

Cours #1 du 20/01/2025

iid = indépendantes et identiquement distribuées

Échantillon: ensemble de n va indépendants et identiquement distribués

Exemple $X_i \sim N(\mu, \sigma^2)$ $\theta = \begin{pmatrix} \mu \\ \sigma^2 \end{pmatrix}$ vecteur des paramètres inconnus du modèle

Estimation statistique: chercher une valeur approchée de θ à l'aide des données x_1, \dots, x_n ou de ses variables aléatoires associées

X_1, \dots, X_n :

Notation

$$\hat{\theta} = \begin{pmatrix} \hat{\mu} \\ \hat{\sigma}^2 \end{pmatrix}$$

Exemple

$$\hat{\theta} = \begin{pmatrix} \frac{1}{n} \sum_{i=1}^n x_i \\ \frac{1}{n} \sum_{i=1}^n x_i^2 - \left(\frac{1}{n} \sum_{i=1}^n x_i \right)^2 \end{pmatrix}$$

$$\begin{cases} \mu = E(X_i) \\ \sigma^2 = E(X_i^2) - E(X_i)^2 \end{cases}$$

Erreur quadratique moyenne

biais $E[\hat{\theta}] - \theta$

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

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

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

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

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

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

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

$$EQ_n = \text{variance} + (\text{biais})^2$$

biais

$= (E[\hat{\theta}] - \theta)^2$
carré du biais

Comparaison d'estimateurs

$$X_i \sim N(m, \sigma^2) \quad \theta = m \quad \left\{ \begin{array}{l} \hat{\theta}_n = \frac{1}{n} \sum_{i=1}^n x_i \\ \tilde{\theta}_n = \frac{2}{n(n+1)} \sum_{i=1}^n i x_i \end{array} \right.$$

Lequel de ces deux estimateurs préférez-vous ?

Biais.

biais de $\hat{\theta}_n$: $E(\hat{\theta}_n) - \theta$

$$E(\hat{\theta}_n) = \frac{1}{n} \sum_{i=1}^n E(x_i) = m = \theta$$

$X_i \sim N(m, \sigma^2)$
 $\uparrow \quad \uparrow$
 $E(x_i) \quad \text{Var}(x_i)$

donc $\boxed{E(\hat{\theta}_n) - \theta = 0}$
 $\hat{\theta}_n$ est un estimateur non biaisé de $\theta = m$

biais de $\tilde{\theta}_n$: $E(\tilde{\theta}_n) - \theta$

$$E(\tilde{\theta}_n) = E\left(\frac{2}{n(n+1)} \sum_{i=1}^n i x_i\right) = \frac{2}{n(n+1)} \sum_{i=1}^n (i \underbrace{E(x_i)}_m)$$

$$= \frac{2m}{n(n+1)} \left(\sum_{i=1}^n i\right) = m = \theta$$

donc $\boxed{E(\tilde{\theta}_n) - \theta = 0}$

$\tilde{\theta}_n$ est également un estimateur non biaisé de $\theta = m$

Variances-

$$\text{Var}(\hat{\theta}_n) = \text{Var}\left(\frac{1}{n} \sum_{i=1}^n x_i\right)$$

$$\rightarrow = \frac{1}{n^2} \sum_{i=1}^n \underbrace{\text{Var}(x_i)}_{\sigma^2} = \boxed{\frac{\sigma^2}{n}}$$

x_1, \dots, x_n ind

Biais = 0
 $\text{Var}(\hat{\theta}_n) = \frac{\sigma^2}{n} \xrightarrow[n \rightarrow \infty]{\rightarrow 0}$

donc

$\hat{\theta}_n$ est un estimateur convergent

$$\text{Var}(\tilde{\theta}_n) = \text{Var}\left(\frac{2}{n(n+1)} \sum_{i=1}^n i x_i\right)$$

$$\rightarrow = \frac{4}{n^2(n+1)^2} \sum_{i=1}^n \underbrace{\text{Var}(i x_i)}_{i^2 \text{Var}(x_i) = i^2 \sigma^2}$$

Rappel

$$E(ax+b) = aE(x) + b$$

$$\text{Var}(ax+b) = a^2 \text{Var}(x)$$

si x et y sont indep

$$\text{alors } \text{Var}(x+y) = \text{Var}(x) + \text{Var}(y)$$

x_1, \dots, x_n ind
 \Rightarrow la var x_i ind

$$\text{d'où } \text{Var}(\tilde{\theta}_n) = \frac{4\sigma^2}{n^2(n+1)^2} \underbrace{\sum_{i=1}^n i^2}_{\frac{n(n+1)(2n+1)}{6}}$$

$$= \frac{2}{3} \sigma^2 \frac{2n+1}{n(n+1)}$$

$$\underset{n \rightarrow \infty}{\sim} \frac{4\sigma^2}{3n} \rightarrow 0$$

Biais $(\tilde{\theta}_n) > 0$
 $\text{Var}(\tilde{\theta}_n) \xrightarrow[n \rightarrow \infty]{} 0$

donc $\tilde{\theta}_n$ est un estimateur convergent de $\theta = m$

$\frac{4\sigma^2}{3n} > \frac{\sigma^2}{n}$ donc on préfère $\hat{\theta}_n = \frac{1}{n} \sum_{i=1}^n x_i$

Exemple 2 $x_i \sim N(m, \sigma^2)$ $\theta = \begin{pmatrix} m \\ \sigma^2 \end{pmatrix}$ $\hat{\theta} = \begin{pmatrix} \frac{1}{n} \sum_{i=1}^n x_i = \bar{x}_n = \hat{m} \\ \frac{1}{n} \sum_{i=1}^n (x_i - \bar{x}_n)^2 = \hat{\sigma}^2 \end{pmatrix}$

Biais de $\hat{\theta} = \begin{pmatrix} E(\hat{m}) - m \\ E(\hat{\sigma}^2) - \sigma^2 \end{pmatrix} \in \mathbb{R}^2$

on a déjà vu $E(\hat{m}) - m = 0$ (voir exo précédent)

Biais de $\hat{\sigma}^2$
 $E(\hat{\sigma}^2) = E\left[\frac{1}{n} \sum_{i=1}^n (x_i - \bar{x}_n)^2\right]$
 $= \frac{1}{n} \sum_{i=1}^n \underbrace{E[(x_i - \bar{x}_n)^2]}_{E[(x_i - m + m - \bar{x}_n)^2]}$

$$E(\hat{\sigma}^2) = \frac{1}{n} \sum_{i=1}^n \left[\underbrace{E[(x_i - m)^2]}_{\text{Var}(x_i) = \sigma^2} + \underbrace{E[(\bar{x}_n - m)^2]}_{\text{Var } \hat{m} = \frac{\sigma^2}{n}} + 2 \underbrace{E[(x_i - m)(m - \bar{x}_n)]}_{\textcircled{3}} \right]$$

calculé dans l'exemple 1

$$\textcircled{3} = E\left[(x_i - m) \left(m - \frac{1}{n} \sum_{k=1}^n x_k \right) \right] = \frac{1}{n} E\left[(x_i - m) \sum_{k=1}^n (m - x_k) \right]$$

$$= -\frac{1}{n} E\left[\sum_{k=1}^n (x_{i-m})(x_{k-m})\right]$$

$$= -\frac{1}{n} \sum_{k=1}^n E\left[\underbrace{(x_{i-m})(x_{k-m})}_{\text{cov}(x_i, x_k)}\right] = \begin{cases} 0 & k \neq i \\ E[(x_{i-m})^2] & k=i \\ \text{Var } x_i = \sigma^2 & \end{cases}$$

d'où $E(\hat{\sigma}^2) = \frac{1}{n} \sum_{i=1}^n \left(\underbrace{\sigma^2 + \frac{\sigma^2}{n} - \frac{2\sigma^2}{n}}_{\sigma^2 - \frac{\sigma^2}{n} = \frac{(n-1)\sigma^2}{n}} \right)$

$E(\hat{\sigma}^2) = \frac{n-1}{n} \sigma^2 \neq \sigma^2$ donc $\hat{\sigma}^2$ est un estimateur biaisé de σ^2

on pose $(\sigma^2)^* = \frac{n}{n-1} \hat{\sigma}^2$ et alors $E((\sigma^2)^*) = \sigma^2$

$$\uparrow$$

$$\frac{1}{n} \sum_{i=1}^n (x_i - \bar{x}_n)^2$$

Un estimateur non biaisé de la variance est

$$(\sigma^2)^* = \frac{1}{n-1} \sum_{i=1}^n (x_i - \bar{x}_n)^2$$

Calcul de la borne de Cramér-Rao

pour $\hat{\theta} = \frac{1}{n} \sum_{i=1}^n x_i$ estimateur de $\theta = m$

$$\text{BCR}(m) = \frac{(1 + b'_n(\theta))^2}{E\left[-\frac{\partial^2 \text{LL}(x_1, \dots, x_n)}{\partial m^2}\right]}$$

$x_i \sim N(m, \sigma^2)$
 σ^2 connue

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

Log-vraisemblance $\text{Ln}L = \sum_{i=1}^n \left[-\frac{1}{2} \ln(2\pi\sigma^2) - \frac{(x_i - m)^2}{2\sigma^2} \right]$

\downarrow
 $+\frac{1}{\sigma^2} 2(x_i - m)(-1)$

Dérivée première $\frac{\partial L}{\partial \mu} = \sum_{i=1}^n \frac{x_i - \mu}{\sigma^2}$

Dérivée seconde $\frac{\partial^2 L}{\partial \mu^2} = \sum_{i=1}^n \left(-\frac{1}{\sigma^2} \right) = \boxed{-\frac{n}{\sigma^2}}$

Espérance de la dérivée seconde $E\left(\frac{\partial^2 L}{\partial \mu^2} \right) = -\frac{n}{\sigma^2}$

Borne $\frac{[1 + b'_1(\theta)]^2}{E\left[-\frac{\partial^2 L}{\partial \mu^2} \right]} = \frac{1}{-\left(-\frac{n}{\sigma^2} \right)} = \frac{\sigma^2}{n}$

la variance minimale d'un estimateur non biaisé de μ pour le modèle $X_i \sim N(\mu, \sigma^2)$ est $\frac{\sigma^2}{n}$

On sait que $\hat{\mu} = \frac{1}{n} \sum_{i=1}^n X_i$ est non biaisé et de variance $\frac{\sigma^2}{n} = \text{BCR}(\mu)$

donc $\hat{\mu}$ est le meilleur estimateur possible de μ !!

on dit que $\hat{\mu}$ est l'estimateur efficace de μ