

## Stats

Qualité d'un estimateur :

L'erreur quadratique moyenne  $EQ(T_n) = E_\theta((T_n - \theta)^2)$

**Th :**  $EQ(T_n) = V(T_n) + b_n^2(\theta)$

*Preuve*

$$\begin{aligned}EQ(T_n) &= E_\theta((T_n - \theta)^2) = E_\theta([(T_n - E[T_n]) + (E[T_n] - \theta)]^2) \\ &= E[(T_n - E[T_n])^2] - E[(E[T_n] - \theta)^2] + 2E[(T_n - E[T_n])(E[T_n] - \theta)]\end{aligned}$$

$$\begin{aligned}EQ(T_n) &= \text{Var}(T_n) + b_n^2(\theta) + 2(E[T_n] - \theta) - E[(T_n - E[T_n])] = E[T_n] - E[E[T_n]] \\ &= E[T_n] - E[T_n] = 0\end{aligned}$$

**Rq :** Si  $t_n$  est un estimateur sans biais de  $\theta$ , alors  $EQ(T_n) = \text{Var}(T_n)$

➔ Un estimateur sans biais est d'autant meilleur que sa variance est petite

Def : Soit  $T_n$  et  $T_n'$  deux estimateurs sans biais de  $\theta$

On dit que  $T_n$  est plus efficace que  $T_n'$  si  $\text{Var}(T_n) \leq \text{Var}(T_n')$  pour tout  $\theta \in \Theta$  et ceci à partir d'un certain rang pour  $n$

*Borne de Cramer-Rao*

La borne de Cramer-Rao est la valeur qui minimise la variance associée aux estimateurs sans biais

Def : On appelle information de Fisher la quantité,

$$I_n(\theta) = E \left[ \left( \frac{\partial \ln L}{\partial \theta} \right)^2 \right] \text{ où } L \text{ est la vraisemblance associée à l'échantillon } (X_1, \dots, X_n)$$

**Rq :**  $I_n(\theta)$  est une quantité fixe qui en général dépend de  $\theta$

**Th :** Sous certaines hypothèses (non détaillés dans leur totalité mais savoir qu'il y a un maximum  $\Theta$  ouvert et  $f$  fonction dérivable par rapport à  $\theta$ ) et si  $X(\Omega)$  est un domaine indépendant de  $\theta$ , alors si  $T_n$  est un estimateur sans biais de  $\theta$ , on a

$$\text{Var}(T_n) \geq \frac{1}{\underbrace{I_n(\theta)}_{\text{borne de cramer rao}}}$$

**Rq :** Si  $X(\Omega)$  est indépendant de  $\theta$ , alors  $I_n(\theta) = E \left[ \left( \frac{\partial \ln L}{\partial \theta} \right)^2 \right]$

Soit une va de loi  $\mathcal{E}(\frac{1}{\theta})$

On veut estimer  $\theta$

On dispose de  $X_1, \dots, X_n$  n va indépendantes et identiquement distribuées de loi  $\mathcal{E}(\frac{1}{\theta})$

$$f(x) = \begin{cases} \frac{1}{\theta} e^{-\frac{x}{\theta}} & \text{si } x \geq 0 \\ 0 & \text{sinon} \end{cases}$$

$$L(x_1, \dots, x_n) = \prod_{i=1}^n f_{\theta}(x_i) = \begin{cases} \left(\frac{1}{\theta}\right)^n e^{-\sum \frac{x_i}{\theta}} & \text{si pour tout } i \ x_i \geq 0 \\ 0 & \text{sinon} \end{cases}$$

$X(\Omega) = [0, +\infty[$  (domaine indépendant de  $\theta$ )

Soit  $x_1, \dots, x_n \in X(\Omega)$

$$\ln L(x_1, \dots, x_n; \theta) = -n \ln \theta - \frac{\sum x_i}{\theta}$$

$$\frac{\partial \ln L}{\partial \theta} = -\frac{n}{\theta} + \frac{\sum x_i}{\theta^2}$$

$$\frac{\partial^2 \ln L}{\partial \theta^2} = \frac{n}{\theta^2} - \frac{2 \sum x_i}{\theta^3}$$

Un estimateur du maximum de vraisemblance de  $\theta$  est  $\bar{X}_n = \frac{1}{n} \sum x_i$

$$I_n(\theta) = E\left[-\frac{d^2 \ln L}{d\theta^2}\right] = -n/\theta + \frac{2}{\theta^3} E[\sum x_i] = \sum E[x_i] = \sum E[X] = nE[X] = n\theta$$

$$I_n(\theta) = -\frac{n}{\theta^2} + \frac{2n\theta}{\theta^3} = \frac{n}{\theta^2}$$

$$I_n(\theta) = E\left[\left(\frac{\partial \ln L}{\partial \theta}\right)^2\right] = E\left[\left(-\frac{n}{\theta} + \frac{\sum x_i}{\theta^2}\right)^2\right] = E\left[\frac{n^2}{\theta^2} + \frac{(\sum x_i)^2}{\theta^4} - \frac{2n \sum x_i}{\theta^3}\right]$$


$$I_n(\theta) = \frac{n^2}{\theta^2} - \frac{2n}{\theta^3} E[\sum x_i] + \frac{1}{\theta^4} E[(\sum x_i)^2]$$

$$E[(\sum x_i)^2] = \text{var}(\sum x_i) + E^2[\sum x_i] \text{ car } \text{Var}(y) = E[y^2] - E^2[y]^2$$

$$= \sum \text{var}(x_i) + n^2 E[(\sum x_i)^2]^2 = n \text{var}(x) + n^2 \theta^2 = n\theta^2 + n^2 \theta^2$$

$$L(x_1, \dots, x_n; \theta) = \begin{cases} \left(\frac{1}{\theta}\right)^n & \text{si pour } i \ x_i \in [0, \theta] \\ 0 & \text{sinon} \end{cases}$$

Dire  $\forall i, x_i \in [0, \theta] \rightarrow \begin{cases} \min(x_i) \geq 0 \\ \max(x_i) \leq \theta \end{cases}$



→ Un estimateur du max de vraisemblance est  $\max(X_i)$

Def : Un estimateur sans biais de  $\theta$ , noté  $T_n$ , est efficace si  $\text{Var}(T_n) = \frac{1}{I_n(\theta)}$

Ex :  $X \sim \mathcal{E}(\frac{1}{\theta})$ ,  $X_1, \dots, X_n$  n échantillon de loi  $\mathcal{E}(\frac{1}{\theta})$  on a vu précédemment que

$T_n = \bar{X}_n = \frac{1}{n} \sum x_i \rightarrow$  estimateur sans biais de  $\theta$

$$I_n(\theta) = \frac{n}{\theta^2}$$

$$\text{Var}(T_n) = \text{Var}\left(\frac{1}{n} \sum x_i\right) = \frac{1}{n^2} \text{Var}\left(\sum x_i\right) = \frac{n\theta^2}{n^2} = \frac{\theta^2}{n}$$

$$\text{Var}(T_n) = \frac{1}{I_n(\theta)}$$

$T_n$  est un estimateur efficace

Rq : un estimateur sans biais et efficace est le meilleur estimateur possible, au cou de l'erreur quadratique moyenne, où  $x_i$  des estimateurs sans biais

Cependant il est parfois possible de trouver un estimateur biaisé qui sera meilleur que l'estimateur sans biais efficace

Ex :  $X \sim \mathcal{N}(0, \sigma^2)$  : paramètre à estimer est  $\sigma^2$

$X_1, \dots, X_n$  n échantillon de mm loi que X

Soit  $\hat{\sigma}_n^2 = \frac{1}{n} \sum x_i^2$  estimateur sans biais et efficace

$T_n = \frac{1}{n} + 2 \sum x_i^2$  : estimateur biaisé de  $\sigma^2$

$$\text{EQ}(T_n) = \frac{2}{n+2} \sigma^2 < \text{EQ}(\hat{\sigma}_n^2) = \frac{2}{n} \sigma^2$$

## Retour aux probabilités

- loi de chi-deux
- loi de Student
- loi de Fisher

- la loi du chi-deux à n degré de liberté ( $\chi^2(n)$ )

On dit que  $X \sim \chi^2(n)$  si

$X = Y_1^2 + Y_2^2 + \dots + Y_n^2$  avec  $Y_1, \dots, Y_n$  n variable aléatoire indépendantes de loi  $N(0,1)$

**Prop :**  $X \sim \chi^2(n)$

$$E[X] = n$$

$$V[X] = 2n$$

Liberté	0,99      0,9 ...
1	Seuil
2	
⋮	

$P(X \leq t)$

- La loi de Student

Soit  $U \sim \mathcal{N}(0,1)$  et soit  $V \sim \chi^2(n)$  avec U et V indépendantes

$$T = \frac{U}{\sqrt{\frac{1}{n}}} \sim T(n)$$

$$S_n^2 = \frac{1}{n-1} \sum (X_i - \bar{X}_n)^2 \text{ avec } X_i \sim N(m, \sigma^2)$$

$\bar{X}_n$  estimateur sans biais de m

$$\bar{X}_n \sim \mathcal{N}\left(0, \frac{\sigma^2}{n}\right) \rightarrow \frac{\bar{X}_n - m}{\sigma/\sqrt{n}} \sim \mathcal{N}\left(0, \frac{\sigma^2}{n}\right)$$

$$\sqrt{n} * \frac{\bar{X}_n - m}{\sigma} \sim \mathcal{N}(0,1)$$

$$\left. \begin{aligned} \frac{\bar{X}_n - m}{\sigma/\sqrt{n}} &= \frac{\frac{\bar{X}_n - m}{\sigma} \sim \mathcal{N}(0,1)}{\sqrt{\frac{S_n^2}{\sigma^2}/n} \sim \chi^2(n)} \end{aligned} \right\} 2 \text{ variables indépendantes}$$