

### I- Séries Statistiques Doubles :


◆ **Exemple** : Le tableau suivant donne le poids en Kg et la taille en cm d'un groupe de 10 enfants :

$P_i$	25	27	23	30	27	23	25	30	32	28
$T_i$	90	92	85	99	93	88	92	98	99	90

- ▶ Le couple  $(P_1, T_1) = (25, 90)$  veut dire que l'enfant N°1 pèse 25 Kg et mesure 90 cm.
- ▶ On a donc une population de 10 enfants sur laquelle on a observé simultanément les deux variables P et T.

◆ **Définition** : On dit qu'un couple  $(X, Y)$  de variables statistiques définit une série double si les deux variables X et Y sont observés simultanément sur une même population.

- ▶ La moyenne arithmétique des poids est :  $\bar{P} = \dots\dots\dots$
- ▶ La moyenne arithmétique des Tailles est :  $\bar{T} = \dots\dots\dots$
- ▶ Placer dans un repère orthogonal l'ensemble des points  $M_i(P_i, T_i)$  :



◆ **Définition** : Soit une série statistique définie par deux variables X et Y . On désigne par  $x_1, x_2, \dots, x_n$  les valeurs de X et par  $y_1, y_2, \dots, y_n$  celles de Y. Le plan étant rapporté à un repère orthogonal. L'ensemble des points  $M_i(x_i, y_i)$  ;  $i \in \{1, 2, \dots, n\}$  est appelé Nuage De Points. Le point  $G(\bar{x}, \bar{y})$  est appelé point moyen du nuage.

◆ **Distributions marginales :**

Soit le tableau statistique suivant : X : note en mathématiques ; Y : nombre de frères et sœurs. N = 100

X \ Y	0	1	2	3	4	5	6	Totaux
[0,4[	1	0	1	1	0	1	1	
[4,8[	2	2	4	3	3	4	2	20
[8,12[	5	5	10	7	6	4	3	
[12,16[	2	3	5	5	4	4	2	25
[16,20[	1	1	2	3	2	1	0	
Totaux	11		22		15		8	100

- Les totaux inscrits en marge de chaque tableau à double entrée définissent deux distributions marginales, l'une associée à la première variable statistique et l'autre associée à la deuxième variable statistique.

X : Note en Maths	[0,4[	[4,8[	[8,12[	[12,16[	[16,20[	Total
$\sum_{j=1}^7 n_{ij}$		20		25	10	100

Distribution marginale de X

Y : nombre de frères et sœurs	0	1	2	3	4	5	6	Total
Effectif $n_{\bullet j}$	11		22		15		8	100

Distribution marginale de Y

- Calcul de la **moyenne** ( $\bar{X}$ ) ; la **variance** ( $V(X)$ ) et l'**écart-type** ( $\sigma(X)$ )

►  $\bar{X} = \frac{\sum_{i=1}^p x_i n_i}{N} = \frac{(2 \times 5) + (6 \times 20) + (10 \times 40) + (14 \times 25) + (18 \times 10)}{100} = \dots\dots\dots$

►  $V(X) = \frac{\sum_{i=1}^p x_i^2 \cdot n_i}{N} - \bar{X}^2 = \frac{(2^2 \times 5) + (6^2 \times 20) + (10^2 \times 40) + (14^2 \times 25) + (18^2 \times 10)}{100} - \bar{X}^2 = \dots\dots\dots$

►  $\sigma(X) = \sqrt{V(X)} \approx \dots\dots\dots$

►  $\bar{Y} = \frac{\sum_{i=1}^q y_i n_i}{N} = \frac{(0 \times 11) + (1 \times 11) + (2 \times 22) + (3 \times 19) + (4 \times 15) + (5 \times 14) + (6 \times 8)}{100} = \dots\dots\dots$

►  $V(Y) = \frac{\sum_{i=1}^q y_i^2 \cdot n_i}{N} - \bar{Y}^2 = \frac{(0^2 \times 11) + (1^2 \times 11) + (2^2 \times 22) + \dots\dots\dots + (6^2 \times 8)}{100} - \bar{Y}^2 = \dots\dots\dots$

►  $\sigma(Y) = \sqrt{V(Y)} \approx \dots\dots\dots$

## II- Ajustement affine d'une série statistique double :

Lorsque le nuage des points, représentant graphiquement une série statistique à deux caractères X et Y, a une forme allongée, on peut approcher la relation entre les deux variables X et Y par une relation affine définie par :  $Y = aX + b$  ou  $X = a'Y + b'$ .

On appelle ajustement affine toute méthode permettant la détermination d'une telle relation.

### 1) Méthode de Mayer :


La méthode de Mayer consiste à :

- Partager le nuage de points en deux parties  $P_1$  et  $P_2$  situées de part et d'autre par rapport à une droite parallèle à l'axe des ordonnées et contenant à peu près le même nombre de points.
- Déterminer les points moyens respectifs  $G_1$  et  $G_2$  des parties  $P_1$  et  $P_2$ .
- La droite  $(G_1G_2)$  est alors la droite d'ajustement affine du nuage de points représentant la série.
- La droite  $(G_1G_2)$  est appelée droite de Mayer et passe par le point moyen G du nuage global.

### ◆ Exemple :

Le tableau ci-dessous présente la consommation de fuel d'une habitation en fonction de la température.

Température $x_i$ en °C	-5	-3	-1	2	5	7	10	13
Consommation $y_i$ de fuel /24h en L	38	36	30	29	25	20	15	12



- 1) Compléter le nuage de points  $M(x_i, y_i)$  dans le repère ci-dessus.
- 2) Fractionner le nuage de points en deux parties égales.
- 3) Calculer les coordonnées du point moyen  $G_1$  de la première partie du nuage.

$$G_1 \left( \frac{-5-3-1+2}{4} ; \frac{38+36+30+29}{4} \right) \text{ alors } G_1 ( \dots ; \dots )$$

4) Calculer les coordonnées du point moyen  $G_2$  de la deuxième partie du nuage.

$$G_2 ( \dots ; \dots )$$

5) Tracer la droite  $(G_1 G_2)$ .

6) Calculer les coordonnées du point moyen  $G$  du nuage.  $G ( \dots ; \dots )$

7) Déterminer l'équation réduite de la droite  $(G_1 G_2)$ .  $(y = ax + b)$ .

$$a = \frac{y_{G_1} - y_{G_2}}{x_{G_1} - x_{G_2}} = \dots \approx -1,45$$

$$b = y_{G_1} - a \cdot x_{G_1} = \dots \approx 30,71 \text{ donc } (G_1 G_2) : y = \dots$$

8) A partir de l'équation de la droite, donner une estimation de la consommation de fuel pour une température de  $-10^\circ\text{C}$ .

9) Déterminer graphiquement, à l'aide de la droite d'ajustement, la température pour une consommation de 22L.

10) Retrouver le résultat précédent par le calcul à partir de l'équation de  $(G_1 G_2)$ .

## 2) Méthode des Moindres carrés :

On peut reconnaître la relation affine éventuelle entre les deux variables  $X$  et  $Y$  à l'aide d'un moyen non graphique et en faisant intervenir deux paramètres statistiques à savoir : la covariance  $\text{Cov}(X, Y)$  et le coefficient de corrélation linéaire  $r$ .

◆ **Covariance** : Soit une série statistique  $(X, Y)$  double définie par  $\{x_1, \dots, x_n\}$  et  $\{y_1, \dots, y_n\}$  observée sur une population de  $n$  individus. On appelle covariance du couple  $(X, Y)$  le réel :

$$\text{Cov}(X, Y) = \frac{1}{n} \sum_{i=1}^n x_i y_i - \bar{X} \bar{Y} = \overline{XY} - \bar{X} \bar{Y}$$

◆ **Exemple** : Soit la série statistique double définie par le tableau suivant, Compléter le tableau :

$x_i$	2	5	3	1	1	4	2	3	$\sum x_i = \dots$	$\bar{X} = \dots$
$y_i$	25	40	10	5	0	15	50	12	$\sum y_i = \dots$	$\bar{Y} = \dots$
$x_i y_i$	50		30		0		100		$\sum x_i y_i = \dots$	$\overline{XY} = \dots$

$$\text{Cov}(X, Y) = \overline{XY} - \bar{X} \bar{Y} = \dots$$

◆ **Exercice** : Calculer la covariance de la série statistique double (X, Y) définie par :

$x_i$	1	2	2	2	5
$y_i$	7	8	9	5	8

$\bar{X} =$  .....

$\bar{Y} =$  .....

$\overline{XY} =$  .....

$\text{Cov}(X, Y) = \overline{XY} - \bar{X} \bar{Y} =$  .....

◆ **Coefficient de corrélation linéaire** :

On appelle coefficient de corrélation linéaire le réel  $r$  défini par :  $r = \frac{\text{Cov}(X, Y)}{\sigma(X) \cdot \sigma(Y)}$  ;  $r \in [-1, 1]$

◆ **Exercice** :

Calculer le coefficient de corrélation linéaire  $r$  pour la série statistique suivante :

$x_i$	1	2	3	4	5	6	7	8	9	10
$y_i$	200	205	211	216	220	225	240	260	280	300

•  $\bar{X} =$  .....

•  $\bar{Y} =$  .....

•  $\overline{XY} =$  .....

•  $V(X) =$  .....

•  $V(Y) =$  .....

•  $\text{Cov}(X, Y) =$  ..... •  $\sigma(X) =$  ..... •  $\sigma(Y) =$  .....

•  $r =$  .....

◆ **Théorème** :

X et Y deux variables statistiques observées sur une population d'effectif N.

- Si  $0,75 \leq |r| \leq 1$  alors il y a une relation linéaire entre X et Y ; ( $Y = aX + b$  ;  $X = a'Y + b'$ )

représentées graphiquement par deux droites passant par  $G(\bar{X}, \bar{Y})$ .

- $Y = aX + b$  : Droite de régression de Y en X avec  $a = \frac{\text{Cov}(X, Y)}{V(X)}$  et  $b = \bar{Y} - a\bar{X}$ .

- $X = a'Y + b'$  : Droite de régression de X en Y avec  $a' = \frac{\text{Cov}(X, Y)}{V(Y)}$  et  $b' = \bar{X} - a'\bar{Y}$ .

◆ **Exercice :**

Soit la série statistique suivante :

$x_i$	100	150	200	300	500
$y_i$	0,7	1	1,2	1,6	2,3

Donner les résultats arrondi à  $10^{-4}$  près si nécessaire.

- 1) Calculer le coefficient de corrélation linéaire  $r$ .
- 2) Existe-t-il une relation de type affine entre  $X$  et  $Y$ .
- 3) Déterminer une équation de la droite de régression de  $Y$  en  $X$ .
- 4) Pour  $x = 650$  que peut-on prévoir pour  $y$  ?.

◆ **Solution :**

- 1) •  $\bar{X} = \frac{1}{5}(100 + 150 + 200 + 300 + 500) = 250$  ;  
•  $V(X) = \frac{1}{5}(100^2 + 150^2 + 200^2 + 300^2 + 500^2) - 250^2 = 20000$   
•  $\sigma(X) = \sqrt{20000} \approx 141,4214$   
•  $\bar{Y} = \frac{1}{5}(0,7 + 1 + 1,2 + 1,6 + 2,3) = 1,36$  ;  
•  $V(Y) = \frac{1}{5}(0,7^2 + 1^2 + 1,2^2 + 1,6^2 + 2,3^2) - 1,36^2 \approx 0,3064$   
•  $\sigma(Y) = \sqrt{0,3064} \approx 0,5535$   
•  $\overline{XY} = \frac{1}{5}((100 \times 0,7) + (150 \times 1) + (200 \times 1,2) + (300 \times 1,6) + (500 \times 2,3)) = 418$   
•  $\text{Cov}(X, Y) = \overline{XY} - \bar{X}\bar{Y} = 418 - 250 \times 1,36 = 78$   
•  $r = \frac{\text{Cov}(X, Y)}{\sigma(X)\sigma(Y)} \approx 0,9965$   
2)  $r \approx 0,9965$  donc  $0,75 \leq r \leq 1$  alors il existe une relation de type affine entre  $X$  et  $Y$ .  
3) Equation de la droite de régression de  $Y$  en  $X$  :  $Y = aX + b$   
avec  $a = \frac{\text{Cov}(X, Y)}{V(X)} = 0,0039$  et  $b = \bar{Y} - a\bar{X} = 0,385$   
4) Si  $x = 650$  alors  $y = 0,0039 \times 650 + 0,385 = 2,92$

◆ **Utilisation de la calculatrice :** ( Exemple pour une calculatrice Sharp )

Le tableau suivant donne la distance de freinage  $d$  (en mètres) d'une voiture, en fonction de sa vitesse  $v$  ( en kilomètres par heure )

$v$ (km / h)	30	40	50	60	70	80
$d$ ( mètres)	42	60	80	90	95	110

1) Calculer  $\bar{v}$  ,  $\bar{d}$  ,  $V(v)$  ,  $V(d)$  ,  $\sigma(v)$  ,  $\sigma(d)$  ,  $Cov(v,d)$  et le coefficient de corrélation linéaire entre  $v$  et  $d$ .

2) Déterminer une équation de la droite de régression de  $d$  en  $v$  (  $d = a v + b$  ).

- Choisir le mode statistique double : 2ndF DRG 2

- Entrer les données en tapant

<span style="border: 1px solid black; padding: 2px;">30</span>	<span style="border: 1px solid black; padding: 2px;">STO</span>	<span style="border: 1px solid black; padding: 2px;">42</span>	<span style="border: 1px solid black; padding: 2px;">M+</span>
<span style="border: 1px solid black; padding: 2px;">40</span>	<span style="border: 1px solid black; padding: 2px;">STO</span>	<span style="border: 1px solid black; padding: 2px;">60</span>	<span style="border: 1px solid black; padding: 2px;">M+</span>
<span style="border: 1px solid black; padding: 2px;">50</span>	<span style="border: 1px solid black; padding: 2px;">STO</span>	<span style="border: 1px solid black; padding: 2px;">80</span>	<span style="border: 1px solid black; padding: 2px;">M+</span>
<span style="border: 1px solid black; padding: 2px;">60</span>	<span style="border: 1px solid black; padding: 2px;">STO</span>	<span style="border: 1px solid black; padding: 2px;">90</span>	<span style="border: 1px solid black; padding: 2px;">M+</span>
<span style="border: 1px solid black; padding: 2px;">70</span>	<span style="border: 1px solid black; padding: 2px;">STO</span>	<span style="border: 1px solid black; padding: 2px;">95</span>	<span style="border: 1px solid black; padding: 2px;">M+</span>
<span style="border: 1px solid black; padding: 2px;">80</span>	<span style="border: 1px solid black; padding: 2px;">STO</span>	<span style="border: 1px solid black; padding: 2px;">110</span>	<span style="border: 1px solid black; padding: 2px;">M+</span>

- $\bar{v}$  : RCL 4  $\rightarrow \bar{v} = 55$
- $\bar{d}$  : RCL 7  $\rightarrow \bar{d} = 79,5$
- $V(v)$  : RCL 6  $x^2$  =  $\rightarrow V(v) = 291,66$
- $V(d)$  : RCL 9  $x^2$  =  $\rightarrow V(d) = 511,25$
- $\sigma(v)$  : RCL 6  $\rightarrow \sigma(v) \approx 17,07$
- $\sigma(d)$  : RCL 9  $\rightarrow \sigma(d) \approx 22,61$
- $Cov(v,d)$  : RCL  $\div$   $\times$  RCL 6  $\times$  RCL 9 =  $\rightarrow Cov(v,d) = 379,166 .$
- $r$  : RCL  $\div$   $\rightarrow r \approx 0,981$
- $a$  : RCL )  $\rightarrow a = 1,3$
- $b$  : RCL (  $\rightarrow b = 8$
- Donc :  $d = 1,3v + 8$