

# Chapitre 6: Regression linéaire simple

## 1 Introduction

Dans ce chapitre, on s'intéresse à des situations où on observe deux variables  $X$  et  $Y$  sur chaque unité statistique et on aimerait pouvoir prédire  $Y$  en fonction de  $X$ .  $Y$  s'appelle la **variable dépendante** ou variable réponse.  $X$  s'appelle la **variable explicatrice**, variable indépendante, ou régresseur.

On s'intéresse à des situations où  $Y$  n'est pas une fonction déterministe de  $X$ . Autrement dit, c'est possible d'avoir des unités statistiques qui ont la même valeur de  $X$  mais des valeurs différentes de  $Y$ . Cette différence peut être due à:

- Des erreurs de mesure.
- L'existence d'autres variables dont on ne serait pas entrain de tenir compte.

**Exemple 1.1.** On cherche à prédire la taille  $Y$  en fonction de l'âge  $X$ . On sait tous que la taille fluctue parmi des personnes de même âge. Mais on sait aussi "qu'en moyenne" la taille augmente avec l'âge (jusqu'en début de l'âge adulte).

Soit  $\mu_{Y|x}$  la moyenne de  $Y$  parmi les unités pour lesquelles  $X = x$ . On va utiliser le modèle suivant pour expliquer la relation entre  $X$  et  $Y$ :

$$Y = \mu_{Y|x} + \varepsilon, \quad (1.1)$$

où  $\varepsilon$  est une variable aléatoire qui rend compte des fluctuations qu'on pourrait observer parmi les unités qui ont la même valeur de  $X$ .

**Definition 1.1.** La fonction  $\mu_{Y|x}$  vue comme fonction de  $x$  s'appelle la **courbe de régression** de  $Y$  sur  $X$ .

**Exemple 1.2.** Dans la population des hommes, on s'intéresse à la taille ( $Y$ ) en fonction de l'âge ( $X$ ).  $\mu_{Y|10}$  serait alors la taille moyenne des garçons de 10 ans.

Dans ce chapitre, on s'intéresse à l'estimation de fonction de régression. C'est un problème difficile à résoudre en général. On va se limiter à l'estimation de fonctions de régression **linéaire simple**.

**Definition 1.2.** Une fonction de régression  $\mu_{Y|x}$  est dite linéaire simple si

$$\mu_{Y|x} = a + bx. \quad (1.2)$$

L'adjectif "simple" vient du fait qu'on cherche à prédire  $Y$  avec seulement **une seule** variable  $X$ . Si on laisse  $Y$  dépendre de plusieurs variables explicatrices  $X_1, \dots, X_k$ , on parlerait de régression multiple.

On parle de **modèle** linéaire simple lorsqu'on **postule** que la fonction de régression en présence est linéaire simple. Il s'écrit:

$$Y = a + bX + \varepsilon. \quad (1.3)$$

Objectif:

1. Comment partir d'un échantillon de  $(X_1, Y_1), \dots, (X_n, Y_n)$  pour estimer les coefficients  $a$  et  $b$  d'un modèle de régression linéaire simple.
2. Comment prédire la valeur de  $Y$  connaissant la valeur de  $X$  sur une unité.

## 2 Estimation d'un modèle de regression linéaire simple: la méthode des moindres carrés


La démarche pour estimer une fonction lineaire simple est la suivante:

1. Obtenir un echantillon  $(x_1, y_1), (x_2, y_2), \dots, (x_n, y_n)$  ou  $(x_i, y_i)$  sont les valeurs observées pour  $X$  et  $Y$  sur l'unité  $i$ .
2. Dessiner le nuage des points  $(x_i, y_i)$ . Si ce nuage à une tendance linéaire, alors on peut raisonnablement **modéliser** la fonction de regression par un modele de regression lineaire simple. On utilise alors la méthode des moindres carrés pour estimer  $a$  et  $b$ .
3. Si la tendance n'est pas linéaire, le modele de regression lineaire simple n'est donc approprié.

**Exemple 2.1.** Soit deux echantillons de points  $(X, Y)$ .

$x$	1.0	1.1	1.5	1.7	2.0	2.5	3.0	3.0	3.0	3.1	3.2	3.5	3.6	4.0
$y$	0.2	0.24	0.60	0.66	1.48	4.92	14.80	10.96	12.11	16.35	4.03	32.94	29.80	81.03
$x$	1.0	1.1	1.5	1.7	2.0	2.5	3.0	3.0	3.1	3.2	3.5	3.6	4.0	
$y$	3.0	3.2	4.1	4.2	5.0	6.2	7.3	7.0	7.1	7.4	6.0	8.1	8.0	9.0

Le graphe des nuages de points donne:



On voit que le nuage 1 n'a pas une tendance lineaire, mais une tendance plutot exponentielle. On ne peut donc pas utiliser le modele lineaire simple dans ce cas. Mais le nuage 2 a bien une tendance lineaire. Dans ce cas, il parait raisonnable de modeliser sa courbe de regression par l'equation 1.2.

### 2.1 Méthodes des moindres carrés

Le modèle de régression lineaire simple s'écrit:

$$Y_i = a + bx_i + \varepsilon_i, \quad (2.1)$$

ou chaque  $\varepsilon_i \sim N(0, \sigma^2)$ . On cherche à estimer  $a$  et  $b$  à partir des données  $(x_1, y_1), \dots, (x_n, y_n)$ .

Le principe des moindres carrés revient à estimer  $a$  et  $b$  par les valeurs qui minimisent:

$$\sum_{i=1}^n (y_i - a - bx_i)^2. \quad (2.2)$$

On montre facilement le

**Theoreme 2.1.** *Posons*

$$\bar{x} = \frac{1}{n} \sum_{i=1}^n x_i, \quad \text{et} \quad \bar{y} = \frac{1}{n} \sum_{i=1}^n y_i, \quad (2.3)$$

$$S_{xx} = \sum_{i=1}^n x_i^2 - \frac{1}{n} \left( \sum_{i=1}^n x_i \right)^2, \quad (2.4)$$

$$S_{yy} = \sum_{i=1}^n y_i^2 - \frac{1}{n} \left( \sum_{i=1}^n y_i \right)^2, \quad (2.5)$$

and

$$S_{xy} = \sum_{i=1}^n x_i y_i - \frac{1}{n} \left( \sum_{i=1}^n x_i \right) \left( \sum_{i=1}^n y_i \right). \quad (2.6)$$

Alors les valeurs de  $a$  et  $b$  qui minimisent  $\sum_{i=1}^n (y_i - a - bx_i)^2$  sont données par:

$$\hat{a} = \bar{y} - b\bar{x} \quad \text{et} \quad \hat{b} = \frac{S_{xy}}{S_{xx}}. \quad (2.7)$$

- $\hat{a}$  et  $\hat{b}$  s'appellent les estimateurs des moindres carrés de  $a$  et  $b$ .
- $\hat{y} = \hat{a} + \hat{b}x$  s'appelle la valeur estimée ou la prediction de  $y$ .
- la droite d'équation  $y = \hat{a} + \hat{b}x$  s'appelle la droite de regression estimée de  $Y$  sur  $X$ .
- $e_i = y_i - \hat{y}_i$  s'appelle le residu de l'observation  $i$ .
- La somme des carrés des résidus est

$$\begin{aligned} SSE &= \sum_{i=1}^n (y_i - \hat{a} - \hat{b}x_i)^2 \\ &= S_{yy} - \frac{S_{xy}^2}{S_{xx}}. \end{aligned}$$

**Exemple 2.2.** On a les données suivantes:


$x$	12.8	13.9	14.1	14.7	15.0	15.1	16.0	16.5	16.6	17.2	17.9
$y$	110	54	98	50	67	58	52	50	43	15	28

On cherche la droite de regression lineaire de  $y$  sur  $x$ .

On a besoin de calculer:  $\bar{x}$ ,  $\bar{y}$ ,  $S_{xx}$  et  $S_{xy}$ . A partir des données on a:

$$\begin{aligned} \sum x_i &= 169.8, \quad \sum y_i = 625, \quad \sum x_i y_i = 9286.2, \quad \sum x_i^2 = 2645.02. \quad \text{D'ou: } S_{xx} = \sum x_i^2 - (\sum x_i)^2/n = \\ &2645.02 - \frac{169.8^2}{11} = 23.92., \quad S_{xy} = \sum x_i y_i - \frac{1}{n} (\sum x_i) (\sum y_i) = 9286.2 - \frac{169.8 \cdot 625}{11} = -351.53. \quad \text{Et} \\ \hat{b} &= \frac{S_{xy}}{S_{xx}} = \frac{-351.53}{23.92} = -15.11. \quad \text{et} \\ \hat{a} &= \bar{y} - \hat{b}\bar{x} = \frac{625}{11} - (-15.11) \frac{169.8}{11} = 290.06. \end{aligned}$$

La droite de regression lineaire est dont  $y = 290.06 - 15.11x$ . Le graphe ci-dessous donne le nuage de points  $(x, y)$  ainsi que la droite de regression estimée.



### 3 Inference sur le modele

On voudrait d'abord savoir comment estimer la variabilité qu'il y a sur la perturbation  $\varepsilon$ .

**Theoreme 3.1.** *On peut estimer  $\sigma^2$  par:*

$$\begin{aligned} s_e^2 &= \frac{1}{n-2} \sum_{i=1}^n \left( y_i - (\hat{a} + \hat{b}x_i) \right)^2 \\ &= \frac{S_{yy} - (S_{xy})^2 / S_{xx}}{n-2}. \end{aligned}$$

**Theoreme 3.2.** *Dans le modele lineaire simple, les variables aleatoires*

$$t_a = \frac{\hat{a} - a}{s_e \sqrt{\frac{1}{n} + \frac{(\bar{x})^2}{S_{xx}}}}, \quad (3.1)$$

et

$$t_b = \frac{\hat{b} - b}{s_e / \sqrt{S_{xx}}}, \quad (3.2)$$

suivent une distribution de student à  $n - 2$  degre de liberté.

#### 3.1 Intervalle de confiance pour $a$ et $b$

Soit  $t_{\alpha/2}$  tel que  $P(T_{n-2} > t_{\alpha/2}) = \alpha/2$ . Le theoreme 3.2 implique que:

$\hat{a} \pm t_{\alpha/2} s_e \sqrt{\frac{1}{n} + \frac{(\bar{x})^2}{S_{xx}}}$  est un I.C. à  $(1 - \alpha)$  pour  $a$ .

$\hat{b} \pm t_{\alpha/2} \frac{s_e}{\sqrt{S_{xx}}}$  est un I.C. à  $(1 - \alpha)$  pour  $b$ .

**Exemple 3.1.** Dans l'exemple precedent, construire un IC a 95% pour  $a$  et  $b$ .

Solution:  $n = 11$  donc  $t_{\alpha/2} = 2.262$ .

$$S_{yy} = \sum y_i^2 - \frac{(\sum y_i)^2}{n} = 7523.64.$$

$$s_e^2 = \frac{S_{yy} - (S_{xy})^2 / S_{xx}}{n-2} = 261.95. \text{ D'ou } s_e = 16.18.$$

A partir de la formule:  $IC(a) = 290.06 \pm 15.57$ .

et  $IC(b) = -15.11 \pm 7.48$ .

### 3.2 Test sur $b$

Tester si  $b = 0$  ou pas est important en pratique parce que  $b = 0$  signifie que statistiquement  $Y$  ne varie pas avec  $X$ . Donc on veut tester:

$H_0 : b = 0$  contre  $H_1 : b \neq 0$ , au seuil  $\alpha$ .

La statistique de test est  $t_b = \frac{\hat{b}}{s_e / \sqrt{S_{xx}}}$ . On rejette  $H_0$  si  $t_b < -t_{\alpha/2}$  ou si  $t_b > t_{\alpha/2}$ , ou  $t_{\alpha/2}$  est tel que  $P(T_{n-2} > t_{\alpha/2}) = \alpha/2$ .

**Exemple 3.2.** Dans l'exemple precedent, tester  $H_0 : b = 0$  contre  $H_1 : b \neq 0$  à 5%.

Solution: Comme  $n = 11$ , on trouve  $t_{\alpha/2} = 2.262$ . La statistique de test vaut  $t_b = \frac{-15.11}{16.18 / \sqrt{23.92}} = -4.56 < -2.262$ . Donc on rejette  $H_0$ .

En fait, on pouvait prendre la meme decision rien qu'en regardant l'IC sur  $b$  qui ne contient pas 0.

### 3.3 Intervalle de confiance sur la moyenne de $Y$ a $X = x_0$

Supposons qu'on connait une valeur de  $X$ , disons  $x_0$ . La valeur moyenne de  $Y$  sachant  $X = x_0$  est  $a + bx_0$  qu'on peut naturellement estimer par  $\hat{a} + \hat{b}x_0$ . On peut montrer que l'IC a  $(1 - \alpha)$  pour  $a + bx_0$  est donne par:

$$IC(a + bx_0) = \hat{a} + \hat{b}x_0 \pm t_{\alpha/2} s_e \sqrt{\frac{1}{n} + \frac{(x_0 - \bar{x})^2}{S_{xx}}}. \quad (3.3)$$

**Exemple 3.3.** Dans l'exemple precedent, trouver un intervalle de confiance a 95% pour la reponse moyenne  $Y$  a  $X = 15.5$ .

Solution: L'estime de la moyenne de  $Y$  a  $X = 15.5$  est  $290.06 - 15.11 * 15.5 = 55.85$ .

$n = 11$ ,  $t_{\alpha/2} = 3.25$ . D'ou par la formule  $IC(a + bx_0) = 55.85 \pm 11.04$ .

### 3.4 Intervalle de prediction pour $Y$ sachant $X = x_0$

On se rappelle que d'apres le modele de regression lineaire simple,  $Y_i = a + bx_i + \varepsilon_i$ , ou  $\varepsilon_i \sim N(0, \sigma^2)$ . Si on cherche a predire  $Y$  sachant que  $X = x_0$  il faut tenir de l'erreur commise en estimant  $a$  par  $\hat{a}$ ,  $b$  par  $\hat{b}$  mais aussi de la variabilite de  $\varepsilon_i$ .

On peut montrer que l'intervalle de prediction a  $(1 - \alpha)$  pour  $Y$  lorsque  $X = x_0$  est:

$$IC(Y|X = x_0) = \hat{a} + \hat{b}x_0 \pm t_{\alpha/2} s_e \sqrt{1 + \frac{1}{n} + \frac{(x_0 - \bar{x})^2}{S_{xx}}}. \quad (3.4)$$

**Exemple 3.4.** Trouver un intervalle de prediction a 95% pour  $Y$  lorsque  $X = 15.5$ .

Solution: Avec la formule on trouve  $IC(Y|X = 15.5) = 55.85 \pm 38.23$ .