

TD 03 : Statistiques descriptives bivariées

Exercice 3

Lors d'une enquête menée sur un échantillon de 15 familles, on a converti la consommation journalière en milliers de calories. Chaque adulte est compté pour une « unité de consommation » alors que les enfants sont comptés pour « une part d'unité », dépendant de son âge et de son sexe. Les résultats sont les suivants :

Familles	1	2	3	4	5	6	7	8	9	10	11	12	13	14	15
Unités de consommation (Xi)	3,5	7,1	6,5	7,1	4,0	3,8	5,1	5,4	4,1	4,2	2,1	3,8	4,7	5,1	7,2
Calories par jour (Yi)	11	18	10	15	9	7	8	9	8	9	5	6	11	8	22

1. Calculer les paramètres statistiques univariés pour chaque variable ;
2. Calculer la covariance et le coefficient de corrélation de x et y ;
3. Existe-il une relation entre X et Y ?
4. Quel est le type de relation qui existe entre les 2 variables ?
5. Calculer l'équation de la régression linéaire ?
6. Tracer le nuage de points représentant les données ;
7. Déterminer le point moyen et représenter-le dans le nuage de points ;
8. Tracer la droite de régression sur le nuage de points.
9. Calculer les valeurs prédites
10. Calculer les variabilités entre :
 - les valeurs observées et leur moyenne
 - les valeurs observées et les valeurs prédites
 - les valeurs prédites et la moyenne des valeurs observées

Exercice 4

Une expérience consiste à mesurer l'activité enzymatique avant et après l'addition d'un produit X. cette expérience est menée dans 23 tubes à essai et dans des conditions de laboratoire. Les résultats obtenus (en mg/l) sont les suivants :

Tube	1	2	3	4	5	6	7	8	9	10	11	12
Avant	15,9	14,9	15,1	14,9	14,9	14,7	15	14,8	14,8	14,8	15,1	15,2
Après	8,2	11,3	11,9	11,1	11,5	11	10,9	10,9	10,2	10,9	10,2	11,5

Tube	13	14	15	16	17	18	19	20	21	22	23
Avant	14,8	14,9	15,2	15,4	14,9	14,5	14,9	15,1	15,5	15,4	15,4
Après	13,9	12,2	10,1	10,2	11,2	15,7	14,2	12,1	9,9	9,9	9,3

1. Calculer les paramètres statistiques univariés pour chaque variable ;
2. Calculer la covariance et le coefficient de corrélation de x et y ;
3. Existe-il une relation entre X et Y ?
4. Quel est le type de relation qui existe entre les 2 variables ?
5. Calculer l'équation de la régression linéaire ?
6. Tracer le nuage de points représentant les données ;
7. Déterminer le point moyen et représenter-le dans le nuage de points ;
8. Tracer la droite de régression sur le nuage de points.
9. Calculer les valeurs prédites
10. Calculer les variabilités entre :
 - les valeurs observées et leur moyenne
 - les valeurs observées et les valeurs prédites
 - les valeurs prédites et la moyenne des valeurs observées

TD 03 / Corrigé-type / Exercice 3

1. Calculer les paramètres statistiques univariés pour chaque variable ;

$$\bar{x}; \bar{y}; x_i - \bar{x}; y_i - \bar{y}; (x_i - \bar{x}); (y_i - \bar{y})^2; (x_i - \bar{x})(y_i - \bar{y})$$

Familles	UC (X)	Cal/J (Y)	$x_i - \bar{x}$	$y_i - \bar{y}$	$(x_i - \bar{x})^2$	$(y_i - \bar{y})^2$	$(x_i - \bar{x})(y_i - \bar{y})$
1	3,5	11	-1,41	0,60	2,00	0,36	-0,85
2	7,1	18	2,19	7,60	4,78	57,76	16,62
3	6,5	10	1,59	-0,40	2,52	0,16	-0,63
4	7,1	15	2,19	4,60	4,78	21,16	10,06
5	4	9	-0,91	-1,40	0,83	1,96	1,28
6	3,8	7	-1,11	-3,40	1,24	11,56	3,79
7	5,1	8	0,19	-2,40	0,03	5,76	-0,45
8	5,4	9	0,49	-1,40	0,24	1,96	-0,68
9	4,1	8	-0,81	-2,40	0,66	5,76	1,95
10	4,2	9	-0,71	-1,40	0,51	1,96	1,00
11	2,1	5	-2,81	-5,40	7,91	29,16	15,19
12	3,8	6	-1,11	-4,40	1,24	19,36	4,90
13	4,7	11	-0,21	0,60	0,05	0,36	-0,13
14	5,1	8	0,19	-2,40	0,03	5,76	-0,45
15	7,2	22	2,29	11,60	5,23	134,56	26,53
	$\bar{x} = 4,91$	$\bar{y} = 10,40$	////	///	$\Sigma = 32,06$	$\Sigma = 297,60$	$\Sigma = 78,12$

2. Calculer la covariance et le coefficient de corrélation de x et y ;

$$Cov(x, y) = \frac{\Sigma(x_i - \bar{x})(y_i - \bar{y})}{N} = \frac{78,12}{15} = \mathbf{5,208}$$

$$\text{Coef. Corrélation : } r_{cal} = \frac{Cov(x, y)}{\sigma_x \times \sigma_y}; \text{ Sachant que :}$$

$$\sigma_x = \sqrt{\frac{\Sigma(x_i - \bar{x})^2}{N}} = \sqrt{\frac{32,06}{15}} = \mathbf{1,46}; \quad \sigma_y = \sqrt{\frac{\Sigma(y_i - \bar{y})^2}{N}} = \sqrt{\frac{297,60}{15}} = \mathbf{4,32}; \quad r_{cal} = \frac{5,208}{1,46 \times 4,32} = \mathbf{0,83}$$

3. Existe-il une relation entre X et Y ? que constatez-vous ?

Comparer r_{cal} # r_{the} (r_{the} Coef théorique)

- Si $N \leq 100$: le r_{tab} est à lire sur une table du coefficient de corrélation, avec ddl = N - 2
- Si $N > 100$: $r_{th} = Z_{\alpha} \cdot S_m = Z_{\alpha} \cdot \frac{1}{\sqrt{N-1}}$ avec $Z_{\alpha} = 1,96$ si $\alpha = 5\%$ ou $Z_{\alpha} = 2,58$ si $\alpha = 1\%$
 - si $r_{cal} > r_{tab} \rightarrow$ il y'a une relation entre x et y
 - si $r_{cal} < r_{tab} \rightarrow$ il n'y a pas de relation entre x et y.

Puisque $N = 15 < 100 \rightarrow$ ddl = N-2 = 13 ; $\alpha = 5\% \Rightarrow r_{the} = \mathbf{0,5139}$; $\alpha = 1\% \Rightarrow r_{the} = \mathbf{0,6411}$.

Nous constatons que $r_{cal} > r_{the}$, cela montre qu'il existe une relation entre X et Y.


4. Quel est le type de relation qui existe entre les 2 variables ? **Corrélation positive**
5. Déterminer l'équation de régression de type $Y = aX + b$ ($y_i = a \cdot x_i + b + e_i$) :

- « a » représente la pente de la droite de régression.

$$a = \frac{cov(x, y)}{var(X)} = \frac{5,208}{2,137} = \mathbf{2,437} \quad \text{ou} \quad a = \frac{\Sigma(x_i - \bar{x})(y_i - \bar{y})}{\Sigma(x_i - \bar{x})^2} = \frac{78,12}{32,06} = \mathbf{2,437}$$

- « b » représente l'ordonnée à l'origine (valeur de Y quand X = 0). On la détermine à partir du point central du nuage de point qui correspond aux moyennes des deux paramètres, ce qui coïncide avec : $b = \bar{y} - a\bar{x} = 10,40 - 2,437 \times 4,91 = -1,566$
- L'équation de la droite de régression est donc : **$Y = 2,437 X - 1,566$** .

6. Nuage de points / Point moyen **m (4,91 - 10,40)** / Droite de régression.



9. Valeurs de prédiction ou valeurs prédites (\hat{Y}) et calcul des variabilités.

UC (X)	Cal/J (Y)	\hat{Y}	$(Y - \bar{Y})^2$	$(Y - \hat{Y})^2$	$(\hat{Y} - \bar{Y})^2$
3,5	11	6,9635	0,36	16,29	11,81
7,1	18	15,7367	57,76	5,12	28,48
6,5	10	14,2745	0,16	18,27	15,01
7,1	15	15,7367	21,16	0,54	28,48
4	9	8,182	1,96	0,67	4,92
3,8	7	7,6946	11,56	0,48	7,32
5,1	8	10,8627	5,76	8,20	0,21
5,4	9	11,5938	1,96	6,73	1,43
4,1	8	8,4257	5,76	0,18	3,90
4,2	9	8,6694	1,96	0,11	2,99
2,1	5	3,5517	29,16	2,10	46,90
3,8	6	7,6946	19,36	2,87	7,32
4,7	11	9,8879	0,36	1,24	0,26
5,1	8	10,8627	5,76	8,20	0,21
7,2	22	15,9804	134,56	36,24	31,14
$\bar{x} = 4,91$	$\bar{y} = 10,4$	10,41	$\Sigma = 297,60$	$\Sigma = 107,23$	$\Sigma = 190,39$

- Variabilité entre les valeurs observées et leur moyenne

$$\text{Var (obs-moy)} = \Sigma(y_i - \bar{y})^2 / (N) = \mathbf{19,84}$$

- Variabilité entre les valeurs observées et les valeurs prédites

$$\text{Var (obs-pred)} = \Sigma(y_i - \hat{y})^2 / (N) = \mathbf{7,15}$$

- Variabilité entre les valeurs prédites et la moyenne des valeurs observées

$$\text{Var (pred-moy)} = \Sigma(\hat{y} - \bar{y})^2 / (N) = \mathbf{12,69}$$

- Que constatez-vous ? **Var (obs-moy) = Var (obs-pred) + Var (pred-moy)**