

# Introduction à la régression

## cours n°2 - Estimation

ENSM.SE – 1A  
Olivier Roustant

# Objectif du cours

- Considérons une variable dépendant linéairement d'une autre :  $y \approx \beta_0 + \beta_1 x$
  
- Quelques méthodes d'estimation de  $\beta_0$  et  $\beta_1$ :
  - Minimiser la somme des  $(y_i - (\beta_0 + \beta_1 x_i))^2$  **MOINDRES CARRÉS**
  - Minimiser la somme des  $|y_i - (\beta_0 + \beta_1 x_i)|$ , des  $(y_i - (\beta_0 + \beta_1 x_i))^4 \dots$
  
- *On utilise souvent les moindres carrés.*
  - *A-t-on toujours raison de le faire ?*
  - *Quand peut-on le faire ? Quel critère utiliser en général ?*

# 1ère partie. Estimation. Cadre. Méthodes de construction d'estimateurs

- Cadre : voir poly p. 54
- Estimation / estimateur : voir poly p. 56
- Méthodes de construction d'estimateurs
  - Méthode des moments : cf. p. 59
  - Maximum de vraisemblance : cf. p. 60 et 61
- Propriétés (biais, variance, risque)
  - Sera vu en TD mardi 30 mai

# Exemple

➤ On dispose d'un échantillon  $x_1, \dots, x_n$  d'une loi normale  $N(\mu, \sigma^2)$ . Estimation de  $\mu$  et  $\sigma^2$ ?

▪ Estimations naturelles :

$$- \mu = E(X_i) \Rightarrow \hat{\mu} = \bar{x} := \frac{1}{n} \sum_{i=1}^n x_i$$

$$- \sigma^2 = \text{var}(X_i) \Rightarrow \hat{\sigma}^2 = \frac{1}{n} \sum_{i=1}^n (x_i - \bar{x})^2$$

▪ Remarque : ce sont les estimateurs obtenues par la méthode des moments

## Exemple (suite)

- Estimation par maximum de vraisemblance
  - On écrit la vraisemblance :

$$L(x_1, \dots, x_n; \mu, \sigma^2) = \prod_{i=1}^n \frac{1}{\sigma\sqrt{2\pi}} \exp\left(-\frac{(x_i - \mu)^2}{2\sigma^2}\right)$$

- On cherche  $\mu$  et  $\sigma$  de façon à maximiser  $L$ , ou de façon équivalente, à minimiser  $-2\log(L)$

$$-2\log(L) = n \ln(\sigma^2) + n \ln(2\pi) + \frac{1}{\sigma^2} \sum_{i=1}^n (x_i - \mu)^2$$

## Exemple (suite)

➤ On écrit les conditions du 1er ordre

- Estimation de  $\mu$

$$\frac{\partial}{\partial \mu} (-2 \log(L)) \Big|_{(\mu^*, \sigma^{*2})} = 0 \Leftrightarrow \frac{\partial}{\partial \mu} \left( \sum_{i=1}^n (x_i - \mu)^2 \right) \Big|_{(\mu^*, \sigma^{*2})} = 0$$

- Deux remarques :

- Revient à minimiser la somme des carrés  $(x_i - \mu)^2$
- L'estimation obtenue est l'estimateur usuel de la moyenne

$$\frac{\partial}{\partial \mu} (-2 \log(L)) \Big|_{(\mu^*, \sigma^{*2})} = 0 \Leftrightarrow \dots \Leftrightarrow \mu^* = \bar{x} := \frac{1}{n} \sum_{i=1}^n x_i$$

## Exemple (suite)

- Estimation de  $\sigma^2$

$$\frac{\partial}{\partial \sigma^2} (-2 \log(L)) \Big|_{(\mu^*, \sigma^{*2})} = 0 \Leftrightarrow \dots \Leftrightarrow (\sigma^*)^2 = \frac{1}{n} \sum_{i=1}^n (x_i - \bar{x})^2$$

- On retrouve l'estimateur « naturel » de la variance

➤ Remarque : **moindres carrés  $\Leftrightarrow$  loi normale**

# Exercice

- Considérons un échantillon  $x_1, \dots, x_n$  de la **loi de Laplace**, définie par sa densité

$$f_{\mu,\sigma}(t) = \frac{1}{2\sigma} \exp\left(-\frac{|t - \mu|}{\sigma}\right)$$

- Vérifier que :
- $\mu$  est à la fois l'espérance et la médiane de la loi de Laplace
  - L'estimateur de maximum de vraisemblance de  $\mu$  s'obtient **en minimisant la somme des valeurs absolues**  $|x_i - \mu|$
  - Il s'agit de la médiane des  $x_i$



# 2ème partie

## Application à la régression

- Considérons le modèle linéaire avec 1 prédicteur
  - $y_i = \beta_0 + \beta_1 x_i + \varepsilon_i$ , avec  $\varepsilon_1, \varepsilon_2, \dots, \varepsilon_n$  i.i.d  $N(0, \sigma^2)$
  - Notons  $(y_{i, \text{obs}})_{1 \leq i \leq n}$  les résultats des expériences  $x_i$
- Trois paramètres à estimer :  $\beta_0, \beta_1$  et  $\sigma^2$
- Estimation usuelle :
  - $\beta_0, \beta_1$  par moindres carrés
  - Ensuite,  $\sigma^2 = E(\varepsilon_i^2) = E((y_i - (\beta_0 + \beta_1 x_i))^2)$  estimé par

$$\hat{\sigma}^2 = \frac{1}{n} \sum_{i=1}^n (y_{i, \text{obs}} - (\hat{\beta}_0 + \hat{\beta}_1 x_i))^2$$

# Estimation par Maximum de Vraisemblance (EMV)

➤ Remarque : la v.a  $y_i$  s'obtient à partir de  $\varepsilon_i$  par translation de la quantité fixe  $\beta_0 + \beta_1 x_i$

➤ Conséquences :

- Les  $y_i$  sont aussi indépendantes
- $y_i$  est de loi  $N(\beta_0 + \beta_1 x_i, \sigma^2)$
- La vraisemblance des observations s'écrit :

$$L(y_{1,obs}, \dots, y_{n,obs}; \beta_0, \beta_1, \sigma^2) = \prod_{i=1}^n \frac{1}{\sigma \sqrt{2\pi}} \exp\left(-\frac{\{y_{i,obs} - (\beta_0 + \beta_1 x_i)\}^2}{2\sigma^2}\right)$$

## EMV (suite)

### ➤ Minimisation de $-2\log(L)$

- Estimation de  $\beta_0$  et  $\beta_1$ :

$$\frac{\partial}{\partial \beta_k} (-2\log(L)) \Big|_{(\beta_0^*, \beta_1^*, \sigma^{*2})} = 0 \Leftrightarrow \frac{\partial}{\partial \beta_k} \left( \sum_{i=1}^n \{y_{i,obs} - (\beta_0 + \beta_1 x_i)\}^2 \right) \Big|_{(\beta_0^*, \beta_1^*, \sigma^{*2})} = 0$$

- On retrouve les moindres carrés
- C'est dû à l'hypothèse que les  $\varepsilon_i$  sont de loi normale
  - Si les  $\varepsilon_i$  étaient supposés de **loi de Laplace**, on obtiendrait  $\beta_0$  et  $\beta_1$  en minimisant la somme des **valeurs absolues** des écarts

## EMV (suite)

- Estimation de  $\sigma^2$

$$\frac{\partial}{\partial \sigma^2} (-2 \log(L)) \Big|_{(\beta_0^*, \beta_1^*, \sigma^{*2})} = 0 \Leftrightarrow \dots \Leftrightarrow (\sigma^*)^2 = \frac{1}{n} \sum_{i=1}^n (y_{i,obs} - (\beta_0^* + \beta_1^* x_i))^2$$

- On retrouve l'estimateur usuel

# Retour sur les objectifs

- Considérons le modèle linéaire avec 1 prédicteur
  - $y_i = \beta_0 + \beta_1 x_i + \varepsilon_i$ , avec  $\varepsilon_1, \varepsilon_2, \dots, \varepsilon_n$  i.i.d
  
- Alors le critère à utiliser pour estimer la droite de régression **dépend des hypothèses sur la loi des  $\varepsilon_i$** 
  - $\varepsilon_i$  de loi  $N(0, \sigma^2)$   $\Rightarrow$  EMV = Moindres carrés
  - $\varepsilon_i$  de loi de Laplace  $\Rightarrow$  EMV = Moindres valeurs absolues
  - Etc.

# Exercice

- Vous pouvez réaliser  $n$  expériences pour estimer un phénomène linéaire sur  $[a,b]$  impliquant 1 prédicteur
  - Comment répartir les expériences dans le domaine expérimental  $[a,b]$  de façon à ce que l'estimation soit la plus précise possible ?