

Droite de régression linéaire par la méthode des moindres carrés.

Le plan est muni du repère $(O; \vec{i}; \vec{j})$

Soit un couple de caractères (X, Y) dont le coefficient de corrélation linéaire vérifie $|\rho(X, Y)| \simeq 1$

On veut approximer Y par une fonction linéaire de X définie par $f(X) = aX + b$ de telle façon que $g(a, b) = \frac{1}{n} \sum_{i=1}^{i=n} (f(X_i) - Y_i)^2 = \frac{1}{n} \sum_{i=1}^{i=n} (aX_i + b - Y_i)^2$, moyenne des écarts au carré entre les Y_i et $f(X_i)$, soit minimum. C'est à dire trouver la droite d , d'équation $y = ax + b$, qui passe « le plus près des points du nuage ».

1 Cas particulier $\bar{X} = E(X) = 0$ et $\bar{Y} = E(Y) = 0$

$$\begin{aligned} \frac{\partial g(a, b)}{\partial a} &= \frac{2}{n} \sum_{i=1}^{i=n} X_i (aX_i + b - Y_i) = \frac{2}{n} \sum_{i=1}^{i=n} a(X_i)^2 + bX_i - X_i Y_i \\ &= 2 \left(a \frac{1}{n} \sum_{i=1}^{i=n} (X_i)^2 + b \frac{1}{n} \sum_{i=1}^{i=n} X_i - \frac{2}{n} \sum_{i=1}^{i=n} X_i Y_i \right) \\ &= 2 (aV(X) + bE(X) - cov(X; Y)) \\ &= 2 (aV(X) - cov(X; Y)) \end{aligned}$$

$$\begin{aligned} \frac{\partial g(a, b)}{\partial b} &= \frac{2}{n} \sum_{i=1}^{i=n} (aX_i + b - Y_i) = 2a \frac{1}{n} \sum_{i=1}^{i=n} X_i + b \frac{1}{n} \sum_{i=1}^{i=n} 1 - \frac{1}{n} \sum_{i=1}^{i=n} Y_i \\ &= 2 (aE(X) + b - E(Y)) = b \end{aligned}$$

Une condition nécessaire pour que (a, b) soit un minimum est que les dérivées partielles soient nulles.

$$\begin{aligned} \frac{\partial g(a, b)}{\partial a} = 0 &\Rightarrow a = \frac{cov(X; Y)}{V(X)} \\ \frac{\partial g(a, b)}{\partial b} = 0 &\Rightarrow b = 0 \end{aligned}$$

La matrice hessienne des dérivées secondes partielles est $\begin{pmatrix} V(X) & 0 \\ 0 & 1 \end{pmatrix}$, $V(X) \geq 0$ et $1 > 0$ donc ce point est un minimum.

$$y = \frac{cov(X; Y)}{V(X)} x$$

2 Cas général.

On effectue le changement d'origine $O \rightarrow G$ où $G(E(X); E(Y))$ est le point moyen.


Dans le nouveau repère les points du nuage ont pour coordonnées $M_i(X_i - E(X); Y_i - E(Y))$ donc correspondent aux caractères Z et T tels que :

$$Z = X - E(X) \text{ et } T = Y - E(Y) \Rightarrow E(Z) = E(T) = 0$$

Dans ce repère la droite de régression linéaire a pour équation : $y = \frac{\text{cov}(Z; T)}{V(Z)} x$

On sait que : $V(X - E(X)) = V(X)$ et $\text{cov}(X - E(X); Y - E(Y)) = \text{cov}(X; Y)$ donc l'équation s'écrit :

$$y = \frac{\text{cov}(X; Y)}{V(X)} x .$$



Un changement d'origine conserve le coefficient directeur, a , d'une droite donc dans le repère $(O; \vec{i}; \vec{j})$ l'équation de la droite de régression linéaire est :

$$y = \frac{\text{cov}(X; Y)}{V(X)} x + b .$$

Cette droite passe par le point moyen $G(E(X); E(Y))$:

$$E(Y) = \frac{\text{cov}(X; Y)}{V(X)} E(X) + b \text{ donc } b = E(Y) - \frac{\text{cov}(X; Y)}{V(X)} E(X)$$