

## Estimation

Problème : Soit une variable aléatoire réelle  $Y$  dont la loi de probabilité  $\mathcal{L}_\theta$  dépend d'un paramètre réel inconnu noté  $\theta$ . On cherche à utiliser l'information contenue dans un échantillon pour répondre à l'une des deux questions :

- 1) Quelle est la valeur du paramètre  $\theta$  ? C'est le problème de l'estimation ponctuelle.
- 2) Dans quelle "fourchette" peut-on situer  $\theta$  ? C'est le problème de l'estimation par intervalle.

### Estimation ponctuelle

**Définition 1** 1 - Un échantillon de taille  $N$  de  $Y$  est un ensemble de  $N$  variables aléatoires  $(Y_1, \dots, Y_N)$  indépendantes et de même loi que  $Y$  (on écarte le cas où les  $Y_n$  ne sont pas indépendantes).

2 - Un ensemble  $(y_1, \dots, y_N)$  de réalisations des  $N$  variables  $Y_n$  est une observation, ou réalisation de l'échantillon. C'est un point de  $\mathbb{R}^N$ .

3 - Si  $\mathcal{L}_\theta$  est une loi discrète, sa distribution étant  $L(y; \theta) = P_\theta \{Y = y\}$ , la loi de distribution de l'échantillon est

$$\begin{aligned} L(y_1, \dots, y_N; \theta) &= P \{Y_1 = y_1, \dots, Y_N = y_N; \theta\} \\ L(y_1, \dots, y_N; \theta) &= P_\theta \{Y_1 = y_1\} P_\theta \{Y_2 = y_2\} \dots P_\theta \{Y_N = y_N\} \end{aligned}$$

4 - Si  $\mathcal{L}_\theta$  est une loi continue de densité  $f(y; \theta)$ , la loi de distribution de l'échantillon est :

$$L(y_1, \dots, y_N; \theta) = f(y_1; \theta) f(y_2; \theta) \dots f(y_N; \theta)$$

5 - Dans les deux cas, la fonction  $L(y_1, \dots, y_N; \theta)$  considérée comme fonction de  $\theta$  s'appelle vraisemblance du paramètre (attachée à l'observation de  $y_1, \dots, y_N$ ).

6 - Un estimateur de  $\theta$  est une variable aléatoire  $T_N = t(Y_1, \dots, Y_N)$ , où  $t$  est une fonction de  $\mathbb{R}^N$  dans  $\mathbb{R}$  qui, aux valeurs observées  $(y_1, \dots, y_N)$ , fait correspondre le nombre réel :

$$\hat{\theta}_N = t(y_1, \dots, y_N)$$

dit estimation de  $\theta$ .

**Remarque 2** l'estimateur  $T_N = t(Y_1, \dots, Y_N)$ , fonction de  $N$  variables aléatoires, est une variable aléatoire (si  $f$  est une fonction dite "mesurable", ce qui sera le cas pour toutes les fonctions envisagées ici).

l'estimation  $\hat{\theta}_N = t(y_1, \dots, y_N)$  est un nombre certain, réalisation de la variable aléatoire  $T_N$ .

Ces définitions sont encore valables si le paramètre est constitué de  $k$  coordonnées. La fonction  $t$  est alors une fonction de  $\mathbb{R}^N$  dans  $\mathbb{R}^k$ .

## A - Estimateurs sans biais, estimateurs convergents

**Définition 3** Un estimateur  $T_N$  est sans biais si son espérance mathématique est la vraie valeur du paramètre :

$$\text{pour tout } \theta, E_\theta(T_N) = \theta$$

**Définition 4** Un estimateur  $T_N$  est convergent en probabilité s'il tend en probabilité vers  $\theta$  lorsque  $N$  augmente infiniment.

Rappel : " $T_N$  tend en probabilité vers  $\theta$ " s'écrit  $T_N \xrightarrow{P} \theta$ ,

et signifie que pour tout  $\varepsilon > 0$ ,  $P \{|T_N - \theta| < \varepsilon\} \longrightarrow 1$  lorsque  $N$  tend vers l'infini.

**Théorème 5** CS de convergence en probabilité :  $\{E(T_N) \longrightarrow \theta \text{ et } V(T_N) \longrightarrow 0\}$ .

Un estimateur dont l'espérance mathématique tend vers  $\theta$  et dont la variance tend vers 0 est convergent.

**Remarque 6** a fortiori, un estimateur sans biais dont la variance tend vers zéro est convergent.

## B - Comparaison de deux estimateurs sans biais

Un estimateur sans biais est plus précis, donc meilleur, qu'un autre estimateur sans biais si sa variance est plus petite.

**Définition 7** La quantité d'information contenue dans l'échantillon, relative au paramètre  $\theta$  est

$$I_N(\theta) = E \left[ \left( \frac{\partial \ln L(Y_1, \dots, Y_N; \theta)}{\partial \theta} \right)^2 \right]$$

**Théorème 8** Inégalité de CRAMER-RAO. Si l'intervalle de variation de la variable aléatoire  $Y$  ne dépend pas du paramètre à estimer, et sous réserve de certaines conditions de régularité de la fonction de vraisemblance<sup>1</sup>, la variance d'un estimateur sans biais  $T_N$  est bornée inférieurement. Elle satisfait à l'inégalité :

$$V(T_N) \geq \frac{1}{I_N(\theta)}$$

L'hypothèse précédente écarte en particulier les lois uniformes sur l'intervalle  $[0; \theta]$ . Dans ce cas, l'estimateur du maximum de vraisemblance a une variance plus petite que la borne de Cramer-Rao (exemple traité en TD de DEUG Sciences Economiques).

**Théorème 9** Sous les hypothèses de Cramer-Rao, la quantité d'information peut aussi se calculer par une formule plus facile à calculer :

$$\begin{aligned} I_N(\theta) &= V \left[ \frac{\partial \ln L(Y_1, \dots, Y_N; \theta)}{\partial \theta} \right] \\ I_N(\theta) &= -E \left[ \frac{\partial^2 \ln L(Y_1, \dots, Y_N; \theta)}{\partial \theta^2} \right] \end{aligned}$$

**Définition 10** Un estimateur sans biais est efficace si sa variance est égale à  $\frac{1}{I_N(\theta)}$

## C - Méthode du maximum de vraisemblance : Estimation ponctuelle d'un paramètre

On choisit comme estimation  $\hat{\theta}_N$  celle qui pour  $(y_1, \dots, y_N)$  fixés rend maximum la vraisemblance du paramètre. En général<sup>2</sup>, l'estimation du maximum de vraisemblance  $\hat{\theta}_N$  vérifiera :

$$\begin{cases} CN1 : \frac{\partial L(y_1, \dots, y_N; \theta)}{\partial \theta} = 0 \\ CS2 : \frac{\partial^2 L(y_1, \dots, y_N; \theta)}{\partial \theta^2} < 0 \end{cases}$$

ou de façon équivalente :

$$\begin{cases} CN1 : \frac{\partial \ln L(y_1, \dots, y_N; \theta)}{\partial \theta} = 0 \\ CS2 : \frac{\partial^2 \ln L(y_1, \dots, y_N; \theta)}{\partial \theta^2} < 0 \end{cases}$$

**Théorème 11** Sous réserve des conditions d'application de l'inégalité de CRAMER-RAO (certaines conditions de régularité et si l'intervalle de variation de  $Y$  ne dépend pas de  $\theta$ ), l'estimateur  $T_N$  du maximum de vraisemblance :

- tend en probabilité vers la vraie valeur du paramètre .
- est asymptotiquement Normal, sans biais et efficace.

<sup>1</sup>Toutes les lois rencontrées dans le cours de Licence satisfont à ces conditions de régularité.

<sup>2</sup>la première égalité n'est nécessaire que si la vraisemblance est continue et dérivable en  $\theta$  et si le maximum n'est pas sur le bord de l'ensemble de définition. La seconde condition n'est que suffisante.

Cela signifie que pour  $N$  assez grand, on peut approcher la loi de  $T_N$  par une loi Normale d'espérance  $\theta$  et de variance  $\frac{1}{I_N(\theta)}$ .

**Théorème 12** *Si il existe un estimateur efficace, il est solution de l'équation du maximum de vraisemblance.*

**Remarque 13** *Ces deux théorèmes justifient l'emploi fréquent de cette méthode.*

*Les propriétés décrites dans le premier théorème étant des propriétés asymptotiques (ie quand  $N \rightarrow \infty$ ) la méthode sera d'autant mieux justifiée que la taille de l'échantillon sera grande.*

## D : Estimation simultanée de plusieurs paramètres par la méthode du maximum de vraisemblance.

La variable aléatoire  $Y$  suit une loi de probabilité  $\mathcal{L}_\theta$  dépendant d'un paramètre qui peut être un ensemble de plusieurs nombres réels :  $\theta = (\theta_1, \dots, \theta_p)$

La vraisemblance du paramètre est alors  $L(y_1, \dots, y_N; \theta_1, \dots, \theta_p)$ .

La méthode du maximum de vraisemblance conduit en général à la résolution du système d'équations :

$$\begin{aligned}
 CN1 & : \begin{cases} \frac{\partial L(y_1, \dots, y_N; \theta)}{\partial \theta_1} = 0 \\ \vdots \\ \frac{\partial L(y_1, \dots, y_N; \theta)}{\partial \theta_p} = 0 \end{cases} \\
 CS2 & : \left[ \frac{\partial^2 L(Y_1, \dots, Y_N; \theta)}{\partial \theta_i \partial \theta_j} \right]_{i,j=1, \dots, p} \quad \text{matrice définie négative}
 \end{aligned}$$

Attention : les conditions suffisantes pour que la solution trouvée corresponde à un maximum font intervenir le tableau complet des dérivées secondes de la log-vraisemblance <sup>3</sup>

## E - Méthode des moments

La variable aléatoire  $Y$  suit une loi de probabilité  $\mathcal{L}_\theta$  dépendant d'un paramètre (qui peut être un ensemble de plusieurs nombres réels,  $\theta = (\theta_1, \dots, \theta_p)$ ). Nous ne supposons pas que cette loi est entièrement déterminée par la donnée de  $\theta$ . Nous supposons seulement qu'il est possible de calculer en fonction de  $\theta$  les  $p$  premiers moments de  $Y$ , notés  $m_1, m_2, \dots, m_p$ . Nous supposons également que ces  $p$  équations permettent de calculer  $\theta$  en fonction des moments de  $Y$  :

$$\begin{cases} E(Y) =: m_1 = f_1(\theta_1, \dots, \theta_p) \\ E(Y^2) =: m_2 = f_2(\theta_1, \dots, \theta_p) \\ \vdots \\ E(Y^p) =: m_p = f_p(\theta_1, \dots, \theta_p) \end{cases} \iff \begin{cases} \theta_1 = g_1(m_1, \dots, m_p) \\ \theta_2 = g_2(m_1, \dots, m_p) \\ \vdots \\ \theta_p = g_p(m_1, \dots, m_p) \end{cases}$$

L'estimateur de  $\theta$  par la méthode des moments est obtenu en remplaçant dans ces expressions les moments théoriques par les moments empiriques de  $Y$  calculés à partir d'un échantillon de taille  $N$  :

$$\begin{cases} \widehat{m}_1 = \frac{1}{N} \sum_{n=1}^N Y_n \\ \widehat{m}_2 = \frac{1}{N} \sum_{n=1}^N Y_n^2 \\ \vdots \\ \widehat{m}_p = \frac{1}{N} \sum_{n=1}^N Y_n^p \end{cases} \iff \begin{cases} \widehat{\theta}_1 = g_1(\widehat{m}_1, \dots, \widehat{m}_p) \\ \widehat{\theta}_2 = g_2(\widehat{m}_1, \dots, \widehat{m}_p) \\ \vdots \\ \widehat{\theta}_p = g_p(\widehat{m}_1, \dots, \widehat{m}_p) \end{cases}$$

Si les fonctions  $g_i$  sont continues en  $(m_1, m_2, \dots, m_p)$ , alors les estimateurs obtenus sont des estimateurs convergents.

<sup>3</sup>cf. par exemple "Fonctions de plusieurs variables" de BOUZITAT - PRADEL, Cujas.

**Exemple 14** Un assureur étudie la distribution du coût d'un certain sinistre pour un certain type d'assuré. Un modèle classique attribue à ce coût  $Y$  une loi Gamma, dont la densité dépend de deux paramètres strictement positifs,  $a$  et  $r$  :

$$L(y; a, r) = \frac{y^{r-1}}{a^r \Gamma(r)} e^{-y/a} \quad \text{pour } y > 0, \quad 0 \text{ sinon}$$

On peut montrer que  $E(Y) = ra$ , et  $V(Y) = ra^2$ . On en tire immédiatement que

$$\begin{cases} a = \frac{V(Y)}{E(Y)} \\ r = \frac{[E(Y)]^2}{V(Y)} \end{cases}$$

et les estimateurs par la méthode des moments sont :

$$\begin{cases} \hat{a} = \frac{S^2}{\bar{Y}} \\ \hat{r} = \frac{\bar{Y}^2}{S^2} \end{cases} \quad \text{où } \bar{Y} = \frac{1}{N} \sum_{n=1}^N Y_n \quad \text{et } S^2 = \frac{1}{N} \sum_{n=1}^N (Y_n - \bar{Y})^2$$

## F - Méthode d'ajustement par les moindres carrés ordinaires(MCO)

Nous cherchons ici à expliquer la variable  $Y$  en fonction de variables (dites explicatives) :  $x_1, x_2, \dots, x_p$ . Nous avons  $N$  observations  $(Y_1, x_{11}, x_{21}, \dots, x_{p1}), \dots, (Y_N, x_{1N}, x_{2N}, \dots, x_{pN})$ .

Pour simplifier les notations, nous notons  $x_n = (x_{1n}, x_{2n}, \dots, x_{pn})$  l'ensemble des variables explicatives.

**Définition 15** Dans la famille des fonctions  $f(x; \theta)$ , où  $\theta \in \Theta$ , la fonction ajustée par les Moindres Carrés Ordinaires (MCO) est la fonction "la plus proche" des valeurs observées, au sens où :

$$\hat{f} = f(x; \hat{\theta}), \quad \hat{\theta} \text{ solution de } \underset{\theta \in \Theta}{\text{Min}} \sum_{n=1}^N [y_n - f(x_n; \theta)]^2$$

### Cas de l'ajustement à une droite passant par l'origine $y = ax$

Calcul de l'estimateur

Les  $N$  observations  $(y_n, x_n)$  étant fixées, la fonction objectif est  $Q(a) = \sum_{n=1}^N [y_n - ax_n]^2$

Les dérivées d'ordre 1 et 2 de  $Q(a)$  sont :

$$\begin{cases} \frac{\partial Q(a)}{\partial a} = 2 \sum_{n=1}^N (y_n - ax_n)(-x_n) = -2 \sum_{n=1}^N (y_n - ax_n)x_n \\ \frac{\partial^2 Q(a)}{\partial a^2} = 2 \sum_{n=1}^N x_n^2 > 0 \end{cases}$$

$(\frac{\partial^2 Q(a)}{\partial a^2})$  est strictement positive si les  $x_n$  ne sont pas tous nuls).

La condition nécessaire d'ordre 1 entraîne donc

$$\hat{a} = \frac{\sum_{n=1}^N y_n x_n}{\sum_{n=1}^N x_n^2}$$

qui correspond bien à un minimum de la fonction  $Q(a)$ , puisque la condition suffisante d'ordre 2 est satisfaite.

Propriétés statistiques dans le cadre du modèle linéaire standard : si nous supposons que

$$\begin{aligned} H1 & : E(y_n) = ax_n \\ H2 & : V(y_n) = \sigma^2, Cov(y_n, y_m) = 0 \text{ si } n \neq m \end{aligned}$$

l'estimateur  $\hat{a}$  a pour espérance et pour variance :

$$\begin{aligned} E(\hat{a}) & = \frac{\sum_{n=1}^N E(y_n) x_n}{\sum_{n=1}^N x_n^2} = \frac{\sum_{n=1}^N ax_n^2}{\sum_{n=1}^N x_n^2} = a \\ V(\hat{a}) & = \frac{\sum_{n=1}^N V(y_n) x_n^2}{\left[ \sum_{n=1}^N x_n^2 \right]^2} = \frac{\sigma^2}{\sum_{n=1}^N x_n^2} \end{aligned}$$

La condition de convergence de  $\hat{a}$  vers  $a$  est donc que la somme des carrés des  $x_n$  tende vers l'infini.

### Cas de l'ajustement à une droite $y = ax + b$

Calcul de l'estimateur :

Les  $N$  observations  $(y_n, x_n)$  étant fixées, la fonction objectif est  $Q(a, b) = \sum_{n=1}^N [y_n - ax_n - b]^2$

Les dérivées d'ordre 1 et 2 de  $Q(a, b)$  sont :

$$\left\{ \begin{array}{l} \frac{\partial Q(a,b)}{\partial a} = 2 \sum_{n=1}^N (y_n - ax_n - b)(-x_n) = -2 \sum_{n=1}^N (y_n - ax_n - b)x_n \\ \frac{\partial Q(a,b)}{\partial b} = 2 \sum_{n=1}^N (y_n - ax_n - b)(-1) = -2 \sum_{n=1}^N (y_n - ax_n - b) \\ \frac{\partial^2 Q(a,b)}{\partial a^2} = 2 \sum_{n=1}^N x_n^2 \quad \frac{\partial^2 Q(a,b)}{\partial a \partial b} = 2 \sum_{n=1}^N x_n \\ \frac{\partial^2 Q(a,b)}{\partial b^2} = 2 \sum_{n=1}^N 1 = 2N \end{array} \right.$$

Les conditions nécessaires d'ordre 1 (appelées « équations normales ») sont :

$$\left\{ \begin{array}{l} \sum_{n=1}^N (y_n - ax_n - b)x_n = 0 \\ \sum_{n=1}^N (y_n - ax_n - b) = 0 \end{array} \right.$$

Nous avons un système de deux équations pour les deux inconnues  $(a, b)$  :

$$\left\{ \begin{array}{l} a \sum_{n=1}^N x_n^2 + b \sum_{n=1}^N x_n = \sum_{n=1}^N y_n x_n \\ a \sum_{n=1}^N x_n + bN = \sum_{n=1}^N y_n \end{array} \right.$$

Nous notons

$$\begin{aligned} \text{moments empiriques} & : \quad \bar{x} = \frac{1}{N} \sum_{n=1}^N x_n \quad \bar{y} = \frac{1}{N} \sum_{n=1}^N y_n \\ \text{Var}_N(x) & = \frac{1}{N} \sum_{n=1}^N (x_n - \bar{x})^2 \\ \text{Cov}_N(y, x) & = \frac{1}{N} \sum_{n=1}^N (x_n - \bar{x})(y_n - \bar{y}) \end{aligned}$$

Rappelons les formules classiques de statistique descriptive

$$\begin{aligned} \sum_{n=1}^N (x_n - \bar{x}) & = 0 \quad \text{et} \quad \sum_{n=1}^N (y_n - \bar{y}) = 0 \\ \text{Var}_N(x) & = \frac{1}{N} \sum_{n=1}^N x_n^2 - (\bar{x})^2 \\ \text{Cov}_N(y, x) & = \frac{1}{N} \sum_{n=1}^N (x_n - \bar{x})y_n = \frac{1}{N} \sum_{n=1}^N x_n y_n - \bar{x}\bar{y} \end{aligned}$$

La solution des équations normales est, si les  $x_n$  ne sont pas constantes :

$$\begin{cases} \hat{a} = \frac{\text{Cov}_N(y, x)}{\text{Var}_N(x)} \\ \hat{b} = \bar{y} - \hat{a}\bar{x} \end{cases}$$

La matrice des dérivées secondes est  $Hess = 2 \begin{pmatrix} \sum_{n=1}^N x_n^2 & \sum_{n=1}^N x_n \\ \sum_{n=1}^N x_n & N \end{pmatrix}$ .

C'est une matrice 2x2, sa trace est  $> 0$  et son déterminant est

$$\det(Hess) = 4 \left[ N \sum_{n=1}^N x_n^2 - \left( \sum_{n=1}^N x_n \right)^2 \right] = 4N^2 \text{Var}_N(x) > 0$$

Les deux valeurs propres de  $H$  sont de même signe positif. La condition suffisante d'ordre 2 est satisfaite : la solution trouvée correspond bien à un minimum de la fonction  $Q(a, b)$

**Théorème 16** *Propriétés statistiques dans le cadre du modèle linéaire standard :*

si  $\begin{cases} H1 : E(y_n) = ax_n + b \\ H2 : V(y_n) = \sigma^2 \text{ et } \text{Cov}(y_n, y_m) = 0 \text{ si } n \neq m \end{cases}$ , alors :

$$E[\hat{a}] = a, \quad E[\hat{b}] = b$$

$$V(\hat{a}) = \sigma^2 \frac{1}{\sum_{n=1}^N (x_n - \bar{x})^2}, \quad V(\hat{b}) = \sigma^2 \frac{\frac{1}{N} \sum_{n=1}^N x_n^2}{\sum_{n=1}^N (x_n - \bar{x})^2} = \sigma^2 \left( \frac{1}{N} + \frac{(\bar{x})^2}{\sum_{n=1}^N (x_n - \bar{x})^2} \right)$$

$$\text{Cov}(\hat{a}, \hat{b}) = -\sigma^2 \frac{\bar{x}}{\sum_{n=1}^N (x_n - \bar{x})^2}$$

Nous constatons que l'estimateur  $\hat{a}$  est convergent si et seulement si  $\sum_{n=1}^N (x_n - \bar{x})^2 \rightarrow \infty$ .