

# Chap. La régression simple linéaire

## I/ Introduction

étant donné un couple de v. o. numériques  $(X, Y)$ . Si  $X$  et  $Y$  ne sont pas indépendantes, la connaissance de la valeur prise par  $X$  change notre incertitude concernant la réalisation de  $Y$ : elle lui diminue généralement, car la variance de la distribution de  $Y | X = x$  est en moyenne inférieure à la variance de  $Y$ :  $E(V(Y|X)) < V(X)$  (théorème de la var totale). Lorsqu'on peut admettre que  $X$  peut servir pour se prédire  $Y$ , on doit alors chercher une formule de prédiction de  $Y$  par  $X$  de type de  $\hat{Y} = f(X)$  sans biais  $E(\hat{Y} - Y) = 0$ , ainsi qu'à évaluer l'ordre de grandeur de l'erreur de prédiction qui est mesurée par  $\text{Var}(e) = \text{Var}(Y - \hat{Y})$ . On cherche bientôt à minimiser  $\text{Var}(e)$ .

Dans ce chap nous cherchons la formule de prédiction "idéale" au sens des moindres carrés, particulièrement, le cas où cette formule est linéaire avec un écart-type conditionnel  $C^t$

$$\sigma(e | X = x) = \sigma < \infty \text{ dit homoscédasité}$$

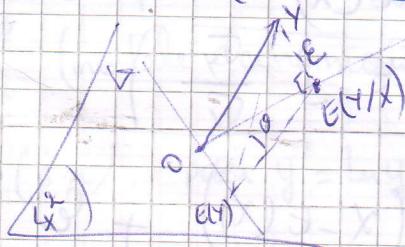
$X$  est dite variable explicative ou prédicteur

$Y$  est dite variable à expliquer ou cible

## II) Méthode de régression simple

### II.1) Approximation conditionnelle.

Considérons deux v. o.  $Y$  et  $X$ , pour trouver la meilleure formule qui est le plus proche possible de  $Y$  en moyenne quadratique menant à minimiser  $E((Y - f(X))^2)$



$L_x^2$  est l'espace des v. o. de type  $f(X)$   
 $E(Y|X)$  est la projection de  $Y$  sur  $L_x^2$   
 $e$  des rés.

La qualité de l'approximation de  $Y$  par  $E(Y/x)$  est mesurée par le rapport de  $\eta_{Y/x}^2 = \frac{V(E(Y/x))}{V(Y)} = \frac{\text{Variance expliquée}}{\text{Variance totale}} = \cos^2 \theta$

Pour une valeur  $x$  de  $X$ ; on associe  $E(Y/x=x)$  dite fonction de régression de  $Y$  en  $X$ ; son graphe est la courbe de régression de  $Y$  sur  $X$ .  
on peut donc poser  $Y = E(Y/x=x) + \varepsilon$   
où  $\varepsilon$  est un résidu qui n'est pas très négligeable.

$$\text{on a } E(Y) = E(E(Y/x)) \Rightarrow E(\varepsilon) = 0$$

De plus  $\varepsilon$  est non corrélé linéairement avec  $X$  et avec  $E(Y/x)$  car  $\varepsilon$  est orthogonale à  $L_x^2$ .

La variance de  $\varepsilon$ , ou variance résiduelle est alors  $V(\varepsilon) =$

$$Var(\varepsilon) = Var(Y) = Var(E(Y/x))$$

$$\text{et d'après (*) } Var(E(Y/x)) = \eta_{Y/x}^2 \cdot Var(Y)$$

$$V(\varepsilon) = Var(Y) = \eta_{Y/x}^2 \cdot Var(Y) = (1 - \eta_{Y/x}^2) Var(Y)$$

## II.2) Cas de la régression linéaire

En général, en pratique, on utilise le cas où  $E(Y/x) = \alpha + \beta X$  (ce qui se produit en particulier si  $X$  et  $Y$  suivent une loi normale à deux dimensions)

$$\text{on a donc } Y = \alpha + \beta X + \varepsilon. \quad (1)$$

$$E(Y) = \alpha + \beta E(X) \quad (2)$$

La droite de régression passe donc par le p<sup>t</sup>  $(E(X), E(Y))$

$$(1)-(2) \text{ on a } Y - E(Y) = \beta(X - E(X)) + \varepsilon \quad (3)$$

$$\Rightarrow (Y - E(Y))(X - E(X)) = \beta(X - E(X))^2 + \varepsilon(X - E(X))$$

$$\text{et } E((Y - E(Y))(X - E(X))) = \beta E((X - E(X))^2) + E(\varepsilon) \cdot E(X - E(X))$$

$$\Rightarrow \text{cov}(Y, X) = \beta \text{Var}(X)$$

$$\Leftrightarrow \boxed{\beta = \frac{\text{cov}(Y, X)}{\text{Var}(X)} = \frac{\int \frac{\partial Y}{\partial X}}{\int X}}$$

$$(3) \text{ devient } Y - E(Y) = \int \frac{\partial Y}{\partial X} (X - E(X)) + \varepsilon$$

ce qui fait  $\gamma = E(Y) + \rho \frac{\sigma_Y}{\sigma_X} (X - E(X)) + \epsilon$

$$\begin{aligned} \text{Var}(Y) &= \text{Var}(E(Y) + \rho \frac{\sigma_Y}{\sigma_X} (X - E(X)) + \epsilon) \\ &= \rho^2 \frac{\sigma_Y^2}{\sigma_X^2} \text{Var}((X - E(X))) + \text{Var}(\epsilon) \\ &= \rho^2 \frac{\sigma_X^2}{\sigma_X^2} \text{Var}(X) + \text{Var}(\epsilon) \\ &= \rho^2 \sigma_X^2 + (1 - \rho^2_{Y/X}) \text{Var}(Y) \end{aligned}$$

$$(\Rightarrow) \quad 1 = \rho^2 + 1 - \rho^2_{Y/X}$$

$$(\Leftarrow) \quad \boxed{\rho^2 = \rho^2_{Y/X}}$$

### II-3 / Ajustement de la régression linéaire par des données expérimentales

Soient  $n$  couple de la.v.a  $(X, Y)$ :  $(x_i, y_i)$   $i = 1, \dots, n$  échantillon de  $(X, Y)$

On suppose qu'on  $E(Y/X) = \alpha + \beta X$

Le pb est donc d'estimer les coefficients réels  $\alpha$  &  $\beta$  tels que la variance des résidus  $\sigma^2$

Réf Cette méthode s'applique aussi lorsque la v.  $X$  n'est pas aléatoire mais contrôlée par l'expérimentateur.

comme exp, mesurer la grandeur  $Y$  à des instants  $x_i$  fixés

$Y$  est aléatoire grâce aux erreurs  $\epsilon$  mais  $X$  non aléatoire.

on a alors  $y_i = \alpha x_i + \beta x_i + \epsilon_i$   $i = 1, n$

Où  $\epsilon_i$  sont des réalisations indépendantes de moyenne nulle et de variance  $\sigma^2 < \infty$ . On parle alors de modèle linéaire plutôt que de régression linéaire.

Réf. on parle de corrélation entre  $Y$  et  $X$  que lorsque  $X$  est aléatoire

• de nombreux modèles non linéaires se ramènent facilement au modèles linéaire par une simple transformation tel que

-  $y \# \propto x^\beta$  (modèle économique) en poser  $\ln y' = \ln y = \ln \alpha + \beta \ln x$   
 $= \alpha' + \beta' x'$

-  $y \approx \alpha \exp(\beta x)$  poser  $y' = \ln y = \ln \alpha + \beta x$  . modèle croissance expo

$$- y = \frac{\exp(\alpha + \beta x)}{1 + \exp(\alpha + \beta x)}$$

on pose  $y' = \ln \frac{y}{1-y}$  modèle de logistique

alors  $y' = \alpha + \beta x$

En effet on a  $\frac{y}{1-y} = \exp(y')$  ( $\Rightarrow$ )  $\frac{\exp(\alpha + \beta x)}{[1 + \exp(\alpha + \beta x)]}$

$$y = (1-y) \exp(y') \quad (\Rightarrow) \quad y + y \exp(y') = \exp(y')$$

D'où,  $\frac{e^{y'}}{1+e^{y'}} = \frac{e^{\alpha+\beta x}}{1+\exp(\alpha+\beta x)}$  ( $\Rightarrow$ )  $y = \frac{e^y}{1+e^y}$

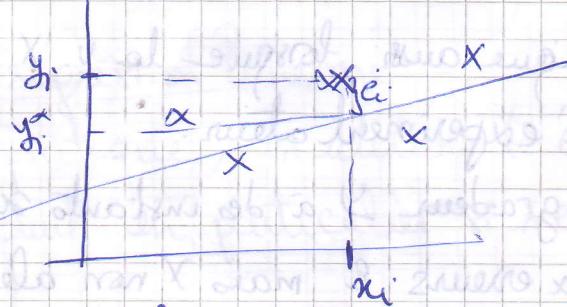
$$y' = \alpha + \beta x.$$

### a/ Estimation des paramètres $\alpha, \beta$ et $\sigma^2$

On utilise le critère des moindres carrés, sachant que  $E(Y/x) = \alpha + \beta x$

est la meilleure approximation de  $Y$  par  $x$ . en moyenne quadratique  
on cherche donc à ajuster le nuage  $(x_i, y_i)$  par une droite

d'équation  $y^* = \hat{a}x + \hat{b}x$  de sorte que  $\sum_{i=1}^n (y_i - y_i^*)^2$  soit minimal



$$\Delta(a, b) = \sum_{i=1}^n (y_i - y_i^*)^2 = \sum_{i=1}^n (y_i - a - b x_i)^2$$

$$\min \Delta(a, b) \Rightarrow \begin{cases} \frac{\partial \Delta(a, b)}{\partial a} = 0 \\ \frac{\partial \Delta(a, b)}{\partial b} = 0 \end{cases}$$

La solution

$$\hat{b} = \frac{\sum_{i=1}^n (y_i - \bar{y})(x_i - \bar{x})}{\sum_{i=1}^n (x_i - \bar{x})^2} = r \frac{s_y}{s_x} = \frac{\text{cov}(x, y)}{s_x^2}$$

$$\hat{a} = \bar{y} - \hat{b} \bar{x}$$

$$y^* = \bar{y} + r \frac{s_y}{s_x} (x - \bar{x})$$

Rq: La droite des moindres carrés passe par le centre de gravité du nuage  $G = \left( \begin{matrix} \bar{x} \\ \bar{y} \end{matrix} \right)$  et sa pente est l'analogue "valeur" empirique de la pente de droite de régression  $\hat{f}_{\bar{x}}$

### Théorème 1

$\hat{a}$ ,  $\hat{b}$ , et  $\hat{y}^*$  sont des estimateurs sans biais de  $a$ ,  $b$  et  $E(Y/x=x_i) = a + b x_i$ .  
 $\hat{b} = \frac{\sum (y_i - \bar{y})(x_i - \bar{x})}{\sum (x_i - \bar{x})^2}$  est la réalisation de la v.a:

$$\hat{b} = \frac{\sum_{i=1}^n (x_i - \bar{x})^2}{\sum_{i=1}^n (y_i - \bar{y})(x_i - \bar{x})} = \frac{\sum_{i=1}^n (x_i - \bar{x})^2}{\sum_{i=1}^n (x_i - \bar{x})^2} E(B/x=x_i) = \frac{\sum_{i=1}^n (x_i - \bar{x}) E(Y_i - \bar{Y}/x_i=x_i)}{\sum_{i=1}^n (x_i - \bar{x})^2}$$

comme  $E(Y/x=x_i) = a + b x_i$   
 $E(\bar{Y}/x=x_i) = a + b \bar{x} \Rightarrow E(Y_i - \bar{Y}/x_i=x_i) = b(x_i - \bar{x})$

Alors

$$E(B/x=x_i) = \frac{\sum_{i=1}^n (x_i - \bar{x}) b (x_i - \bar{x})}{\sum_{i=1}^n (x_i - \bar{x})^2} = b \frac{\sum (x_i - \bar{x})^2}{\sum (x_i - \bar{x})^2} = b$$

D'où  $E(E(B/x=x_i)) = E(B) = b$

comme  $a = \bar{y} - b \bar{x}$  donc  $a$  est la réalisation de la v.a  $A = \bar{Y} - B \bar{x}$   
 et par le même procédé

$$\begin{aligned} E(A/x=x_i) &= E(\bar{Y}/x=x_i) - E(B\bar{x}/x=x_i) \\ &= a + b \bar{x} - \bar{x} E(B/x=x_i) \\ &= a + b \bar{x} - \bar{x} b = a. \end{aligned}$$

Et  $E(E(A/x=x_i)) = E(A) = a$ .

comme  $E(Y/x=x) = a + b x$  et  $y^* = \hat{a} + \hat{b} x$

$$E(Y) = E(a + b x) = a + b x \quad E(y^*) = E(\hat{a}) + \hat{b} \hat{x} \cdot n = a + b x$$

Ainsi  $a + b x$  est estimateur sans biais de  $y^*$

### Propriétés

$B$  non corréle avec  $\bar{Y}$  en effet,

$$\hat{b} = \frac{\sum (x_i - \bar{x})(y_i - \bar{y})}{\sum (x_i - \bar{x})^2} = \frac{\sum (x_i - \bar{x}) y_i}{\sum (x_i - \bar{x})^2} - \frac{\bar{y} \sum_{i=1}^n (x_i - \bar{x})}{\sum_{i=1}^n (x_i - \bar{x})^2}$$

$$\begin{aligned}\text{cov}(B, \bar{Y}) &= \text{cov}\left(\frac{\sum(x_i - \bar{x})y_i}{\sum(x_i - \bar{x})^2}, \bar{Y}\right) \\ &= \frac{1}{\sum(x_i - \bar{x})^2} \sum_{i=1}^n (x_i - \bar{x}) \text{cov}(y_i, \bar{Y}) \\ &= \frac{1}{\sum(x_i - \bar{x})^2} \cdot \sum_{i=1}^n (x_i - \bar{x}) \text{cov}(y_i, \frac{1}{n} \sum_{j=1}^n y_j)\end{aligned}$$

$(y_1, \dots, y_n)$  indép alors  $\text{cov}(y_i, y_j) = 0$  sauf pour  $i=j$

$$\begin{aligned}\text{cov}(B, \bar{Y}) &= \frac{1}{\sum(x_i - \bar{x})^2} \sum_{i=1}^n (x_i - \bar{x}) \frac{1}{n} \text{cov}(y_i, y_i) \\ &= \frac{\sigma^2}{n \sum_{i=1}^n (x_i - \bar{x})^2} \sum_{i=1}^n (x_i - \bar{x}) = 0\end{aligned}$$

D'où  $B$  et  $\bar{Y}$  non corrélés.

### Théorème de Gauss - Markov

$A$  et  $B$  sont des estimateurs sans biais de  $\alpha$  et  $\beta$  de variance minimale.

Preuve ultérieurement.

Calcul de la variance conditionnelle de  $B$  pour  $X$  fixe.

$$V(B/x=x_i) = V\left(\frac{\sum(x_i - \bar{x})y_i}{\sum(x_i - \bar{x})^2}\right) = \frac{\sum((x_i - \bar{x})y_i)_{|x=x_i} \cdot \sum(x_i - \bar{x})^2}{\left[\sum(x_i - \bar{x})^2\right]^2} V(Y_i)_{|x=x_i}$$

$$V(B) = \frac{\sigma^2}{\sum(x_i - \bar{x})^2}$$

car pour  $X$  fixe  $V(Y_i/x=x_i) = V(\alpha + \beta x_i + \varepsilon_i) = V(\varepsilon_i) = \sigma^2$

D'autre part  $A = \bar{Y} - \bar{X}B$

$$V(A) = V(\bar{Y} - \bar{X}B) \text{ et } V(A/x=x_i) = V(\bar{Y}) + \bar{x}^2 V(B) = \frac{\sigma^2}{n} + \bar{x}^2 \frac{\sigma^2}{\sum(x_i - \bar{x})^2}$$

$$V(A) = \sigma^2 \left( \frac{1}{n} + \frac{\bar{x}^2}{\sum(x_i - \bar{x})^2} \right)$$

Pour estimer la variance  $\sigma^2$  des résidus  $\epsilon$ , il est naturel de penser à estimer la variance des résidus  $e_i = y_i - \hat{y}_i$

Théorème

$$\hat{\sigma}^2 = \frac{\sum_{i=1}^n (y_i - \hat{y}_i)^2}{(n-2)} \text{ est un estimateur sans biais de } \sigma^2$$

Propriété des écarts rendus

$$e_i = y_i - \hat{y}_i \text{ écart résiduel.}$$

1) Théorème.

$E(e_i) = 0$  et  $e_i$  de moyenne nulle.

Preuve.

$$\hat{y}_i = \bar{y} + b(x_i - \bar{x})$$

$$\sum e_i = \sum_{i=1}^n (y_i - \hat{y}_i) = \sum_{i=1}^n (\bar{y} - y_i) + b \sum_{i=1}^n (x_i - \bar{x}) = 0$$

Ceci prouve que les résidus  $e_i$  ne sont pas des réalisations d'une v.a. indépendante

Variance empirique des résidus

$$\begin{aligned} \frac{1}{n} \sum_{i=1}^n e_i^2 &= \frac{1}{n} \sum_{i=1}^n (y_i - \bar{y} + b(x_i - \bar{x}))^2 \\ &= \frac{1}{n} \sum_{i=1}^n (y_i - \bar{y})^2 + b^2 \sum_{i=1}^n (x_i - \bar{x})^2 + \frac{2b}{n} \sum_{i=1}^n (y_i - \bar{y})(x_i - \bar{x}) \\ &= S_y^2 + \frac{b^2}{n} S_x^2 - 2b \operatorname{cov}(x, y) \\ &= S_y^2 + \frac{b^2}{n} S_x^2 \end{aligned}$$

$$\text{avec } b = r \frac{S_y}{S_x} = \frac{\operatorname{cov}(x, y)}{S_x^2}$$

$$\begin{aligned} \frac{1}{n} \sum_{i=1}^n e_i^2 &= S_y^2 + r^2 \frac{S_y^2}{S_x^2} \cdot S_x^2 - 2r \frac{S_y}{S_x} \cdot r \frac{S_y}{S_x} \cdot S_x \\ &= S_y^2 + r^2 S_y^2 - 2r^2 \frac{S_y^2}{S_x^2} = (1 - r^2) S_y^2 + 2r^2 S_x^2 \end{aligned}$$

III / Cas où les  $\epsilon$  suivent une loi normale.

Tout les résultats établis précédemment reposent uniquement que  $E(Y|X) = \alpha + \beta X$

Supposons de plus que  $\epsilon \sim N(0, \sigma^2)$

On a.

a)  $Y|X=x \sim N(\alpha + \beta x; \sigma)$

b) B, A et  $y^*$  suivent des lois pour les  $x_i$  fixes, gaussiennes car ils sont combinaisons linéaires des lois de Gauss.

$$B \sim N(\beta, \frac{\sigma}{\sqrt{\sum(x_i - \bar{x})^2}})$$

$$A \sim N(\beta, \sigma \sqrt{\frac{1}{n} + \frac{\bar{x}^2}{\sum(x_i - \bar{x})^2}})$$

$$y^* \sim N(\alpha + \beta x; \sigma \sqrt{\frac{1}{n} + \frac{(x - \bar{x})^2}{\sum(x_i - \bar{x})^2}})$$

c) A, B et  $\hat{\sigma}^2$  sont des estimateurs de variance minimale de  $\alpha, \beta, \sigma^2$

d)  $\frac{(n-2)\hat{\sigma}^2}{\sigma^2} = \frac{\sum(y_i - \hat{y}_i)^2}{\sigma^2} = \frac{nS_{yx}^2}{\sigma^2} \sim \chi^2_{n-2}$  indépendante

de  $\bar{Y}$ , B et de A.

Rq:

A et B ne sont pas indépendants.

de b) on a.

$$\frac{B - \beta}{\frac{\sigma}{\sqrt{\sum(x_i - \bar{x})^2}}} \sim N(0, 1) \text{ et } \frac{nS_{yx}^2}{\sigma^2} \sim \chi^2_{n-2}$$

$$\text{alors } \frac{(B - \beta)S_{yx}}{\sqrt{n-2}} \sim T_{n-2}$$

Ce qui permet de construire des intervalles de confiance pour  $\beta$

de même  $\frac{A - \alpha}{\sigma \sqrt{\frac{1}{n} + \frac{\bar{x}^2}{\sum(x_i - \bar{x})^2}}} \sim N(0, 1)$

$$\frac{A - \alpha}{\sigma \sqrt{\frac{1}{n} + \frac{\bar{x}^2}{\sum(x_i - \bar{x})^2}}} \cdot \frac{\sigma}{\sqrt{n} S_{yx}} \sim T_{n-2}$$

## II / Intervalles de confiance

On a

$$T = \frac{(B - b) S_x}{S_{yx} \sqrt{n-2}} \sim T_{n-2}$$

$$u \leq T \leq v \quad (\Leftrightarrow) \quad \frac{S_{yx}}{S_x \sqrt{n-2}} u \leq B - b \leq \frac{S_{yx}}{S_x \sqrt{n-2}} v$$

$$( \Rightarrow ) B - \frac{S_{yx}}{S_x \sqrt{n-2}} v \leq b \leq - \frac{S_{yx}}{S_x \sqrt{n-2}} + B$$

tg  $P(u \leq T \leq v) = 1-\alpha$ ;  $u$  et  $v$  donnés par la table  $T_{n-2}$

$$\text{et } B = \frac{\sum_{i=1}^n (y_{xi} - \bar{y})(x_i - \bar{x})}{\sum_{i=1}^n (x_i - \bar{x})^2}$$

i) On a

$$U = \frac{A - a}{\sqrt{\frac{1}{n} + \frac{\bar{x}}{\sum (x_i - \bar{x})^2}}} \sim T_{n-2}$$

$$u \leq U \leq v \quad (\Rightarrow) u \sqrt{\frac{1}{n} + \frac{\bar{x}}{\sum (x_i - \bar{x})^2}} \leq A - a \leq v \sqrt{\frac{1}{n} + \frac{\bar{x}}{\sum (x_i - \bar{x})^2}} \cdot \frac{\sqrt{n} S_{yx}}{\sqrt{n-2}}$$

$$\text{et } A - v \sqrt{\frac{1}{n} + \frac{\bar{x}}{\sum (x_i - \bar{x})^2}} \leq a \leq A - u \sqrt{\frac{1}{n} + \frac{\bar{x}}{\sum (x_i - \bar{x})^2}} \cdot \frac{\sqrt{n} S_{yx}}{\sqrt{n-2}}$$

$u$  et  $v$  donnés par la table de Student  $T_{n-2}$

## III / Erreurs d'estimation

Soit  $\hat{y}_i = \hat{a} + \hat{b} x_i$  moyen

Les résidus quadratiques est la quantité donnée par:

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

On a:

$$\begin{aligned} y_i - \hat{y}_i &= y_i - \hat{a} - \hat{b} x_i = y_i - \left( \bar{y} - \frac{S_{xy}}{S_x^2} \bar{x} \right) - \left( \frac{S_{xy}}{S_x^2} \right) x_i \\ &= y_i - \bar{y} + \frac{S_{xy}}{S_x^2} (\bar{x} - x_i) \end{aligned}$$

$$\begin{aligned}
 \eta^2 &= \frac{1}{n} \sum_{i=1}^n (y_i - \hat{y}_i)^2 \\
 &= \frac{1}{n} \sum_{i=1}^n \left[ (y_i - \bar{y}) - \frac{S_{xy}}{S_x^2} (x_i - \bar{x}) \right]^2 \\
 &= \frac{1}{n} \sum_{i=1}^n (y_i - \bar{y})^2 + \frac{S_{xy}^2}{S_x^4} (\bar{x} - \bar{x})^2 - 2 \frac{S_{xy}}{S_x^2} (y_i - \bar{y})(x_i - \bar{x}) \\
 &= \frac{1}{n} \sum_{i=1}^n (y_i - \bar{y})^2 + \frac{S_{xy}^2}{S_x^4} \frac{1}{n} \sum_{i=1}^n (x_i - \bar{x})^2 - 2 \frac{S_{xy}}{S_x^2} \frac{1}{n} \sum_{i=1}^n (y_i - \bar{y})(x_i - \bar{x}) \\
 &= \frac{1}{n} \sum_{i=1}^n (y_i - \bar{y})^2 + \frac{S_{xy}^2}{S_x^4} S_x^2 - 2 \frac{S_{xy}}{S_x^2} \cdot S_{xy} \\
 \eta^2 &= \frac{1}{n} \sum_{i=1}^n (y_i - \bar{y})^2 - \frac{S_{xy}^2}{S_x^2} \\
 \boxed{\eta^2 = \frac{S_y^2}{S_x^2} - \frac{S_{xy}^2}{S_x^2}}
 \end{aligned}$$

On pose  $r = \frac{S_{xy}}{S_x S_y}$  alors  $\eta^2 = S_y^2(1 - r^2)$

$r$  est appelé coefficient de corrélation empirique entre  $X$  et  $Y$

Rq : Si  $\eta^2 = 0$  ( $\Rightarrow y_i = \hat{y}_i$ ) si les points  $(x_i, y_i)$  sont alignés

Interprétation du coefficient de corrélation empirique

Proposition

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

Preuve

$$\begin{aligned}
 (y_i - \bar{y})^2 &= (y_i - \hat{y}_i + \hat{y}_i - \bar{y})^2 \\
 &= (y_i - \hat{y}_i)^2 + (\hat{y}_i - \bar{y})^2 + 2(y_i - \hat{y}_i)(\hat{y}_i - \bar{y})
 \end{aligned}$$

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

$$\begin{aligned}
\sum_{i=1}^n (y_i - \hat{y}_i)(\hat{y}_i - \bar{y}) &= \sum_{i=1}^n (y_i - \hat{y}_i)\hat{y}_i - \bar{y} \sum_{i=1}^n (y_i - \hat{y}_i) \\
&= \sum_{i=1}^n (y_i - \hat{y}_i) \left( \bar{y} - \frac{S_{xy}}{S_x^2} \bar{x} + \frac{S_{xy}}{S_x^2} x_i \right) - \bar{y} \sum_{i=1}^n (y_i - \hat{y}_i) \\
&= \bar{y} \sum_{i=1}^n (y_i - \hat{y}_i) - \frac{S_{xy}}{S_x^2} \bar{x} \sum_{i=1}^n (y_i - \hat{y}_i) + \frac{S_{xy}}{S_x^2} \sum_{i=1}^n x_i (y_i - \hat{y}_i) - \bar{y} \sum_{i=1}^n (y_i - \hat{y}_i) \\
&= \frac{S_{xy}}{S_x^2} \sum_{i=1}^n (x_i - \bar{x})(y_i - \hat{y}_i) \\
&= \frac{S_{xy}}{S_x^2} \sum_{i=1}^n (x_i - \bar{x}) (y_i - \bar{y} + \frac{S_{xy}}{S_x^2} \bar{x} - \frac{S_{xy}}{S_x^2} x_i) \\
&= \frac{S_{xy}}{S_x^2} \sum_{i=1}^n (x_i - \bar{x}) (y_i - \bar{y}) + \left( \frac{S_{xy}}{S_x^2} \right)^2 \sum_{i=1}^n (x_i - \bar{x})^2 \\
&= n \frac{S_{xy}}{S_x^2} - n \frac{S_{xy}}{S_x^2} = 0
\end{aligned}$$

CQFD.

$$\text{Comme } r^2 = S_y^2 (1 - r^2)$$

$$( \Leftrightarrow ) 1 - r^2 = \frac{n^2}{S_y^2} = \frac{\frac{1}{n} \sum_{i=1}^n (y_i - \hat{y}_i)^2}{\frac{1}{n} \sum_{i=1}^n (y_i - \bar{y})^2}$$

$$\text{Alors } r^2 = 1 - \frac{\frac{1}{n} \sum_{i=1}^n (y_i - \hat{y}_i)^2}{\frac{1}{n} \sum_{i=1}^n (y_i - \bar{y})^2}$$

$$\text{Et } \sum_{i=1}^n (y_i - \hat{y}_i)^2 = \sum_{i=1}^n (y_i - \bar{y})^2 - \sum_{i=1}^n (\hat{y}_i - \bar{y})^2$$

$$r^2 = 1 - \frac{\frac{1}{n} \sum_{i=1}^n (y_i - \bar{y})^2 - \sum_{i=1}^n (\hat{y}_i - \bar{y})^2}{\frac{1}{n} \sum_{i=1}^n (y_i - \bar{y})^2} = \frac{\sum_{i=1}^n (\hat{y}_i - \bar{y})^2}{\sum_{i=1}^n (y_i - \bar{y})^2}$$

$$r^2 = \frac{\text{Ecart expliqué}}{\text{Ecart total}}$$

est une mesure de la quantité d'ajustement des moindres carrés

par la droite de régression

qd  $r^2 \rightarrow 1$  ( $\Rightarrow \hat{y}_i$  est très proche de  $y_i \Rightarrow$  la droite est un bon ajustement du nuage des p<sup>b</sup> ( $x_i, y_i$ )

Si  $r^2 \rightarrow 0 \Leftrightarrow \hat{y}_i$  loin de  $y_i \Rightarrow$  la droite n'est pas la bonne modélisation

F

P