

Série statistique à deux variables :

On considère deux variables statistiques numériques x et y observées sur une même population de n individus. On note $x_1; x_2; \dots; x_n$ les valeurs relevées pour la première variable et $y_1; y_2; \dots; y_n$ les valeurs relevées pour la deuxième variable. Les couples $(x_1; y_1); (x_2; y_2); \dots; (x_n; y_n)$ forment une **série statistique à deux variables**.

Nuage de points :

Dans le plan rapporté à un repère orthogonal, on appelle **nuage de points** associé à cette série statistique à deux variables, l'ensemble des points $M_1(x_1; y_1); M_2(x_2; y_2); \dots; M_n(x_n; y_n)$.

Point moyen :

On appelle **point moyen** de cette série le point G de coordonnées $(\bar{x}; \bar{y})$ où \bar{x} et \bar{y} sont les moyennes respectives des séries $x_1; x_2; \dots; x_n$ et $y_1; y_2; \dots; y_n$.

Ajustement :

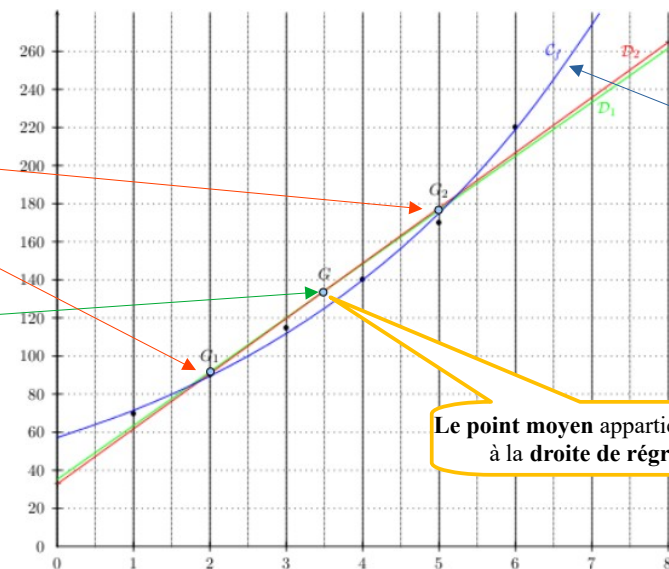
Méthode de Mayer :

Cet ajustement consiste à déterminer la droite passant par deux points moyens du nuage de points.

Méthode des moindres carrés :



Très facile à la calculatrice
Pour une Tinspire :
>Menu
>Statistiques
>Calculs statistiques
>Régression linéaire (mx+b)



Ajustement exponentiel

Le point moyen appartient toujours à la droite de régression


On parle d'**interpolation** pour des valeurs à l'intérieur de la plage des valeurs observées et d'**extrapolation** pour des valeurs à l'extérieur de cette plage.

Les formules de la méthode des moindres carrés :

Dans la pratique, on utilise directement les résultats fournis par la calculatrice.

La **droite de régression** de y en x est la droite qui minimise la somme des carrés des distances des points aux points de même abscisse de la droite.

$$\sum_{i=1}^n (M_i Q_i)^2 = \sum_{i=1}^n (y_i - (ax_i + b))^2$$



Covariance :

$$\text{cov}(x; y) = \sigma_{xy} = \frac{1}{n} \sum_{i=1}^n (x_i - \bar{x})(y_i - \bar{y}) = \frac{1}{n} \sum_{i=1}^n x_i y_i - \bar{x} \bar{y}$$

On aura aussi besoin de : $\text{cov}(x; x) = \sigma_{x^2} = V(x) = (\sigma(x))^2$ (On retrouve la variance de x)

Droite de régression :

La **droite de régression** d de y en x a pour équation $y = ax + b$ où :

$$a = \frac{\sigma_{xy}}{\sigma_{x^2}} = \frac{\sigma_{xy}}{V(x)} \quad \text{et } b \text{ vérifie } \bar{y} = a\bar{x} + b$$

Le point moyen G du nuage appartient toujours à la droite de régression de y en x .

Coefficient de corrélation linéaire :

Le **coefficient de corrélation linéaire** d'une série statistique de variables x et y est le nombre r défini par :

$$r = \frac{\sigma_{xy}}{\sigma(x) \times \sigma(y)}$$

Ce coefficient sert à mesurer la qualité d'un ajustement affine :

Plus le coefficient de corrélation linéaire est **proche de 1 en valeur absolue**, meilleur est l'**ajustement affine**.

Si $r \leq -0,75$ ou $r \geq 0,75$, on dit que la corrélation linéaire entre les séries x et y est **forte**.

Le coefficient de corrélation linéaire r vérifie $-1 \leq r \leq 1$.

Lorsque $r = \pm 1$, la droite de régression passe par tous les points du nuage, qui sont donc alignés.

Si le coefficient de corrélation est **proche de 0**, cela signifie que le nuage de points ne peut pas être ajusté au mieux par une droite. Il faut dans ce cas essayer un autre type de courbe (exponentiel ...)