


Introduction aux statistiques pour l'Ingénieur

Stéphane Canu

asi.insa-rouen.fr/enseignants/~scanu


scanu@insa-rouen.fr



ITI 3, INSA Rouen Normandie, mars 2023

Lecture road map

- 1 Rappels
- 2 Technicités mathématiques
- 3 Information de Fisher
- 4 Borne de Cramer Rao

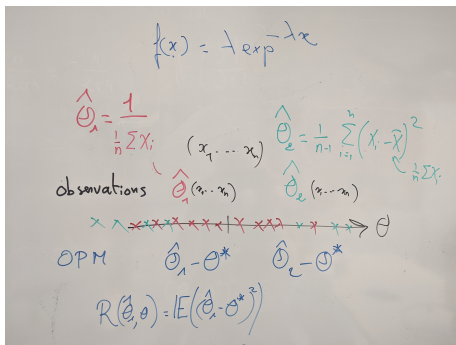


<https://moodle.insa-rouen.fr/course/view.php?id=93>

Comment mesurer la qualité d'un estimateur ?

On définit son risque

$$R_{\hat{\theta}}(\theta) = \mathbb{E}((\hat{\theta}(X_1, \dots, X_n) - \theta)^2)$$




$$R_{\hat{\theta}}(\theta) = \underbrace{\mathbb{E}\left(\left(\hat{\theta} - \mathbb{E}(\hat{\theta})\right)^2\right)}_{\text{Variance}} + \underbrace{\left(\mathbb{E}(\hat{\theta}) - \theta\right)^2}_{\text{Biais}^2}$$

une stratégie pour minimiser le risque R

Trouver un estimateur sans biais de variance minimale

Lecture road map

- 1 Rappels
- 2 Technicités mathématiques
- 3 Information de Fisher
- 4 Borne de Cramer Rao



<https://moodle.insa-rouen.fr/course/view.php?id=93>

Technicités (1) : Intégrale et dérivées

Si

Alors

$$\frac{\partial}{\partial y} \int_{D(x)} \phi(x, y) dx = \int_{D(x)} \frac{\partial \phi(x, y)}{\partial y} dx$$

Exemple : prenons $x = (X_1, \dots, X_n)$, $y = \theta$ et $\phi(x, y)$

$$\mathbb{E} \left(\frac{\partial \ell(\theta, X_1, \dots, X_n)}{\partial \theta} \right) = 0$$

Technicités (2) : inégalité de Cauchy Schwartz

$$\forall (x, y) \in \mathbb{R}^n$$

$$(x^T y)^2 \leq \|x\|^2 \|y\|^2$$

Exemple :

$$\text{cov}(X, Y)^2 \leq \text{Var}(X) \text{Var}(Y)$$

QUALITÉ DES ESTIMATEURS
INFORMATION de FISHER et BORNE de CRAMER-RAO

QUELQUES TECHNICITÉS MATHÉMATIQUES

① INTÉGRALES ET DÉRIVÉS
 $\int \frac{d}{dy} f(x, y) dx = \frac{d}{dy} \int f(x, y) dx$
 $\int \frac{d}{dy} f(x, y) dx = \int \frac{\partial f(x, y)}{\partial y} dx = \frac{d}{dy} \int f(x, y) dx$

$E\left(\frac{d \ln L(\theta; X)}{d\theta}\right) = 0$
 $\frac{d}{d\theta} E(\ln L(\theta; X)) = 0$
 $\frac{d}{d\theta} \int L(\theta; X) \ln L(\theta; X) dx = 0$
 $\int \frac{d}{d\theta} L(\theta; X) \ln L(\theta; X) dx = - \int L(\theta; X) \frac{d \ln L(\theta; X)}{d\theta} dx$
 $\int \frac{d}{d\theta} L(\theta; X) dx = 0$
 $\int \frac{d}{d\theta} L(\theta; X) dx = \frac{d}{d\theta} \int L(\theta; X) dx = 0$

$E\left(\frac{d \ln L(\theta; X)}{d\theta}\right) = \int \frac{d \ln L(\theta; X)}{d\theta} L(\theta; X) dx = 0$
 $E\left(\frac{d \ln L(\theta; X)}{d\theta}\right) = \int \frac{d \ln L(\theta; X)}{d\theta} L(\theta; X) dx = 0$
 $E\left(\frac{d \ln L(\theta; X)}{d\theta}\right) = \int \frac{d \ln L(\theta; X)}{d\theta} L(\theta; X) dx = 0$

INÉGALITÉ de CAUCHY-SCHWARZ
 $(x^T y)^2 \leq \|x\|^2 \|y\|^2 \quad \forall x, y \in \mathbb{R}^n$
 $\|x - y\|^2 \geq 0$
 $\|x\|^2 - 2x^T y + \|y\|^2 \geq 0$
 $\Delta \leq 0 \quad \Delta = \|x - y\|^2 \geq 0$
 $4(x^T y)^2 - 4\|x\|^2 \|y\|^2 \leq 0$
 $(x^T y)^2 \leq \|x\|^2 \|y\|^2$

Information de Fisher : définition

Soit X une variable aléatoire parente de densité ou probabilité $f_\theta(X)$ Avec une log vraisemblance

$$\ell(\theta, X_1, \dots, X_n) = \log L(\theta, X_1, \dots, X_n) = \log \prod_{i=1}^n f_\theta(X_i)$$

L'information de Fisher est

$$I_n(\theta) = \text{Var}\left(\frac{\partial \ell(\theta, X_1, \dots, X_n)}{\partial \theta}\right)$$

Pour $\theta \in \mathbb{R}^p$, L'information de Fisher est la matrice $p \times p$

$$I_n(\theta) = \mathbb{E}(\nabla \ell(\theta, X_1, \dots, X_n) \nabla \ell(\theta, X_1, \dots, X_n)^\top)$$

Information de Fisher : moyen de calcul

$$I_n(\theta) = \text{Var}(\ell'(\theta, X_1, \dots, X_n))$$

Or

$$\mathbb{E} \left(\frac{\partial \ell(\theta, X_1, \dots, X_n)}{\partial \theta} \right) = 0$$

et donc aussi

$$\frac{\partial}{\partial \theta} \mathbb{E} \left(\frac{\partial \ell(\theta, X_1, \dots, X_n)}{\partial \theta} \right) = 0$$

D'où :

L'information de Fisher est aussi

$$I_n(\theta) = -\mathbb{E}(\ell''(\theta, X_1, \dots, X_n)) = -\mathbb{E} \left(\frac{\partial^2 \ell(\theta, X_1, \dots, X_n)}{\partial \theta^2} \right)$$

Information de Fisher : Recette et exemple

$$f(x) = \lambda \exp^{-\lambda x}$$

$$L(\lambda, X_1, \dots, X_n) = \lambda^n \prod_{i=1}^n \exp^{-\lambda X_i}$$

$$\ell(\lambda, X_1, \dots, X_n) = n \log \lambda - \lambda \sum_{i=1}^n X_i$$

$$\frac{\partial \ell(\lambda, X_1, \dots, X_n)}{\partial \lambda} = \frac{n}{\lambda} - \sum_{i=1}^n X_i$$

$$\frac{\partial^2 \ell(\lambda, X_1, \dots, X_n)}{\partial \lambda^2} = -\frac{n}{\lambda^2}$$

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

Matrice (d'information) de Fisher : Exemple

Estimation jointe des paramètres d'une loi normale ($\theta = (\mu, \sigma^2)$)

$$f(x) = \frac{1}{\sqrt{2\pi\sigma^2}} \exp -\frac{(x - \mu)^2}{2\sigma^2}$$

$$\ell(\theta, X_1, \dots, X_n) = -\frac{1}{2\sigma^2} \sum_{i=1}^n (X_i - \mu)^2 - \frac{n}{2} \log \sigma^2 - \frac{n}{2} \log 2\pi$$

$$\nabla \ell(\theta, X_1, \dots, X_n) = \begin{pmatrix} -\frac{1}{\sigma^2} \sum_{i=1}^n (X_i - \mu) \\ \frac{1}{\sigma^4} \sum_{i=1}^n (X_i - \mu)^2 - \frac{n}{2\sigma^2} \end{pmatrix}$$

$$I(\mu, \sigma^2) = \begin{pmatrix} \frac{n}{\sigma^2} & 0 \\ 0 & \frac{n}{2\sigma^4} \end{pmatrix}$$

Théorème de Cramer Rao : énoncé

si

- le support de la distribution ne dépend pas de θ
- la log vraisemblance est différentiable et
- ...
- $\hat{\theta}$ est un estimateur sans biais de θ

alors

$$BCR(\theta) = \frac{1}{I_n(\theta)} \leq \text{Var}(\hat{\theta}(X_1, \dots, X_n))$$

Théorème de Cramer Rao : preuve

$$\mathbb{E}(\hat{\theta}) = \theta \Rightarrow \frac{\partial \mathbb{E}(\hat{\theta})}{\partial \theta} = 1$$

$$\int \hat{\theta}(x_1, \dots, x_n) \frac{\partial L(x_1, \dots, x_n)}{\partial \theta} dx_1, \dots, dx_n = 1$$

$$\text{cov} \left(\hat{\theta}(X_1, \dots, X_n), \frac{\partial \ell(X_1, \dots, X_n)}{\partial \theta} \right) = 1 \quad \text{car } \mathbb{E} \left(\frac{\partial \ell(\theta, X_1, \dots, X_n)}{\partial \theta} \right) = 0$$

or d'après Cauchy Schwartz

$$1 \leq \text{Var}(\hat{\theta}(X_1, \dots, X_n)) \text{Var} \left(\frac{\partial \ell(X_1, \dots, X_n)}{\partial \theta} \right) = \text{Var}(\hat{\theta}(X_1, \dots, X_n)) I(\theta)$$

QUALITE DES ESTIMATEURS
INFORMATION de FISHER + **BORNE de CRAMER RAO**

$X \sim f_{\theta}(x)$
 $L(\theta; x) = \prod_{i=1}^n f_{\theta}(x_i)$
 $\ell(\theta; x) = \log L(\theta; x)$
 $R(\theta) = E(\hat{\theta}) = V(\hat{\theta}) + \text{Bias}^2$
 $\frac{d}{d\theta} \int f_{\theta}(x) dx = \int \frac{d}{d\theta} f_{\theta}(x) dx \Rightarrow$ **ICI ne dépend pas de θ**
 $E \left(\frac{d \ell(\theta; x)}{d\theta} \right) = 0$ (1)
 $\text{cov}(X_i) = \frac{d}{d\theta} \int x_i f_{\theta}(x) dx$ (2)
 $\frac{d}{d\theta} \int \hat{\theta}(x) f_{\theta}(x) dx = \frac{d}{d\theta} \int \hat{\theta}(x) f_{\theta}(x) dx = 1$ (3)
 $\frac{d}{d\theta} \int \hat{\theta}(x) f_{\theta}(x) dx = \frac{d}{d\theta} \int \hat{\theta}(x) f_{\theta}(x) dx = 1$ (4)
 $\frac{d}{d\theta} \int \hat{\theta}(x) f_{\theta}(x) dx = \frac{d}{d\theta} \int \hat{\theta}(x) f_{\theta}(x) dx = 1$ (5)
 $\frac{d}{d\theta} \int \hat{\theta}(x) f_{\theta}(x) dx = \frac{d}{d\theta} \int \hat{\theta}(x) f_{\theta}(x) dx = 1$ (6)

EST sans BIAS $E(\hat{\theta}(x)) = \theta$ (1)
 $\frac{d}{d\theta} E(\hat{\theta}(x)) = 1$ (2)
 $\frac{d}{d\theta} \int \hat{\theta}(x) f_{\theta}(x) dx = 1$ (3)
 $\frac{d}{d\theta} \int \hat{\theta}(x) f_{\theta}(x) dx = 1$ (4)
 $\frac{d}{d\theta} \int \hat{\theta}(x) f_{\theta}(x) dx = 1$ (5)
 $\frac{d}{d\theta} \int \hat{\theta}(x) f_{\theta}(x) dx = 1$ (6)

1 $1 \leq \text{Var}(\hat{\theta}) \text{Var} \left(\frac{d\ell}{d\theta} \right)$
 $\frac{1}{I(\theta)} \leq V(\hat{\theta})$
 avec $I(\theta) = \text{Var} \left(\frac{d\ell(\theta; x)}{d\theta} \right)$
 $I(\theta)$ est appelée l'information de Fisher du paramètre θ .
 $\frac{1}{I(\theta)}$ est appelé la BORNE de CRAMER RAO.
 $\hat{\theta}$ EST EFFICACE si $E(\hat{\theta}) = \theta$ et $V(\hat{\theta}) = \frac{1}{I(\theta)}$ (sans biais)

Théorème de Cramer Rao : Exemple

Estimation de l'espérance d'une loi normale avec σ^2 connu ($\theta = \mu$)

$$f(x) = \frac{1}{\sqrt{2\pi\sigma^2}} \exp -\frac{(x-\mu)^2}{2\sigma^2}$$

$$\ell(\mu, X_1, \dots, X_n) = -\frac{1}{2\sigma^2} \sum_{i=1}^n (X_i - \mu)^2 - \frac{n}{2} \log \sigma^2 - \frac{n}{2} \log 2\pi$$

$$\frac{\partial \ell(\mu, X_1, \dots, X_n)}{\partial \mu} = -\frac{1}{\sigma^2} \sum_{i=1}^n (X_i - \mu)$$

or $\text{Var}(X_i - \mu) = \sigma^2$ et donc

$$\text{Var} \left(\frac{\partial \ell(\mu, X_1, \dots, X_n)}{\partial \mu} \right) = \frac{n}{\sigma^2}$$

L'estimateur $\hat{\theta} = \frac{1}{n} \sum_{i=1}^n X_i$ est sans biais et efficace.

Théorème de Cramer Rao : Exemple

Estimation de la variance d'une loi normale μ connu ($\theta = \sigma^2$)

$$\frac{\partial \ell(\sigma^2, X_1, \dots, X_n)}{\partial \sigma^2} = \frac{1}{2\sigma^4} \sum_{i=1}^n (X_i - \mu)^2 - \frac{n}{2\sigma^2}$$

or, si X_i suit une loi normale, $\sum_{i=1}^n \frac{(X_i - \mu)^2}{\sigma^2}$ suit une loi du chi 2 à n degrés de liberté, et donc $\text{Var}(\sum_{i=1}^n (X_i - \mu)^2) = 2n\sigma^4$ d'où

$$\text{Var} \left(\frac{\partial \ell(\sigma^2, X_1, \dots, X_n)}{\partial \sigma^2} \right) = \frac{n}{2\sigma^4}$$

L'estimateur $\hat{\theta} = S_{n-1} = \frac{1}{n-1} \sum_{i=1}^n (X_i - \bar{X})^2$ est bien sans biais mais pas efficace car :

$$\text{BCR}(\sigma^2) = \frac{2\sigma^4}{n} \leq \text{Var}(S_{n-1}) = \frac{2\sigma^4}{n-1}$$

minimum variance unbiased estimator (MVUE)

Si

$$\frac{\partial \ell(X_1, \dots, X_n)}{\partial \theta} = A(n, \theta) (\hat{\theta}(X_1, \dots, X_n) - \theta)$$

Alors $\hat{\theta}(X_1, \dots, X_n)$ est un estimateur sans biais de risque minimal (UMUE)

Preuve : puisque $\mathbb{E} \left(\frac{\partial \ell(X_1, \dots, X_n)}{\partial \theta} \right) = 0$,

$$\mathbb{E}(\hat{\theta}(X_1, \dots, X_n) - \theta) = 0$$

D'autre part, on a $I(\theta) = -\mathbb{E} \left(\frac{\partial^2 \ell(X_1, \dots, X_n)}{\partial \theta^2} \right) = A(n, \theta)$ et

$\text{Var} \left(\frac{\partial \ell(X_1, \dots, X_n)}{\partial \theta} \right) = A(n, \theta)^2 \text{Var}(\hat{\theta}(X_1, \dots, X_n))$ d'où :

$$\text{Var}(\hat{\theta}(X_1, \dots, X_n)) = \frac{1}{A(n, \theta)} = \frac{1}{I(\theta)}$$

Estimateur d'une fonction de θ

estimateur sans biais d'une fonction de θ : $\mathbb{E}(\hat{u}(\theta)) = u(\theta)$

$$\mathbb{E}(\hat{u}(\theta)) = u(\theta) \quad \Rightarrow \quad \frac{\partial \mathbb{E}(\hat{u}(\theta))}{\partial \theta} = u'(\theta)$$

Dans ce cas :

$$BCR(\theta) = \frac{u'(\theta)^2}{I_n(\theta)} \leq \text{Var}(\hat{u}(\theta(X_1, \dots, X_n)))$$

Conclusion - fiche recette

❶ Vraisemblance : $L(\theta, X_1, \dots, X_n) = \prod_{i=1}^n f_{\theta}(X_i)$

❷ Log vraisemblance : $\ell(\theta, X_1, \dots, X_n) = \log L = \sum_{i=1}^n \log f_{\theta}(X_i)$

❸ Calcul de la dérivée de la log vraisemblance $\frac{\partial \ell(\theta, X_1, \dots, X_n)}{\partial \theta}$

S'il existe un estimateur $\hat{\theta}(X_1, \dots, X_n)$ de θ tel que

$$\frac{\partial \ell(X_1, \dots, X_n)}{\partial \theta} = A(n, \theta)(\hat{\theta}(X_1, \dots, X_n) - \theta)$$

Alors $\hat{\theta}(X_1, \dots, X_n)$ est un estimateur sans biais de risque minimal (UMUE)

S'il existe une fonction u de \mathbb{R} sur \mathbb{R}

$$\frac{\partial \ell(X_1, \dots, X_n)}{\partial \theta} = A(n, \theta)(\hat{u}(X_1, \dots, X_n) - u(\theta))$$

Alors $\hat{u}(\theta)$ est un estimateur sans biais de risque minimal de $u(\theta)$

Exemple (1) : la loi de Bernouilli

$$f(x) = p^x(1-p)^{1-x}$$

$$L(\lambda, X_1, \dots, X_n) = \prod_{i=1}^n p^{X_i}(1-p)^{1-X_i}$$

$$\ell(\lambda, X_1, \dots, X_n) = \log p \sum_{i=1}^n X_i + \log(1-p)(n - \sum_{i=1}^n X_i)$$

$$\begin{aligned} \frac{\partial \ell(\lambda, X_1, \dots, X_n)}{\partial \lambda} &= \frac{\sum_{i=1}^n X_i}{p} - \frac{n - \sum_{i=1}^n X_i}{1-p} \\ &= \frac{n}{p(1-p)} \left(\frac{1}{n} \sum_{i=1}^n X_i - p \right) \end{aligned}$$

$$\hat{\theta}(X_1, \dots, X_n) = \frac{1}{n} \sum_{i=1}^n X_i, \quad A(n, p) = \frac{n}{p(1-p)}, \quad \text{Var}(\hat{\theta}) = \frac{p(1-p)}{n}$$

Exemple (2) : la loi exponentielle

$$f(x) = \lambda \exp^{-\lambda x}$$

$$L(\lambda, X_1, \dots, X_n) = \lambda^n \prod_{i=1}^n \exp^{-\lambda X_i}$$

$$\ell(\lambda, X_1, \dots, X_n) = n \log \lambda - \lambda \sum_{i=1}^n X_i$$

$$\begin{aligned} \frac{\partial \ell(\lambda, X_1, \dots, X_n)}{\partial \lambda} &= \frac{n}{\lambda} - \sum_{i=1}^n X_i \\ &= -n \left(\frac{1}{n} \sum_{i=1}^n X_i - \frac{1}{\lambda} \right) \end{aligned}$$

$$u(\lambda) = \frac{1}{\lambda}, \quad \hat{u}(X_1, \dots, X_n) = \frac{1}{n} \sum_{i=1}^n X_i$$

$$\text{Var}(\hat{u}) = \text{Var}\left(\frac{1}{n} \sum_{i=1}^n X_i\right) = -\frac{u'(\lambda)}{A(n, \lambda)} = \frac{1}{n\lambda^2},$$

Borne de Cramer Rao des estimateurs biaisés

Soit $\hat{\theta}$ un estimateur de biais B avec donc :

$$B(\theta) = \mathbb{E}(\hat{\theta}) - \theta$$

$$\mathbb{E}(\hat{\theta}) = \theta + B(\theta) \quad \Rightarrow \quad \frac{\partial \mathbb{E}(\hat{\theta})}{\partial \theta} = 1 + B'(\theta)$$

Dans ce cas :

$$BCR(\theta) = \frac{1 + B'(\theta)}{I_n(\theta)} \leq \text{Var}(\hat{\theta}(X_1, \dots, X_n))$$

Estimateur et vraisemblance

Le modèle : X de loi parente de distribution $f_\theta(x)$

Échantillon i.i.d.

$$(X_1, \dots, X_n)$$

Vraisemblance :

$$L(\theta, X_1, \dots, X_n) = \prod_{i=1}^n f_\theta(X_i)$$

Log vraisemblance :

$$\ell(\theta, X_1, \dots, X_n) = \log L(\theta, X_1, \dots, X_n) = \sum_{i=1}^n \log f_\theta(X_i)$$

Estimateur du max de vraisemblance

$$\hat{\theta}_{MV} = \arg \max_{\theta} \ell(\theta, X_1, \dots, X_n) \Leftrightarrow \left. \frac{\partial \ell(\theta, X_1, \dots, X_n)}{\partial \theta} \right|_{\theta = \hat{\theta}_{MV}} = 0$$

Propriété des estimateurs max de vraisemblance

Si

- la probabilité ou de la densité dépend d'un paramètre θ
- le support de la probabilité ou de la densité ne dépend pas de θ
- si l existe, est inversible et quelques autres conditions plus techniques

Asymptotiquement sans biais

$$\hat{\theta}_{MV} \xrightarrow[n \rightarrow \infty]{} \theta^*$$

Asymptotiquement efficace

$$\text{Var}(\hat{\theta}_{MV}) \xrightarrow[n \rightarrow \infty]{} I_n^{-1}(\theta^*)$$

Asymptotiquement normal

$$\sqrt{n}(\hat{\theta}_{MV} - \theta^*) \xrightarrow[n \rightarrow \infty]{} \mathcal{N}(0, I_1^{-1}(\theta^*))$$

note : $I_n(\theta^*) = nI_1(\theta^*)$