

Chap 1: ESTIMATION

I Introduction:

L'estimation consiste à donner des valeurs approchées à 1 ou plusieurs paramètres (souvent noté $\theta \in \mathbb{R}$ ou \mathbb{R}^n) à partir d'observations notées généralement x_1, \dots, x_n issues d'une même "population"

Le modèle statistique retenu par la plupart des statisticiens consiste à supposer que x_1, \dots, x_n est la réalisation d'un vecteur (X_1, \dots, X_n) où X_i sont des variables aléatoires indépendantes et de même loi (va iid).

On dit que (x_1, \dots, x_n) est un échantillon.

Un estimateur d'un paramètre $\theta \in \mathbb{R}$ ou \mathbb{R}^n est une fonction des n VA X_i notée $\hat{\theta}$ ou $\hat{\theta}(x_1, \dots, x_n)$

Remarque: $\hat{\theta}(x_1, \dots, x_n)$ est une fonction aléatoire appelée statistique

Qualités d'un estimateur: $\hat{\theta}$

• Biais de l'estimateur: moyenne \Rightarrow non aléatoire

$$\text{Biais}(\hat{\theta}) = E[\hat{\theta}] - \theta$$

moyenne de l'estimé - la vraie valeur

C'est une fonction non aléatoire de θ notée $b(\theta)$

<small>1^{ère} réalisation</small>	o	o	o	o	o
$\hat{\theta}(x_1, \dots, x_n)$	o	o	o	o	o
x	x			x	
θ					
x					
$\hat{\theta}(x_1, \dots, x_n)$	x			x	
<small>2^{ème} réalisation</small>					

l'estimateur X est non biaisé: pas d'erreur systématique.

l'estimateur o est biaisé: il y a une erreur systématique. (ex: balance en 0 mal réglé)

Dans les applications pratiques, on veut $E[\hat{\theta}] - \theta = 0$; on dit que l'estimateur est non biaisé. On veut biais faible

• Variance de l'estimateur

$$\text{Var} \hat{\theta} = E[(\hat{\theta} - E[\hat{\theta}])^2] = E[\hat{\theta}^2] - (E[\hat{\theta}])^2$$

Var $\hat{\theta}$ fournit une précision sur l'estimation. Plus var $\hat{\theta}$ est faible meilleur est l'estimateur. On veut var faible

0	0	0	0	0
x	x	x	x	x
x	x	x	x	x
0	0	0	0	0

$$\text{Var } X < \text{Var } 0$$

$\Rightarrow X$ préférable

• Erreur quadratique moyenne d'un estimateur:

$$EQM(\hat{\theta}) = E[(\hat{\theta} - \theta)^2]$$

l'estimateur $\hat{\theta}$ est d'autant meilleur que $EQM(\hat{\theta})$ est faible

Remarque:
$$EQM(\hat{\theta}) = \text{Var } \hat{\theta} + (\text{Biais } (\hat{\theta}))^2$$

Si on a $\text{var } \hat{\theta}$ et $\text{Biais } \hat{\theta}$, pas le peine de calculer $EQM(\hat{\theta})$

En effet
$$EQM(\hat{\theta}) = E[(\hat{\theta} - E[\hat{\theta}] + E[\hat{\theta}] - \theta)^2]$$

$$= E[(\hat{\theta} - E[\hat{\theta}])^2] + E[(E[\hat{\theta}] - \theta)^2] + 2E[(\hat{\theta} - E[\hat{\theta}])(E[\hat{\theta}] - \theta)]$$

donc
$$EQM(\hat{\theta}) = \text{Var } \hat{\theta} + \underbrace{E[(\text{Biais } \hat{\theta})^2]}_{(\text{Biais } \hat{\theta})^2} + 2(E[\hat{\theta}] - \theta) \underbrace{E[\hat{\theta} - E[\hat{\theta}]]}_{E[\hat{\theta}] - E[E[\hat{\theta}]]}$$

$$E[\hat{\theta}] - E[E[\hat{\theta}]] = 0$$

Définition: On dit que l'estimateur $\hat{\theta}$ est convergent si

$$\hat{\theta} \xrightarrow[n \rightarrow \infty]{P} \theta$$

Condition suffisante de convergence:

Si $\text{biais } (\hat{\theta}) \xrightarrow[n \rightarrow \infty]{} 0$ et $\text{var } (\hat{\theta}) \xrightarrow[n \rightarrow \infty]{} 0$ alors

$\hat{\theta}$ est convergent

$$\left. \begin{array}{l} \text{biais} \rightarrow 0 \\ \text{var} \rightarrow 0 \end{array} \right\} \Rightarrow EQM(\hat{\theta}) \rightarrow 0$$

\Rightarrow conv en moyenne quadratique \Rightarrow conv en proba

En effet $\text{biais } (\hat{\theta}) \xrightarrow[n \rightarrow \infty]{} 0$

$\text{Var } \hat{\theta} \xrightarrow[n \rightarrow \infty]{} 0$

$\Rightarrow EQM(\hat{\theta}) \xrightarrow[n \rightarrow \infty]{} 0 \Leftrightarrow \hat{\theta} \xrightarrow[n \rightarrow \infty]{mq} \theta$

on sait que $\hat{\theta} \xrightarrow[n \rightarrow \infty]{mq} \theta \Rightarrow \hat{\theta} \xrightarrow[n \rightarrow \infty]{P} \theta$

II Exemples:

Exemple 1: Soit (X_1, \dots, X_n) un échantillon tel que $E[X_i] = m$ et $\text{var } X_i = \sigma^2$. On suppose que σ^2 est connue et on désire estimer $\theta = m$.

Comparer $\hat{\theta}_1 = \frac{1}{n} \sum_{i=1}^n X_i = \bar{X}$ et $\hat{\theta}_2 = \frac{2}{n(n+1)} \sum_{i=1}^n i X_i$

Biais: * $E[\hat{\theta}_1] - \theta = E[\hat{\theta}_1] - m$

$$= E\left[\frac{1}{n} \sum_{i=1}^n X_i\right] - m$$

$$= \frac{1}{n} \sum_i \underbrace{E[X_i]}_m - m = \boxed{0}$$

$\hat{\theta}_1$ est un estimateur non biaisé de m $1+2+\dots+n$

* $E[\hat{\theta}_2] - m = \frac{2}{n(n+1)} \left(\sum_{i=1}^n i E[X_i] \right) - m$

$$= \frac{2}{n(n+1)} m \left(\frac{n(n+1)}{2} \right) - m = \boxed{0}$$

$\hat{\theta}_2$ non biaisé

Variances:

Rq: Si X_1, \dots, X_n sont n VA indépendantes, alors

$$\text{Var} \sum_{i=1}^n X_i = \sum_{i=1}^n \text{Var } X_i$$

* $\text{Var } \hat{\theta}_1 = \frac{1}{n^2} \text{Var}(\sum X_i) = \frac{1}{n^2} \sum_{i=1}^n \overbrace{\text{Var } X_i}^{\sigma^2} = \frac{\cancel{\sigma^2}}{\cancel{n^2}} = \boxed{\frac{\sigma^2}{n}}$

Rq: $\text{Var } \hat{\theta}_1 \xrightarrow{n \rightarrow +\infty} 0$ Donc $\hat{\theta}_1$ est convergent
 Biais $\hat{\theta}_1 = 0$

* $\text{Var } \hat{\theta}_2 = \frac{4}{\sigma^2(n+1)^2} \sum_{i=1}^n \underbrace{\text{Var}(i X_i)}_{i^2 \text{Var}(X_i)} = \frac{4 \sigma^2}{n^2(n+1)^2} \sum_{i=1}^n i^2$

$$\frac{4 \sigma^2}{n^2(n+1)^2} \frac{n(n+1)(n+2)}{6}$$

$\text{Var } \hat{\theta}_2 = \frac{2}{3} \sigma^2 \frac{2n+1}{n(n+1)}$

$\text{Var } \hat{\theta}_2 \xrightarrow{n \rightarrow +\infty} 0$ Donc $\hat{\theta}_2$ est convergent
 Biais $\hat{\theta}_2 = 0$

On préférera $\hat{\theta}_1$ à $\hat{\theta}_2$ si $\text{Var } \hat{\theta}_1 < \text{Var } \hat{\theta}_2$

$$\text{si } \frac{\sigma^2}{n} < \frac{2}{3} \sigma^2 \frac{2n+1}{n(n+1)} \sim \frac{4}{3} \frac{\sigma^2}{n}$$

Ok on préférera $\hat{\theta}_1$ à $\hat{\theta}_2$

$$\hat{\theta}_3 = \hat{m}^n = \frac{1}{n} \sum_{i=1}^n x_i$$

$$E[\hat{m}^n] = \frac{1}{n} \sum_{i=1}^n E[x_i] = m^n$$

$$\text{Var}(\hat{m}^n) = E\left[\left(\frac{1}{n} \sum_{i=1}^n x_i\right)^2\right] - (m^n)^2$$

$$= E[x_1^2 + x_2^2 + \dots + x_n^2] - m^{2n}$$

$$= \frac{1}{n} \sum_{i=1}^n E[x_i^2] - m^{2n} = \frac{(m^2 + \sigma^2)^n}{n} - m^{2n}$$

$$m = E[x_i]$$

$$\sigma^2 = E[(x_i - m)^2]$$

Exemple 2:

mêmes hypothèses mais on désire estimer σ^2

1^{er} Cas: m connu

$$\hat{\sigma}^2 = \frac{1}{n} \sum_{i=1}^n (x_i - m)^2$$

$$E[\hat{\sigma}^2] - \sigma^2 = \frac{1}{n} \sum_{i=1}^n E[(x_i - m)^2] - \sigma^2 = \sigma^2 - \sigma^2 = 0$$

$\hat{\sigma}^2$ non biaisé

$$\text{Var } \hat{\sigma}^2 = \frac{1}{n^2} \sum_{i=1}^n \text{Var} (x_i - m)^2 = \frac{n \text{Var} (x_1 - m)^2}{n^2}$$

les x_i ont la même loi \Rightarrow même variance

$$\text{Var } \hat{\sigma}^2 = \frac{\text{Var} (x_1 - m)^2}{n} \xrightarrow{n \rightarrow +\infty} 0 \quad \text{donc } \hat{\sigma}^2 \text{ converge}$$

2^{ème} Cas: m inconnu:

$$\tilde{\sigma}^2 = \frac{1}{n} \sum_{i=1}^n (x_i - \underbrace{\bar{x}}_{\hat{m}})^2$$

Biais? $\tilde{\sigma}^2$ converge?

~~$$\text{Biais } (\tilde{\sigma}^2): E[\tilde{\sigma}^2] - \sigma^2 = \frac{1}{n} \sum_{i=1}^n E[(x_i - \bar{x})^2] - \sigma^2$$~~

~~$$E[(x_i - \bar{x})^2] = E[(x_i - \bar{x} + m - m)^2] = E[(x_i - m + m - \bar{x})^2]$$~~

~~$$= E[(x_i - m)^2] + E[(m - \bar{x})^2] + 2 E[(x_i - m)(m - \bar{x})]$$~~

~~$$\text{Biais } \tilde{\sigma}^2 = \frac{1}{n} \sum_{i=1}^n E[(x_i - m)^2] + \frac{1}{n} \sum_{i=1}^n E[(m - \bar{x})^2] + \frac{2}{n} \sum_{i=1}^n E[(x_i - m)(m - \bar{x})] - \sigma^2$$~~

$$= \frac{\sigma^2}{n} + 0 + \dots - \sigma^2$$

biais $\tilde{\sigma}^2 = E[\tilde{\sigma}^2] - \sigma^2$

$$E[\tilde{\sigma}^2] = \frac{1}{n} \sum_{i=1}^n E\left[\left\{(X_i - m) + (m - \bar{X})\right\}^2\right]$$

$$= \frac{1}{n} \sum_{i=1}^n \underbrace{E[(X_i - m)^2]}_{\sigma^2} + \underbrace{E[(\bar{X} - m)^2]}_{\substack{E[\bar{X}] \\ \text{Var } \bar{X} = \frac{\sigma^2}{n}}} + 2 \underbrace{E[(X_i - m)(m - \bar{X})]}_{-\frac{2\sigma^2}{n}}$$

$$E\left[(X_i - m) \left(m - \frac{1}{n} \sum_{j=1}^n X_j\right)\right] = E\left[(X_i - m) \frac{1}{n} \sum_{j=1}^n (m - X_j)\right]$$

$$= \frac{1}{n} \sum_{j=1}^n -E\left[(X_i - m)(X_j - m)\right]$$

$i \neq j$ $\text{cov}(X_i, X_j) = 0$ $\text{cov } X_i \text{ et } X_j \text{ ind}$
 $i = j$ $\text{Var } X_i = \sigma^2$

$$= -\frac{\sigma^2}{n}$$

$$E[\tilde{\sigma}^2] = \sigma^2 - \frac{\sigma^2}{n} = \frac{n-1}{n} \sigma^2$$

$\tilde{\sigma}^2$ est biaisé

donc $E\left[\frac{n}{n-1} \tilde{\sigma}^2\right] = \sigma^2$

On pose $\sigma^{2*} = \frac{1}{n-1} \sum_{i=1}^n (X_i - \bar{X})^2$ non biaisé

faudrait montrer que cvg

13/12/93

Bon estimateur :
 | Biais proche de 0 (moyenne de l'estimateur proche de la valeur moyenne)
 | var faible
 | Convergence

III Inégalité de RAO-CRAMER - ESTIMATEUR EFFICACE

1) Cas d'un paramètre réel $\theta \in \mathbb{R}$:

On peut tjrs éliminer le biais en général (ex: valeur)

Le var est bornée ...

Définition: On appelle vraisemblance de (x_1, \dots, x_n) la fonction

$L(x_1, \dots, x_n; \theta)$ définie par:

* Si x_i VA continues $L(x_1, \dots, x_n; \theta) = \int (x_1, \dots, x_n; \theta)$
densité de probabilité de (x_1, \dots, x_n)

* Si x_i VA discrètes $L(x_1, \dots, x_n; \theta) = P[X_1 = x_1, \dots, X_n = x_n; \theta]$

Inégalité de RAO-CRAMER

$$\text{Var } \hat{\theta} \geq \frac{[1 + b'(\theta)]^2}{-E\left[\frac{\partial^2 \ln L(x_1, \dots, x_n; \theta)}{\partial \theta^2}\right]} = \text{BRC}(\theta)$$

en général non biaisé $\Rightarrow b'(\theta) = 0$
 $\Rightarrow 1$ au numérateur

$b'(\theta)$: dérivée du biais

* BRC(θ) est appelée borne de Cramer-Rao de θ

Cette inégalité suppose que $L(x_1, \dots, x_n; \theta)$ est 2 fois dérivable par rapport à θ , et que les bornes du support de L sont indépendantes de θ .

Par exemple, cette inégalité n'est pas valable lorsque $X_i \sim U(0, \theta)$ et qu'on cherche à estimer θ .

• Définition: Un estimateur non biaisé de θ noté $\hat{\theta}$ vérifiant $\text{Var } \hat{\theta} = \text{Borne de RAO-CRAMER}$ est unique et appelé l'estimateur efficace de θ .
(c'est le meilleur)

Exemples

ex 1: $X_i \sim N(m, \sigma^2)$, X_i indépendantes, σ^2 connu, on cherche à estimer $\frac{m}{\sigma}$.

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

$$= \left(\frac{1}{2\pi\sigma^2}\right)^{n/2} \exp\left[-\frac{1}{2\sigma^2} \sum_{i=1}^n (x_i - m)^2\right]$$

ind

$$\ln L(x_1, \dots, x_n; m) = -\frac{n}{2} \ln(2\pi\sigma^2) - \frac{1}{2\sigma^2} \sum_{i=1}^n (x_i - m)^2$$

$$\frac{\partial \ln L}{\partial m} = \frac{1}{\sigma^2} \sum_{i=1}^n (x_i - m) = \frac{1}{\sigma^2} \sum (x_i - m)$$

$$\frac{\partial^2 \ln L}{\partial m^2} = \frac{1}{\sigma^2} \sum_{i=1}^n (-1) = -\frac{n}{\sigma^2}$$

$$\frac{\partial^2 \ln L(x_1, \dots, x_n; m)}{\partial m^2} = -\frac{n}{\sigma^2}$$

$$E\left[\frac{-\partial^2 \ln L(x_1, \dots, x_n; m)}{\partial m^2}\right] = E\left[\frac{n}{\sigma^2}\right] = \frac{n}{\sigma^2}$$

Si \hat{m} est un estimateur non biaisé de m alors $\text{Var } \hat{m} \geq \frac{\sigma^2}{n}$

Rq1: $\bar{X} = \frac{1}{n} \sum_{i=1}^n X_i$ on a vu $E[\bar{X}] = m$

$$\text{Var } \bar{X} = \frac{\sigma^2}{n}$$

\bar{X} est l'estimateur efficace de m dans le cas de VA indépendantes de loi $N(m, \sigma^2)$

Rq2: la variance optimale concernant l'estimation de m est $\frac{\sigma^2}{n} \propto \frac{1}{n}$
 → précision de l'estimation optimale

Rq3: lorsque les X_i sont indépendantes

$$L(x_1, \dots, x_n; \theta) = \prod_{i=1}^n L(x_i; \theta)$$

$$\ln L(x_1, \dots, x_n; \theta) = \sum_{i=1}^n \ln L(x_i; \theta)$$

$$\frac{\partial^2 \ln L(x_1, \dots, x_n; \theta)}{\partial \theta^2} = \sum_{i=1}^n \frac{\partial^2 \ln L(x_i; \theta)}{\partial \theta^2}$$

$$E\left[\frac{\partial^2 \ln L(x_1, \dots, x_n; \theta)}{\partial \theta^2}\right] = \sum_{i=1}^n E\left[\frac{\partial^2 \ln L(x_i; \theta)}{\partial \theta^2}\right]$$

Si les VA X_i ont la même loi, toutes les espérances sont égales donc

$$= n \cdot E\left[\frac{\partial^2 \ln L(X_1; \theta)}{\partial \theta^2}\right]$$

$$\text{Var } \hat{\theta} \geq \frac{(1 + b'(\theta))^2}{n E\left[\frac{\partial^2 \ln L(X_1; \theta)}{\partial \theta^2}\right]}$$

Ex 2: $X_i \sim P(\lambda)$ chercher la borne de Rao-Cramer sur λ pour un estimateur non biaisé.

2) Cas où $\theta = (\theta_1, \dots, \theta_p) \in \mathbb{R}^p$

la matrice de covariance de $\hat{\theta} = (\hat{\theta}_1, \dots, \hat{\theta}_p)$ (définie par

$$\text{Cov}(\hat{\theta}) = E \left[\begin{pmatrix} \hat{\theta} - E[\hat{\theta}] \\ \vdots \end{pmatrix} \begin{pmatrix} \hat{\theta} - E[\hat{\theta}] \\ \vdots \end{pmatrix}^t \right] \text{ vérifie } (---) \parallel \Rightarrow a \in \mathbb{R}$$

$$\text{Cov}(\hat{\theta}) \geq \mathbb{I}_\theta^{-1} \quad \text{pour un estimateur non biaisé de } \theta$$

avec $\mathbb{I}_\theta = (\mathbb{I}_{ij})_{\substack{i=1, \dots, p \\ j=1, \dots, p}}$ et $\mathbb{I}_{ij} = E \left[\frac{-\partial^2 \ln L(X_1, \dots, X_n; \theta)}{\partial \theta_i \partial \theta_j} \right]$

$A \geq B$ signifie $A - B$ matrice semi définie positive

$$\left(\begin{pmatrix} t \alpha (A - B) \alpha \geq 0 \quad \forall \alpha \end{pmatrix} \right)$$

Semi définie positive

En particulier

$$\text{Var } \hat{\theta}_i \geq (\mathbb{I}_\theta^{-1})_{ii}$$

$\hat{\theta}_{no}$ est simple à implanter mais possède peu de bonnes propriétés.

IV. Méthode du maximum de vraisemblance

V.1. Définitions

L'estimateur du maximum de vraisemblance de θ est défini par

$$\hat{\theta}_{MV} = \underset{\theta}{\operatorname{arg\,max}} L(x_1, \dots, x_n; \theta) \rightarrow \text{fonc. de } \theta$$

$L(x_1, \dots, x_n; \theta)$ étant la vraisemblance de θ ($f(x_1, \dots, x_n; \theta)$ ou $P[X_1 = x_1, \dots, X_n = x_n; \theta]$)

Dans la mesure où les hypothèses de la borne de Rao Cramer sont vérifiées (ie $L(x_1, \dots, x_n; \theta)$ 2 fois dérivable et bornes du support de $L(x_1, \dots, x_n; \theta)$ indépendantes de θ), la détermination de $\hat{\theta}_{MV}$ se fait à l'aide des équations suivantes:

$$\theta \in \mathbb{R} \quad \frac{\partial L(x_1, \dots, x_n; \theta)}{\partial \theta} = 0 \quad \text{ou} \quad \frac{\partial \ln L(x_1, \dots, x_n; \theta)}{\partial \theta} = 0$$

On vérifie que la solution donne un maximum en étudiant

$$\frac{\partial L(x_1, \dots, x_n; \theta)}{\partial \theta} \geq 0 \quad \text{ou en cas de problème}$$

$$\frac{\partial^2 L(x_1, \dots, x_n; \hat{\theta}_{MV})}{\partial \theta^2} < 0 \quad (\text{condition assurant que } \hat{\theta}_{MV} \text{ est un maximum local})$$


θ	$\hat{\theta}_{MV}$
$\frac{\partial^2 L}{\partial \theta^2}$	< 0
$\frac{\partial L}{\partial \theta}$	
L	

ex 3: $X_i \sim P(\lambda)$ λ ?

$$L(x_1, \dots, x_n; \lambda) = \prod_{i=1}^n P[X_i = x_i; \lambda] = \prod_{i=1}^n \frac{\lambda^{x_i}}{x_i!} e^{-\lambda}$$
$$= \frac{\lambda^{\sum x_i}}{\prod x_i!} e^{-n\lambda}$$

$$\ln L(\cdot) = \sum x_i \ln \lambda - n\lambda - \ln(\prod x_i!)$$

$$\frac{\partial \ln L(\cdot)}{\partial \lambda} \geq 0 \Leftrightarrow \frac{\sum x_i}{\lambda} - n \geq 0 \Leftrightarrow \lambda \leq \bar{x}$$



$\lambda = \bar{x}$ est le maximum global unique de $L(x_i; \lambda)$

on pose $\hat{\lambda}_{ML} = \bar{X}$

04/01/2020

$$f(x_1, \dots, x_n; \theta) = \prod_{i=1}^n f(x_i; \theta)$$

$$\hat{\theta}_{ML} \text{ vérifie } f(x_1, \dots, x_n; \hat{\theta}_{ML}) \geq f(x_1, \dots, x_n; \theta) \quad \forall \theta$$

$\theta \in \mathbb{R}^p$ On résoud $\frac{\partial L(x_1, \dots, x_n; \theta)}{\partial \theta_i} = 0 \quad \forall i = 1, \dots, p$

ou $\frac{\partial \ln L(x_1, \dots, x_n; \theta)}{\partial \theta_i} = 0 \quad \forall i = 1, \dots, p$

V. 2. Propriétés:

* $\hat{\theta}_{nv}$ est asymptotiquement sans biais $\lim_{n \rightarrow +\infty} E[\hat{\theta}_{nv}] - \theta = 0$

* $\hat{\theta}_{nv}$ est convergent

* $\hat{\theta}_{nv}$ est asymptotiquement efficace $\text{Var } \hat{\theta}_{nv} \underset{n \rightarrow +\infty}{\sim} \text{BRC}(\theta)$ borne de Rao Cramer

(ie $\lim_{n \rightarrow +\infty} \frac{\text{Var } \hat{\theta}_{nv}}{\text{BRC}(\theta)} = 1$) /

* Invariance fonctionnelle

Soit $\mu = h(\theta)$, où h est une f° bijective d'un ouvert $O \subset \mathbb{R}^p$ dans un ouvert $V \subset \mathbb{R}^p$ alors

$$\hat{\mu}_{nv} = h(\hat{\theta}_{nv})$$

* $\sqrt{I_n(\theta)} (\hat{\theta}_{nv} - \theta) \xrightarrow[n \rightarrow +\infty]{L} N(0, I_p)$

$$\text{où } I_n(\theta) = E \left[\frac{-\partial^2 \ln L(x_1, \dots, x_n; \theta)}{\partial \theta^2} \right]$$

est l'information de FISHER (c'est le dénominateur de la borne de Rao Cramer).

$\hat{\theta}_{nv}$ possède plein de bonnes propriétés mais peut être difficile à implémenter

V. 3. Exemples:


ex 1: $X_i \sim N(m, \sigma^2)$ σ^2 connu m inconnu

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

$$\ln L(x_1, \dots, x_n; m) = -\frac{1}{2} \ln 2\pi\sigma^2 - \frac{1}{2\sigma^2} \sum_{i=1}^n (x_i - m)^2$$

$$\frac{\partial \ln L}{\partial m} \geq 0 \Leftrightarrow +\frac{1}{\sigma^2} \sum_{i=1}^n 2(x_i - m)(-1) \geq 0$$

$$\Leftrightarrow \sum x_i \geq nm \Leftrightarrow \boxed{m \leq \frac{1}{n} \sum x_i = \bar{x}}$$



\bar{x} est un maximum
global unique de
 $L(x_1, \dots, x_n; m)$

$$\boxed{\hat{m}_{nv} = \frac{1}{n} \sum_{i=1}^n X_i = \bar{X}}$$

Ex 2: m inconnu, σ^2 inconnu

$$\frac{\partial \ln L}{\partial m} = 0 \text{ et } \frac{\partial \ln L}{\partial \sigma^2} = 0$$

$$m = \bar{x} \text{ et } -\frac{n}{2} \frac{1}{\sigma^2} + \frac{1}{2} \frac{1}{\sigma^4} \sum_{i=1}^n (x_i - m)^2 = 0$$

$$m = \bar{x} \text{ et } \sigma^2 = \frac{1}{n} \sum_{i=1}^n (x_i - m)^2$$

j'admets que $(m = \bar{x}, \sigma^2 = \frac{1}{n} \sum_{i=1}^n (x_i - m)^2)$ est l'argument du maximum de $L(x_1, \dots, x_n; \theta)$

On pose

$$\boxed{\begin{aligned} \hat{m}_{nv} &= \bar{X} \\ \hat{\sigma}_{nv}^2 &= \frac{1}{n} \sum_{i=1}^n (X_i - \bar{X})^2 \end{aligned}}$$

IV Méthode des moments:

IV.1. Définition

Soient n VA x_1, \dots, x_n iid dont la loi dépend d'un paramètre $\theta = (\theta_1, \dots, \theta_p) \in \mathbb{R}^p$. Le ^{principe} paramètre de l'estimation θ consiste à donner une valeur approchée de θ à l'aide de x_1, \dots, x_n .

En général θ s'exprime en fonction de m_1, \dots, m_p avec $m_i = E[X_j^i]$ (indépendant de j car toutes les VA X_j ont la même loi), de la façon suivante

$$\theta = h(m_1, \dots, m_p)$$

l'estimateur des moments de θ est défini par

$$\hat{\theta}_{no} = h(\hat{m}_1, \dots, \hat{m}_p) \quad \text{avec} \quad \hat{m}_i = \frac{1}{n} \sum_{j=1}^n X_j^i$$

IV.2. Exemple:

$$X_j \sim N(m, \sigma^2) \quad X_j \text{ iid} \quad \theta = (m, \sigma^2)$$

$$m_1 = E[X_j] = m$$

$$m_2 = E[X_j^2] = \text{Var} X_j + E[X_j]^2 = \sigma^2 + m^2$$

$$\text{Rq: } \begin{cases} m = m_1 \\ \sigma^2 = m_2 - m_1^2 \end{cases}$$

On pose

$$\hat{m}_{no} = \frac{1}{n} \sum_{j=1}^n X_j$$

$$\hat{\sigma}_{no}^2 = \frac{1}{n} \sum_{j=1}^n X_j^2 - \left(\frac{1}{n} \sum_{j=1}^n X_j \right)^2$$

IV.3. Propriétés:

* $\hat{\theta}_{no}$ est convergent (vers θ)

$$* \sqrt{n} (\hat{\theta}_{no} - \theta) \xrightarrow[n \rightarrow +\infty]{L} N(0, \Sigma)$$

Σ matrice $p \times p$ indépen-
dante de n

$\hat{\theta}_{no}$ peut être biaisé, non biaisé, efficace ou non. \rightarrow pas terrible ni con-
propriétés

$\hat{\theta}_{no}$ simple à implémenter mais il possède peu de bonnes propriétés.

VI Estimation BAYESIENNE

L'estimation Bayésienne consiste à supposer que le paramètre inconnu θ est la réalisation d'une va Θ qui possède une appelée Loi A PRIORI (densité de probabilité à priori dans le cas continu).

Le but de l'estimation Bayésienne consiste à estimer θ (la réalisation de la va Θ) à l'aide d'un estimateur noté $\hat{\theta}(x)$ de façon à minimiser une fonction (appelée fonction de coût): $E[c(\theta, \hat{\theta}(x))]$ qui représente l'erreur entre θ et $\hat{\theta}(x)$

Remarque: L'estimateur $\hat{\theta}$ est construit à partir de la loi des va X ; mais aussi à l'aide de la loi à priori

VI.1 - ESTIMATEUR de la moyenne à Posteriori ($\hat{\theta}_{MOAP}(x)$)

$\hat{\theta}_{MOAP}(x)$ est l'estimateur qui minimise $E[(\theta - \hat{\theta}(x))^2]$ (coût quadratique). Il est défini par:

$$\hat{\theta}_{MOAP}(x) = E[\theta/x] \quad \begin{array}{l} \text{moyenne de la loi de } \theta/x \\ \text{appelée loi à POSTERIORI} \end{array}$$

Preuve: On cherche à minimiser $E[(\theta - \hat{\theta}(x))^2]$ ie On cherche $\hat{\theta}(x)$ qui minimise $E\left[E[(\theta - \hat{\theta}(x))^2 | x]\right]$

$$\begin{aligned} E[(\theta - \hat{\theta}(x))^2 | x] &= E[\theta^2/x] - 2 \underbrace{E[\theta \hat{\theta}(x) | x]}_{-2\hat{\theta}(x)E[\theta/x]} + \underbrace{E[\hat{\theta}^2(x) | x]}_{\hat{\theta}^2(x)} \\ &= E[\theta^2/x] - E[\theta/x]^2 + E[\theta/x]^2 - 2\hat{\theta}(x)E[\theta/x] + \hat{\theta}^2(x) \\ &= \text{Var}(\theta/x) + (\hat{\theta}(x) - E[\theta/x])^2 \end{aligned}$$

$\hat{\theta}$ simple à implémenter mais possède peu de bonnes propriétés

à x fixé, on a $E[(\theta - \hat{\theta}(x))^2 | x] \geq \text{Var}(\theta | x)$

il y a égalité pour $\hat{\theta}(x) = E[\theta | x]$

donc $E[\theta | x]$ minimise $E[(\theta - \hat{\theta}(x))^2 | x]$

Limitons nous au cas continu pour simplifier (x_1, \dots, x_n via de densités $f(x_i; \theta)$)

$$E[(\theta - \hat{\theta}(x))^2] = \int_{\mathbb{R}^n} E[(\theta - \hat{\theta}(x))^2 | x] f(x_1, \dots, x_n; \theta) dx_1 \dots dx_n$$

puis que $\hat{\theta}(x) = E[\theta | x]$ minimise $\forall x$, $\hat{\theta}(x) = E[\theta | x]$ minimise aussi $E[(\theta - \hat{\theta}(x))^2]$ CQFD

⊗ exemple (Ex 3 TD3):

- Résistance inconnue θ

- On a N mesures $x_i = \theta + \underbrace{b_i}_{\text{erreur}}$ avec $b_i \sim \mathcal{P}(0, \sigma_b^2)$

Il est clair que $x_i \sim \mathcal{P}(\theta, \sigma_b^2)$

la loi $N(\theta, \sigma_b^2)$ est la loi de x_i / θ

- On suppose qu'on dispose d'une loi a priori sur θ qui est $N(m, \sigma^2)$

ie $p(\theta) = \frac{1}{\sqrt{2\pi\sigma^2}} \exp - \frac{(\theta - m)^2}{2\sigma^2}$

$$\hat{\theta}_{\text{MOA}} = E[\theta | x] \quad x = (x_1, \dots, x_n)$$

Calcul de $E[\theta | x]$ 1) loi de $\theta | x$

Règle de BAYES $p(\theta | \underbrace{x_1, \dots, x_n}_x) = \frac{p(x_1, \dots, x_n | \theta) p(\theta)}{p(x_1, \dots, x_n)}$

$$p(\theta) = \frac{1}{\sqrt{2\pi\sigma^2}} \exp - \frac{(\theta - m)^2}{2\sigma^2} \quad \text{connu}$$

$$p(x_1, \dots, x_n | \theta) = \prod_{i=1}^n \frac{1}{\sqrt{2\pi\sigma_b^2}} \exp\left[-\frac{(x_i - \theta)^2}{2\sigma_b^2}\right]$$

x_i ind

$$p(x_1, \dots, x_n) = \int p(x_1, \dots, x_n, \theta) d\theta = \int \underbrace{p(x_1, \dots, x_n | \theta)}_{\text{connu}} \underbrace{p(\theta)}_{\text{connu}} d\theta$$

$p(x_1, \dots, x_n)$ est évidemment indépendant de θ . Souvent, il n'est pas nécessaire de le calculer.

$$p(x_1, \dots, x_n | \theta) p(\theta) = C \exp\left[-\frac{1}{2}\left[\frac{(\theta - m)^2}{\sigma^2} + \frac{1}{\sigma_b^2} \sum_{i=1}^n (x_i - \theta)^2\right]\right]$$

donc $p(\theta | x_1, \dots, x_n) \propto \exp\left[-\frac{1}{2}\left[\theta^2\left(\frac{1}{\sigma^2} + \frac{n}{\sigma_b^2}\right) - 2\theta\left(\frac{m}{\sigma^2} + \frac{\sum_{i=1}^n x_i}{\sigma_b^2}\right)\right]\right]$

proportionnel

$$\exp\left[-\frac{1}{2} \frac{(\theta - m_p)^2}{\sigma_p^2}\right] = \exp\left[-\frac{1}{2\sigma_p^2} (\theta^2 - 2\theta m_p + m_p^2)\right]$$

$\frac{1}{\sigma_p^2}$ $\frac{m_p}{\sigma_p^2}$

$$p(\theta | x_1, \dots, x_n) \propto \exp\left[-\frac{1}{2} \frac{(\theta - m_p)^2}{\sigma_p^2}\right]$$

$$\text{avec } \frac{1}{\sigma_p^2} = \frac{1}{\sigma^2} + \frac{n}{\sigma_b^2}$$

$$m_p = \left(\frac{m}{\sigma^2} + \frac{n\bar{x}}{\sigma_b^2}\right) \sigma_p^2 = \frac{\frac{m}{\sigma^2} + \frac{n\bar{x}}{\sigma_b^2}}{\frac{1}{\sigma^2} + \frac{n}{\sigma_b^2}}$$

$$\text{ie } m_p = \bar{x} \left(\frac{\sigma^2}{\sigma^2 + \frac{\sigma_b^2}{n}}\right) + m \left(\frac{\frac{\sigma_b^2}{n}}{\sigma_b^2/n + \sigma^2}\right)$$

$$\theta | x \sim \mathcal{N}(m_p, \sigma_p^2)$$

$$\hat{\theta}_{\text{MOAP}} = E[\theta | x] = m_p = \bar{x} \left(\frac{\sigma^2}{\sigma^2 + \frac{\sigma_b^2}{n}}\right) + m \left(\frac{\frac{\sigma_b^2}{n}}{\sigma_b^2/n + \sigma^2}\right)$$

↑ précision valeur R
 ↑ valeur nominale
 ↑ précision appareil de mesure

quand n gd $\frac{\sigma_b^2}{n} \ll \sigma^2$ $\hat{\theta}_{\text{MOAP}} \approx \bar{x}$

On ne tient plus compte de la valeur a priori m (on ne fait pas confiance au fournisseur)

quand n petit ($n=0$) $\frac{\sigma_b^2}{n} \gg \sigma^2$ $\hat{\theta}_{\text{MOAP}} \approx m$

Ex. 2. Estimateur du Maximum A Posteriori ($\hat{\theta}_{MAP}$)

L'estimateur $\hat{\theta}(x)$ qui minimise $E[C(\theta, \hat{\theta}(x))]$ avec


$$C(\theta, \hat{\theta}(x)) = \begin{cases} 1 & \text{si } |\theta - \hat{\theta}(x)| > \Delta \\ 0 & \text{si } |\theta - \hat{\theta}(x)| < \Delta \end{cases}$$

Δ "arbitrairement" petit est défini par

$$\hat{\theta}_{MAP} = \arg \max_{\theta} p(\theta/x) \quad \text{ie} \quad p(\hat{\theta}_{MAP}/x) \geq p(\theta/x)$$

Pour l'exemple précédent $\theta/x \sim N(m_p, \sigma_p^2)$

donc $\hat{\theta}_{MAP} = \hat{\theta}_{MAP}$



VII Estimation par intervalle de confiance.

1) Principe: Dans certaines applications, il est plus réaliste de donner une information de la forme $a < \theta < b$ plutôt que de dire $\hat{\theta} = c$.

Un intervalle de confiance pour l'estimation du paramètre θ est un intervalle de cette forme $[d_1, d_2]$ tel que

$$P[d_1 < \theta < d_2] = \alpha$$

En général $\alpha = 0,95$; $0,99$ ou $0,90$ et s'appelle le paramètre de confiance.

2) Détermination pratique de l'intervalle

On cherche à l'aide d'un estimateur $\hat{\theta}$ de θ (obtenu grâce à la méthode des moments ou du maximum de vraisemblance) une statistique $T(X_1, \dots, X_n)$ dont la loi est connue et qui dépend de θ .

On exprime la probabilité $P[a < T(X_i) < b] = \alpha$ sous la forme

$$P[d_1 < \theta < d_2] = \alpha$$

3) Exemples

Ex 1: $X_i \sim \mathcal{N}(m, \sigma^2)$ σ^2 connue, m inconnue

On sait que $\hat{\theta} = \frac{1}{n} \sum_{i=1}^n X_i$ est un bon estimateur de m

(pour loi \mathcal{N} , $\hat{\theta}$ sans biais, convergent, efficace)

et que $\hat{\theta} \sim \mathcal{N}(m, \frac{\sigma^2}{n})$ (dans les mesures où les VA sont indépendantes)

(en effet $E[\frac{1}{n} \sum_{i=1}^n X_i] = \frac{1}{n} \sum_{i=1}^n E[X_i] = m$ et

$$\text{Var}\left(\frac{1}{n} \sum_{i=1}^n X_i\right) = \frac{1}{n^2} \text{Var}\left(\sum_{i=1}^n X_i\right) \stackrel{\substack{\text{ind.} \\ X_i}}{=} \frac{\sum \text{Var } X_i}{n^2} = \frac{\sigma^2}{n}$$

On pose $T(X_1, \dots, X_n) = \frac{1}{n} \sum_{i=1}^n X_i$ ou \leftarrow la loi est connue et dépend de θ

$$T(X_1, \dots, X_n) = \frac{\frac{1}{n} \sum_{i=1}^n X_i - m}{\sigma/\sqrt{n}} \sim \mathcal{N}(0,1) \rightarrow \text{Tabulé}$$


Rq: $T(X_1, \dots, X_n)$ n'est pas unique

Intervalle de confiance pour m:


il se détermine grâce à

$$P[a < T(X_1, \dots, X_n) < b] = \alpha$$

Prenons $\alpha = 0,95 = 95\%$




On détermine a et b à l'aide des tables



$$b = 1,96$$

$$a = -1,96$$



Donc $P\left[-1,96 < \frac{\frac{1}{n} \sum X_i - m}{\sigma/\sqrt{n}} < 1,96\right] = 95\%$

$$\begin{aligned} -1,96 < \frac{\bar{X} - m}{\sigma/\sqrt{n}} < 1,96 &\Leftrightarrow -1,96 \frac{\sigma}{\sqrt{n}} < \bar{X} - m < 1,96 \frac{\sigma}{\sqrt{n}} \\ &\Leftrightarrow \bar{X} - 1,96 \frac{\sigma}{\sqrt{n}} < m < \bar{X} + 1,96 \frac{\sigma}{\sqrt{n}} \end{aligned}$$


$\left[\bar{X} - 1,96 \frac{\sigma}{\sqrt{n}}, \bar{X} + 1,96 \frac{\sigma}{\sqrt{n}} \right]$ est l'intervalle de confiance pour m avec $\alpha = 0,95$

Ex 2: $X_i \sim N(m, \sigma^2)$ m inconnue

On cherche un intervalle de confiance pour σ^2

On sait que $\hat{\sigma}^2 = \frac{1}{n-1} \sum_{i=1}^n (X_i - \bar{X})^2$ est un estimateur non biaisé et convergent de σ^2 .

On montre que $T(X_1, \dots, X_n) = \frac{1}{\sigma^2} \sum_{i=1}^n (X_i - \bar{X})^2 = \frac{n-1}{\sigma^2} \hat{\sigma}^2$ suit une loi du χ^2_{n-1}



les tables donnent $\begin{cases} a = \text{---} \\ b = \text{---} \end{cases}$

$$a < T(X_1, \dots, X_n) < b \iff a < \frac{1}{\sigma^2} \sum (X_i - \bar{X})^2 < b$$

$$\iff \frac{\sum (X_i - \bar{X})^2}{b} < \sigma^2 < \frac{\sum (X_i - \bar{X})^2}{a}$$

Ex 3: $X_i \sim N(m, \sigma^2)$ Intervalle de confiance pour m , σ^2 étant inconnue

On sait que $\bar{X} = \frac{1}{n} \sum_{i=1}^n X_i$ est un bon estimateur de m
et que $\bar{X} \sim N(m, \frac{\sigma^2}{n})$

On ne peut pas prendre $T(X_1, \dots, X_n) = \bar{X}$ car \bar{X} dépend non seulement de m mais aussi de σ^2 .

$$U = \frac{\bar{X} - m}{\sigma/\sqrt{n}} \sim N(0, 1)$$

$$\text{On sait que } V = \frac{1}{\sigma^2} \sum_{i=1}^n (X_i - \bar{X})^2 \sim \chi^2_{n-1}$$

Donc $\frac{U}{\sqrt{\frac{V}{n-1}}} \sim \underbrace{t_{n-1}}_{\text{loi de Student ou du } t, \text{ à } n-1 \text{ d° de liberté}}$

On pose $T(x_1, \dots, x_n) = \frac{\frac{\bar{x} - m}{\sigma/\sqrt{n}}}{\sqrt{\frac{1}{\sigma^2} \sum (x_i - \bar{x})^2} \frac{1}{\sqrt{n-1}}}$

$$= \frac{\bar{x} - m}{\sqrt{\sum (x_i - \bar{x})^2}} \sqrt{n(n-1)} \sim t_{n-1}$$

VIII Méthode des moindres carrés: Exemple de la régression linéaire


1) Principe

On a un nuage de points (x_i, y_i) et on cherche à estimer une relation fonctionnelle entre y_i et x_i .

Par exemple, on cherche la "meilleure" droite qui passe par ces points (x_i, y_i)

2) Méthode:

On modélise les couples (x_i, y_i) de la façon suivante:
(cas de la meilleure droite)



On détermine alors a et b de façon à minimiser

$$g(a, b) = \sum_{i=1}^n \epsilon_i^2 = \sum_{i=1}^n (Y_i - a x_i - b)^2$$

(cf cours d'optimisation, $g(a, b)$ admet un minimum global unique qui vérifie: $\frac{\partial g(a, b)}{\partial a} = 0 \Leftrightarrow \sum_{i=1}^n 2(y_i - a x_i - b)(-x_i) = 0$ (1)

$$\frac{\partial g(a, b)}{\partial b} = 0 \Leftrightarrow \sum_{i=1}^n 2(y_i - a x_i - b)(-1) = 0 \quad (2)$$

$$(2) \quad n \bar{y} - a n \bar{x} - nb = 0 \quad \Rightarrow \quad \boxed{b = \bar{y} - a \bar{x}}$$

$$\text{avec } \bar{y} = \frac{1}{n} \sum y_i \quad \text{et} \quad \bar{x} = \frac{1}{n} \sum x_i$$

$$(1) \quad \sum y_i x_i - a \sum x_i^2 - nb \bar{x} = 0$$

$$\frac{1}{n} \sum y_i x_i - \frac{a}{n} \sum x_i^2 - (\bar{y} - a \bar{x}) \bar{x} = 0$$

$$\text{d'où} \quad \boxed{a = \frac{\frac{1}{n} \sum_{i=1}^n y_i x_i - \bar{y} \bar{x}}{\frac{1}{n} \sum_{i=1}^n x_i^2 - \bar{x}^2}}$$

Si $\sigma_X \neq 0$: $a = \frac{E(XY) - E(X)E(Y)}{\sigma_X^2} = \rho_{X,Y} \frac{\sigma_Y}{\sigma_X}$ et $b = E(Y) - aE(X) = E(Y) - \rho_{X,Y} \frac{\sigma_Y}{\sigma_X} E(X)$.

Nous trouvons alors l'approximation affine :

$$\hat{Y} = E(Y) + \rho_{X,Y} \frac{\sigma_Y}{\sigma_X} [X - E(X)].$$

La droite $y = ax + b$ porte le nom de *droite de régression de Y en X*. Son équation peut s'écrire sous la forme :

$$\frac{y - m_Y}{\sigma_Y} = \rho_{X,Y} \frac{x - m_X}{\sigma_X} \quad [\text{III.21a}]$$

Cette droite passe par le point $[E(X), E(Y)]$ appelé *centre de gravité de la probabilité unité* sur \mathbb{R}^2 .

L'écart quadratique moyen minimum obtenu entre Y et son approximation affine \hat{Y} est alors de :

$$\begin{aligned} E[Y - E(Y) - \rho_{X,Y} \frac{\sigma_Y}{\sigma_X} [X - E(X)]]^2 &= E[Y - E(Y)]^2 + \rho_{X,Y}^2 \frac{\sigma_Y^2}{\sigma_X^2} E[X - E(X)]^2 - 2\rho_{X,Y} \frac{\sigma_Y}{\sigma_X} E[Y - E(Y)][X - E(X)] \\ &= \sigma_Y^2 + \sigma_Y^2 \rho_{X,Y}^2 - 2\sigma_Y^2 \rho_{X,Y}^2 = \sigma_Y^2 [1 - \rho_{X,Y}^2]. \end{aligned}$$

Cet écart est d'autant plus grand que la variance de Y est grande (grande dispersion des valeurs que peut prendre Y) et que la corrélation linéaire de X et de Y est petite.

Si $\sigma_X = 0$: nous avons $X - m_X = 0$ presque sûrement. La minimisation de l'expression [III.20] est indéterminée et tout revient en se fixant $a = 0$, à chercher un nombre b tel que $E[Y - b]^2$ soit minimum. D'après ce que nous avons dit sur la variance de Y , on trouve $b = m_Y$.

Nous constatons que si $\rho_{X,Y} = 0$, la droite de régression de Y en X devient $y - m_Y = 0$. Comme dans le cas précédent, la meilleure approximation de Y au sens des moindres carrés, sous forme d'une fonction affine de X est $Y = m_Y$.


Remarque : Ces résultats peuvent s'obtenir plus simplement de manière géométrique en considérant l'espace de Hilbert $L^2(\Omega, \mathcal{A}, P)$ des variables aléatoires du second ordre définies sur Ω :

D'après les propriétés des espaces de Hilbert, trouver l'approximation affine $aX + b$ de Y qui minimise $E[Y - aX - b]^2$ est équivalent à projeter orthogonalement le vecteur Y sur l'espace vectoriel noté $\text{sp}\{X, 1\}$ engendré par les vecteurs X et 1 (variable aléatoire $1_{\Omega}(\omega)$) :

$$Y - aX - b \perp X \Leftrightarrow E[(Y - aX - b)X] = 0$$

$$Y - aX - b \perp 1 \Leftrightarrow E[(Y - aX - b)1] = 0$$

et l'on retrouve les équations précédentes.



On pourrait chercher également une approximation de X comme fonction affine de Y . Un raisonnement équivalent donnerait une *droite de régression de X en Y* qui aurait pour équation si $\sigma_Y \neq 0$: $x = E(X) + \rho_{X,Y} \frac{\sigma_X}{\sigma_Y} [y - E(Y)]$. Soit :