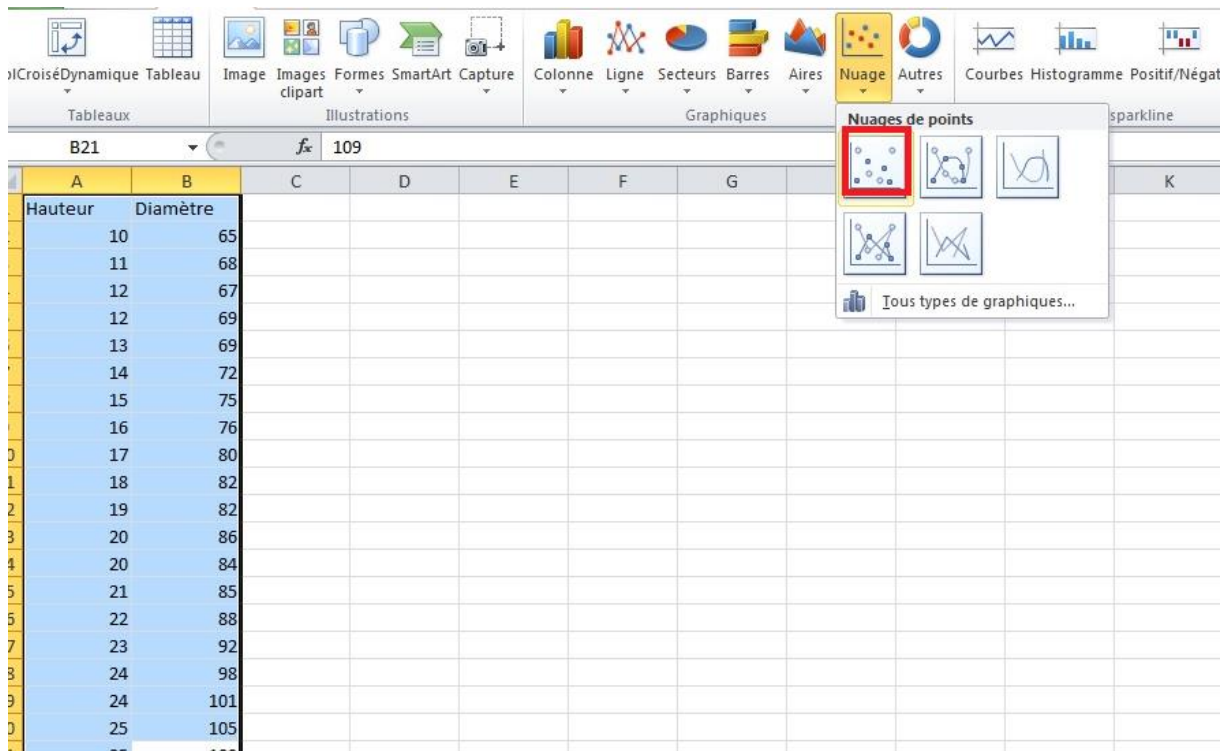
$$y = 2.55x + 36.62$$



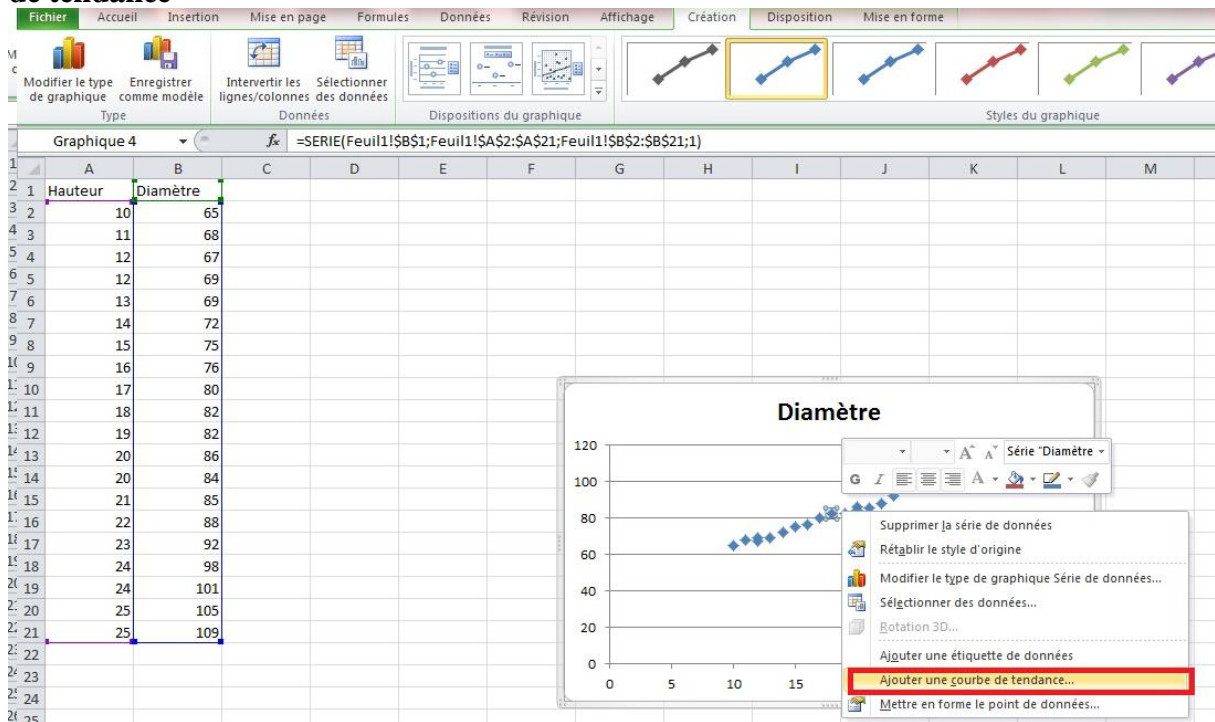
Application TP sur Excel :

Une étude sur la relation entre deux caractéristiques dendrométriques (Hauteur des arbres en mètre et diamètre du tronc en cm.) d'un peuplement forestier a été menée sur un échantillon aléatoire de 20 arbres et les résultats sont les suivants :


Entrer les données des hauteurs et des diamètres des arbres/ **sélectionner** les plages de données / **Insertion/ Nuage de points / Nuage de points avec marqueur uniquement**



Cliqué sur un des point du graphe avec le bouton de droite de la souris/ **Ajouté une courbe de tendance**



Dans la fenêtre suivante /coché -1 **Afficher l'équation sur le graphe** -2 **Afficher le coefficient de détermination (R^2)**



	A	B	C	D	E
1	Hauteur	Diamètre			
2		10	65		
3		11	68		
4		12	67		
5		12	69		
6		13	69		
7		14	72		
8		15	75		
9		16	76		
10		17	80		
11		18	82		
12		19	82		
13		20	86		
14		20	84		
15		21	85		
16		22	88		
17		23	92		
18		24	98		
19		24	101		
20		25	105		
21		25	109		
22					
23					
24					
25					
26					
27					

Format de courbe de tendance

Options de courbe de tendance

Couleur du trait

Style de trait

Ombre

Éclat et contours adoucis

Type de régression/de courbe de tendance

- Exponentielle
- Linéaire
- Logarithmique
- Polynomiale Ordre : 2
- Puissance
- Moyenne mobile Période : 2

Nom de la courbe de tendance

- Automatique : Linéaire (Diamètre)
- Personnalisé :

Prévision

Transférer : 0,0 périodes

Reculer : 0,0 périodes

Définir l'interception = 0,0

Afficher l'équation sur le graphique

Afficher le coefficient de détermination (R²) sur le graphique

Fermer