

Chapitre 3: Erreurs d'estimation

Dans ce chapitre, on dispose de n observations indépendantes $x_1, \dots, x_n \in \mathcal{D}$ (avec $\mathcal{D} \subset \mathbb{R}$) qui sont des réalisations de la loi \mathcal{L}_{θ^*} , $\theta^* \in \Theta$.

Le modèle statistique est décrit par les échantillons X_1, \dots, X_n i.i.d. de la loi \mathcal{L}_{θ} , avec $\theta \in \Theta \subset \mathbb{R}$. Enfin, le paramètre d'intérêt est $g(\theta)$, où $g: \Theta \rightarrow \mathbb{R}$.

1. Intervalle de confiance

On veut construire un intervalle dans lequel se trouve le paramètre d'intérêt, et ceci avec un niveau de confiance élevé.

Définition (Intervalle de confiance)

Fixons $\alpha \in]0, 1[$. Pour tout $\theta \in \Theta$ et x_1, \dots, x_n un échantillon iid de la loi \mathcal{L}_θ , un intervalle de confiance (IC) par excès de niveau de confiance $(1-\alpha)$ pour $g(\theta)$ est un intervalle aléatoire $I(x_1, \dots, x_n)$ tel que :

$$\mathbb{P}(g(\theta) \in I(x_1, \dots, x_n)) \geq 1 - \alpha.$$

Les observations x_1, \dots, x_n sont des réalisations de la loi \mathcal{L}_{θ^*} . Ayant cet IC, on en déduit que

$$g(\theta^*) \in I(x_1, \dots, x_n) \text{ avec un niveau de confiance } \geq 1 - \alpha$$

Remarques

(1) α vs longueur de l'IC.

2 critères de qualité pour un IC : α , qui doit être petit et la longueur de l'IC, qui doit être petite également.

Mais ces 2 critères de qualité s'opposent : + α est petit, + la longueur de l'IC est grande, et réciproquement. On doit donc réaliser un compromis. La plupart du temps, on prend $\alpha = 5\%$ ou 10% .

(2) Sur l'IC. L'IC est construit avec un estimateur, mais tous les estimateurs ne se valent pas, et un IC construit avec un mauvais estimateur sera un mauvais IC.

Exemple de construction d'un IC

On lance 100 fois une pièce, et on veut une approximation de $\theta^* = \text{proba que la pièce tombe sur pile}$. En codant $\begin{matrix} 1 = \text{pile} \\ 0 = \text{face} \end{matrix}$, on a une suite $x_1, \dots, x_{100} \in \{0, 1\}$ telle que $\bar{x}_{100} = 0,7 \cdot \left(= \frac{1}{100} \sum_{i=1}^{100} x_i \right)$.

Considérons un échantillon x_1, \dots, x_{100} i.i.d de loi $\mathcal{B}(\theta)$, $\theta \in]0, 1[$. Un estimateur naturel de θ est donné par \bar{x}_{100} (cf fin du chap. 2).

Où $\mathbb{E}(X_1) = \theta$ et $\text{var}(X_1) = \theta(1-\theta)$, car $X_1 \sim \mathcal{B}(\theta)$. Alors,

$$\bullet \mathbb{E}(\bar{X}_{100}) = \mathbb{E}\left(\frac{1}{100} \sum_{i=1}^{100} X_i\right) = \frac{1}{100} \sum_{i=1}^{100} \mathbb{E}(X_i) = \frac{1}{100} \sum_{i=1}^{100} \theta = \theta$$

$$\bullet \text{var}(\bar{X}_{100}) = \text{var}\left(\frac{1}{100} \sum_{i=1}^{100} X_i\right) = \frac{1}{10^4} \sum_{i=1}^{100} \text{var}(X_i) = \frac{1}{10^4} \sum_{i=1}^{100} \theta(1-\theta) = \frac{\theta(1-\theta)}{100}$$

car $X_1 \dots X_n$
indép.

Alors, $\forall a > 0$:

$$\mathbb{P}(|\bar{X}_{100} - \theta| \geq a) = \mathbb{P}(|\bar{X}_{100} - \mathbb{E}(\bar{X}_{100})| \geq a) \leq \frac{\text{var}(\bar{X}_{100})}{a^2} = \frac{\theta(1-\theta)}{100 a^2}$$

inégalité BT

Or, $\forall \theta \in]0, 1[$, $\theta(1-\theta) \leq \frac{1}{4}$ donc

$$\mathbb{P}(|\bar{X}_{100} - \theta| \geq a) \leq \frac{1}{400 a^2}$$

Alors, $\mathbb{P}(|\bar{X}_{100} - \theta| < a) = 1 - \mathbb{P}(|\bar{X}_{100} - \theta| \geq a) \geq 1 - \frac{1}{400 a^2}$

Si on veut un IC par excès au niveau 95%, on choisit a t.g.

$$1 - \frac{1}{400a^2} = 0,95 \Leftrightarrow \frac{1}{400a^2} = 0,05$$

$$\Leftrightarrow a^2 = \frac{1}{400 \times 0,05} = \frac{1}{20} \Leftrightarrow a = \frac{1}{\sqrt{20}}$$

On a donc

$$\mathbb{P}\left(|\bar{X}_{100} - \theta| < \frac{1}{\sqrt{20}}\right) \geq 0,95$$

$$\Leftrightarrow \mathbb{P}\left(\theta \in \left] \bar{X}_{100} - \frac{1}{\sqrt{20}}, \bar{X}_{100} + \frac{1}{\sqrt{20}} \right[\right) \geq 0,95$$

Donc l'IC par excès pour θ au niveau 95% est

$$\mathbb{I}(X_1, \dots, X_{100}) = \left] \bar{X}_{100} - \frac{1}{\sqrt{20}}, \bar{X}_{100} + \frac{1}{\sqrt{20}} \right[$$

Rappel

$$|x - \theta| < l$$

$$\Leftrightarrow x \in]\theta - l, \theta + l[$$

Par suite,

$$\theta^* \in \left] \bar{x}_{100} - \frac{1}{\sqrt{20}}, \bar{x}_{100} + \frac{1}{\sqrt{20}} \right[= \left] 0,7 - \frac{1}{\sqrt{20}}; 0,7 + \frac{1}{\sqrt{20}} \right[=]0,47; 0,92[$$

avec un niveau de confiance de 95%.

2. Biais

Pour un estimateur \hat{g} de $g(\theta)$, on veut que ses ^{réalisations} valeurs fluctuent autour de $g(\theta)$. De ce fait, une propriété minimale de \hat{g} est qu'il se comporte en moyenne comme le paramètre d'intérêt.

Définition (Biais) Soient $\theta \in \Theta$, et X_1, \dots, X_n un échantillon iid de la loi \mathcal{L}_θ . Le biais en θ de l'estimateur $\hat{g} = \hat{g}(X_1, \dots, X_n)$ est la quantité

$$B_{\hat{g}}(\theta) = \mathbb{E}(\hat{g}) - g(\theta).$$

On dit que l'estimateur \hat{g} est sans biais si $B_{\hat{g}}(\theta) = 0 \quad \forall \theta \in \Theta$

Exemples

① Dans le modèle de Bernoulli décrit par les échantillons X_1, \dots, X_n de la loi de loi $\mathcal{B}(\theta)$, $\theta \in]0,1[$.

→ si le paramètre d'intérêt est θ .

Estimateur \bar{X}_n (car par la LGN : $\bar{X}_n \approx \mathbb{E}(X_1) = \theta$, car $X_1 \sim \mathcal{B}(\theta)$)

$$\begin{aligned}\mathbb{E}(\bar{X}_n) &= \mathbb{E}\left(\frac{1}{n} \sum_{i=1}^n X_i\right) = \frac{1}{n} \sum_{i=1}^n \mathbb{E}(X_i) = \frac{1}{n} \sum_{i=1}^n \theta, \text{ car } X_i \sim \mathcal{B}(\theta) \\ &= \theta\end{aligned}$$

Donc
$$\boxed{B_{\bar{X}_n}(\theta) = 0 \quad \forall \theta \in]0,1[}$$

→ si le paramètre d'intérêt est $\theta(1-\theta)$ (= variance de la loi $\mathcal{B}(\theta)$)

Comme \bar{X}_n est un estimateur de θ , $\hat{g} = \bar{X}_n(1-\bar{X}_n)$ est un estimateur (par infection) de $\theta(1-\theta)$.

Calculons

$$\mathbb{E}(\hat{g}) = \mathbb{E}(\bar{X}_n(1-\bar{X}_n)) = \mathbb{E}(\bar{X}_n) - \mathbb{E}(\bar{X}_n^2) = \theta - \mathbb{E}(\bar{X}_n^2)$$

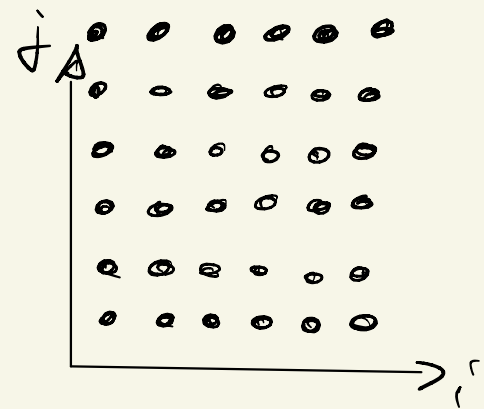
Or,

$$\begin{aligned}\mathbb{E}(\bar{X}_n^2) &= \mathbb{E}\left(\left(\frac{1}{n} \sum_{i=1}^n X_i\right)^2\right) = \frac{1}{n^2} \mathbb{E}\left(\left(\sum_{i=1}^n X_i\right)^2\right) = \frac{1}{n^2} \sum_{i,j=1}^n \mathbb{E}(X_i X_j) \\ &= \frac{1}{n^2} \sum_{i=1}^n \mathbb{E}(X_i^2) + \frac{1}{n^2} \sum_{\substack{i,j=1 \\ i \neq j}}^n \mathbb{E}(X_i X_j)\end{aligned}$$

Or $X_i^2 = X_i$ car $X_i \sim \text{CB}(\theta)$, et si $i \neq j$, X_i indépendante de X_j d'où

$\mathbb{E}(X_i X_j) = \mathbb{E}(X_i) \mathbb{E}(X_j)$. Donc

$$\begin{aligned}\mathbb{E}(\bar{X}_n^2) &= \frac{1}{n^2} \sum_{i=1}^n \underbrace{\mathbb{E}(X_i)}_{=\theta} + \frac{1}{n^2} \sum_{\substack{i,j=1 \\ i \neq j}}^n \underbrace{\mathbb{E}(X_i)}_{=\theta} \underbrace{\mathbb{E}(X_j)}_{=\theta} \\ &= \frac{\theta}{n^2} \underbrace{\sum_{i=1}^n 1}_{=n} + \frac{\theta^2}{n^2} \underbrace{\sum_{\substack{i,j=1 \\ i \neq j}}^n 1}_{=n^2-n} = \frac{\theta}{n} + \frac{\theta^2(n-1)}{n}\end{aligned}$$



Donc $\mathbb{E}(\hat{g}) = \theta - \mathbb{E}(\bar{X}_n^2) = \theta - \frac{\theta}{n} - \frac{\theta^2(n-1)}{n}$. Par suite,

$$\begin{aligned} B_{\hat{g}}(\theta) &= \mathbb{E}(\hat{g}) - \theta(1-\theta) = \theta - \frac{\theta + \theta^2(n-1)}{n} - \theta(1-\theta) \\ &= \cancel{\theta} - \frac{\theta + \theta^2(n-1)}{n} - \cancel{\theta} + \theta^2 = \frac{-\theta - \cancel{\theta^2/n} + \theta^2 + \cancel{\theta^2/n}}{n} \\ &= \frac{\theta(\theta-1)}{n} \neq 0, \text{ donc } \boxed{\hat{g} \text{ est biaisé}} \end{aligned}$$

② Dans le modèle décrit par les échantillons X_1, \dots, X_n iid de loi $\mathcal{G}(\theta)$, avec $\theta \in]0, 1[$. Supposons que le paramètre d'intérêt est θ .

Par la LGN, $\bar{X}_n \simeq \mathbb{E}(X_1) = \frac{1}{\theta}$, car $X_1 \sim \mathcal{G}(\theta)$. L'estimateur de θ par inversion est donc $\frac{1}{\bar{X}_n}$. Calculons son biais pour son biais.

$$|B_{\frac{1}{\bar{X}_n}}(\theta)| = \left| \mathbb{E}\left(\frac{1}{\bar{X}_n}\right) - \theta \right| = \left| \mathbb{E}\left(\frac{1}{\bar{X}_n} - \theta\right) \right| \leq \mathbb{E}\left(\left|\frac{1}{\bar{X}_n} - \theta\right|\right)$$

Rappel $|\mathbb{E}(Z)| \leq \mathbb{E}(|Z|)$

$$|B_{\frac{1}{\bar{X}_n}}(\theta)| \leq \mathbb{E}\left(\left|\frac{1}{\bar{X}_n} - \theta\right|\right) = \mathbb{E}\left(\left|\frac{1 - \theta \bar{X}_n}{\bar{X}_n}\right|\right)$$

$$|\mathbb{E}(Z)| \leq \sqrt{\mathbb{E}(Z^2)}$$

↳ inégalité de Cauchy-Schwarz

Or, comme $X_i \sim \mathcal{G}(\theta)$, $X_i \geq 1 \forall i=1, \dots, n$ d'où $\bar{X}_n = \frac{1}{n} \sum_{i=1}^n X_i \geq \frac{1}{n} \sum_{i=1}^n 1 = 1$

Alors,

$$|B_{\frac{1}{\bar{X}_n}}(\theta)| \leq \mathbb{E}(|1 - \theta \bar{X}_n|) \quad \text{car } \bar{X}_n \geq 1 \Rightarrow \frac{1}{\bar{X}_n} \leq 1$$

$$\Rightarrow |B_{\frac{1}{\bar{X}_n}}(\theta)| \leq \theta \mathbb{E}\left(\left|\frac{1}{\theta} - \bar{X}_n\right|\right) \quad \text{Or } \mathbb{E}(\bar{X}_n) = \frac{1}{n} \sum_{i=1}^n \mathbb{E}(X_i) = \frac{1}{n} \sum_{i=1}^n \frac{1}{\theta} = \frac{1}{\theta}$$

$$\leq \theta \sqrt{\mathbb{E}\left(\left(\frac{1}{\theta} - \bar{X}_n\right)^2\right)} = \theta \sqrt{\text{Var}(\bar{X}_n)}$$

$$\text{Or, } \text{Var}(\bar{X}_n) = \text{Var}\left(\frac{1}{n} \sum_{i=1}^n X_i\right) = \frac{1}{n^2} \text{Var}\left(\sum_{i=1}^n X_i\right) = \frac{1}{n^2} \sum_{i=1}^n \text{Var}(X_i), \quad \text{car } X_1, \dots, X_n \text{ indep.}$$
$$= \frac{1}{n^2} \sum_{i=1}^n \frac{1-\theta}{\theta^2} = \frac{1-\theta}{n\theta^2}$$

$$\text{Donc } \left| B_{\frac{1}{\sqrt{X_n}}(\theta)} \right| \leq \theta \sqrt{\text{var}(X_n)} = \theta \sqrt{\frac{1-\theta}{n\theta^2}} = \frac{\sqrt{1-\theta}}{\sqrt{n}}$$

3. Risque quadratique

On veut évaluer une "distance" entre l'estimateur et son paramètre d'intérêt.

Définition (Risque quadratique) Soient $\theta \in \Theta$ et X_1, \dots, X_n un échantillon iid de la loi \mathcal{L} . Le risque quadratique en θ de l'estimateur $\hat{g} = \hat{g}(X_1, \dots, X_n)$ est la quantité

$$R_{\hat{g}}(\theta) = \mathbb{E}((\hat{g} - g(\theta))^2)$$

Soit \hat{g}' un autre estimateur. Si $\forall \theta \in \Theta, R_{\hat{g}'}(\theta) \leq R_{\hat{g}}(\theta)$,

on dit que \hat{g}' est préférable à \hat{g}

Exemples

⊕ Modèle de Bernoulli : X_1, \dots, X_n iid de loi $\mathcal{B}(\theta)$, $\theta \in]0, 1[$.

Paramètre d'intérêt : θ .

Estimateurs de θ : \bar{X}_n, X_1

Comparons \bar{X}_n à X_1 :

$$R_{X_1}(\theta) = \mathbb{E} \left((X_1 - \theta)^2 \right) = \mathbb{E} \left((X_1 - \mathbb{E}(X_1))^2 \right) = \text{var}(X_1) = \theta(1-\theta)$$

$$R_{\bar{X}_n}(\theta) = \mathbb{E} \left((\bar{X}_n - \theta)^2 \right) = \mathbb{E} \left((\bar{X}_n - \mathbb{E}(\bar{X}_n))^2 \right) = \text{var}(\bar{X}_n) = \frac{1}{n^2} \sum_{i=1}^n \text{var}(X_i)$$

car X_1, \dots, X_n indep.

$$= \frac{1}{n^2} \sum_{i=1}^n \theta(1-\theta) = \frac{\theta(1-\theta)}{n}, \text{ car } X_i \sim \mathcal{B}(\theta).$$

$\mathbb{E}(\bar{X}_n)$, car \bar{X}_n sans biais.

Donc $R_{\bar{X}_n}(\theta) \leq R_{X_1}(\theta) \quad \forall \theta \in]0, 1[\Rightarrow \bar{X}_n$ est préférable à X_1

② Dans le modèle décrit par le n -échantillon X_1, \dots, X_n iid de loi $g(\theta)$, $\theta \in]0, 1[$, considérons le paramètre d'intérêt $g(\theta) = \theta$.

D'après la LGN: $\bar{X}_n \approx \mathbb{E}(X_1) = \frac{1}{\theta}$, car $X_1 \sim g(\theta)$. Donc $\hat{\theta} = \frac{1}{\bar{X}_n}$ est un estimateur naturel de θ . Évaluons maintenant son risque quadratique:

$$R_{\frac{1}{\theta}}(\theta) = \mathbb{E}[(\hat{\theta} - \theta)^2] = \mathbb{E}\left[\left(\frac{1}{\bar{X}_n} - \theta\right)^2\right] = \mathbb{E}\left[\left(\frac{1 - \theta \bar{X}_n}{\bar{X}_n}\right)^2\right]$$

$\forall i, X_i \sim g(\theta)$ donc $X_i \geq 1 \Rightarrow \bar{X}_n = \frac{1}{n} \sum_{i=1}^n X_i \geq \frac{1}{n} \sum_{i=1}^n 1 = 1$. Alors,

$$R_{\frac{1}{\theta}}(\theta) \leq \mathbb{E}[(1 - \theta \bar{X}_n)^2] = \theta^2 \mathbb{E}\left[\left(\frac{1}{\theta} - \bar{X}_n\right)^2\right] = \theta^2 \text{var}(\bar{X}_n)$$

car X_1, \dots, X_n indep.

$$\text{Or, } \text{var}(\bar{X}_n) = \frac{1}{n^2} \sum_{i=1}^n \text{var}(X_i) = \frac{1}{n^2} \sum_{i=1}^n \frac{1-\theta}{\theta^2} = \frac{1-\theta}{n\theta^2}, \text{ d'où}$$

$$\boxed{R_{\frac{1}{\theta}}(\theta) \leq \theta^2 \frac{1-\theta}{n\theta^2} = \frac{1-\theta}{n}}$$

Théorème (Décomposition biais-variance) Soient $\theta \in \Theta$, et X_1, \dots, X_n un échantillon iid de loi \mathcal{L}_θ . Alors, si $\hat{g} = \hat{g}(X_1, \dots, X_n)$ est un estimateur de $g(\theta)$, on a

$$R_{\hat{g}}(\theta) = B_{\hat{g}}(\theta)^2 + \text{var}(\hat{g})$$

Cette décomposition montre qu'à baisser le biais revient à augmenter la variance, et réciproquement.

Preuve On a

$$\begin{aligned} R_{\hat{g}}(\theta) &= \mathbb{E}[(\hat{g} - g(\theta))^2] = \mathbb{E}[(\underbrace{\hat{g} - \mathbb{E}[\hat{g}]} + \underbrace{\mathbb{E}[\hat{g}] - g(\theta)}_0)^2] \\ &= \underbrace{\mathbb{E}[(\hat{g} - \mathbb{E}[\hat{g}])^2]}_{=\text{var}(\hat{g})} + \underbrace{\mathbb{E}[(\mathbb{E}[\hat{g}] - g(\theta))^2]}_{(\mathbb{E}[\hat{g}] - g(\theta))^2} + 2 \underbrace{\mathbb{E}[(\hat{g} - \mathbb{E}[\hat{g}])(\mathbb{E}[\hat{g}] - g(\theta))]}_{=(\mathbb{E}[\hat{g}] - g(\theta))\mathbb{E}[\hat{g} - \mathbb{E}[\hat{g}]]} \\ &= \text{var}(\hat{g}) + B_{\hat{g}}(\theta)^2 + 2(\mathbb{E}[\hat{g}] - g(\theta))(\underbrace{\mathbb{E}[\hat{g}] - \mathbb{E}(\mathbb{E}[\hat{g}])}_{=\mathbb{E}[\hat{g}]}) \\ &= \text{var}(\hat{g}) + B_{\hat{g}}(\theta)^2 + 2(\mathbb{E}[\hat{g}] - g(\theta))(\underbrace{\mathbb{E}[\hat{g}] - \mathbb{E}[\hat{g}]}_{=0}) = \text{var}(\hat{g}) + B_{\hat{g}}(\theta)^2 \quad \square \end{aligned}$$

On suppose que $\forall y_1, \dots, y_n \in \mathcal{D}$:

$$\left\{ \begin{array}{l} \textcircled{H} \ni \theta \mapsto L(\theta; y_1, \dots, y_n) \text{ est de classe } \mathcal{C}^1 \\ \textcircled{H} \ni \theta \mapsto \ln L(\theta; y_1, \dots, y_n) \text{ est de classe } \mathcal{C}^1 \end{array} \right.$$

\hookrightarrow fonction "log-vraisemblance"

Hypothèses de
"régularité"

On note alors $I(\theta)$ l'information de Fisher en θ par

$$I(\theta) = \text{var} \left(\frac{\partial \ln L(\theta; X_1, \dots, X_n)}{\partial \theta} \right)$$

Théorème de Cramer-Rao Supposons que \mathcal{D} est fini et que g est dérivable sur \textcircled{H} . Alors, $\forall \theta \in \textcircled{H}$, X_1, \dots, X_n iid de loi \mathcal{L}_θ et pour tout estimateur sans biais $\hat{g} = \hat{g}(X_1, \dots, X_n)$, on a

$$R_n(\hat{g}) \geq \frac{g'(\theta)^2}{I(\theta)}$$

Cette inégalité nous donne une vitesse de convergence vers 0 de $R_n(\hat{g})$, vitesse qu'on ne peut pas dépasser.

Prove that

$$\frac{\partial \ln L(\theta; y_1, \dots, y_n)}{\partial \theta} = \frac{\frac{\partial L(\theta; y_1, \dots, y_n)}{\partial \theta}}{L(\theta; y_1, \dots, y_n)}$$

Also,

Th. transfer

$$\mathbb{E} \left(\frac{\partial \ln L(\theta; X_1, \dots, X_n)}{\partial \theta} \right) = \sum_{y_1, \dots, y_n \in \Theta} \frac{\partial \ln L(\theta; y_1, \dots, y_n)}{\partial \theta} P(X_1 = y_1, \dots, X_n = y_n)$$

$$= \sum_{y_1, \dots, y_n \in \Theta} \frac{\frac{\partial L(\theta; y_1, \dots, y_n)}{\partial \theta}}{L(\theta; y_1, \dots, y_n)} P(X_1 = y_1, \dots, X_n = y_n)$$

as best friend

$$= \sum_{y_1, \dots, y_n \in \Theta} \frac{\partial L(\theta; y_1, \dots, y_n)}{\partial \theta} = \frac{\partial}{\partial \theta} \left(\sum_{y_1, \dots, y_n \in \Theta} L(\theta; y_1, \dots, y_n) \right)$$

$$\text{So, } \sum_{y_1, \dots, y_n \in \Theta} L(\theta; y_1, \dots, y_n) = \sum_{y_1, \dots, y_n \in \Theta} P(X_1 = y_1, \dots, X_n = y_n) = 1 \text{ done}$$

$$\frac{\partial}{\partial \theta} \left(\sum_{y_1, \dots, y_n \in \Theta} L(\theta; y_1, \dots, y_n) \right) = 0 \Rightarrow$$

$$\boxed{\mathbb{E} \left(\frac{\partial \ln L(\theta; X_1, \dots, X_n)}{\partial \theta} \right) = 0}$$

Comme \hat{g} est une biais, $\mathbb{E}(\hat{g}) = g(\theta)$ d'où

$$g'(\theta) = \frac{d}{d\theta} \mathbb{E}(\hat{g}) = \frac{d}{d\theta} \left(\sum_{y_1, \dots, y_n \in \mathcal{D}} \hat{g}(y_1, \dots, y_n) \underbrace{L(\theta; y_1, \dots, y_n)}_{= P(X_1=y_1, \dots, X_n=y_n)} \right)$$

Cette somme finie

$$= \sum_{y_1, \dots, y_n \in \mathcal{D}} \hat{g}(y_1, \dots, y_n) \frac{\partial L(\theta; y_1, \dots, y_n)}{\partial \theta}$$

$$= \sum_{y_1, \dots, y_n \in \mathcal{D}} \hat{g}(y_1, \dots, y_n) \frac{\partial \ln L(\theta; y_1, \dots, y_n)}{\partial \theta} \underbrace{L(\theta; y_1, \dots, y_n)}_{= P(X_1=y_1, \dots, X_n=y_n)}$$

$$= \mathbb{E} \left(\hat{g}(X_1, \dots, X_n) \frac{\partial \ln L(\theta; X_1, \dots, X_n)}{\partial \theta} \right) - g(\theta) \underbrace{\mathbb{E} \left(\frac{\partial \ln L(\theta; X_1, \dots, X_n)}{\partial \theta} \right)}_{= 0}$$

$$= \mathbb{E} \left(\left(\hat{g}(X_1, \dots, X_n) - g(\theta) \right) \frac{\partial \ln L(\theta; X_1, \dots, X_n)}{\partial \theta} \right)$$

On utilise maintenant l'inégalité de Cauchy-Schwarz : $\mathbb{E}(z_1 z_2)^2 \leq \mathbb{E}(z_1^2) \mathbb{E}(z_2^2)$
 pour des var z_1, z_2 . Alors,

$$g'(\theta)^2 = \left(\mathbb{E} \left(\underbrace{(\hat{g}(x_1, \dots, x_n) - g(\theta))}_{= z_1} \underbrace{\frac{\partial \ln L(\theta; x_1, \dots, x_n)}{\partial \theta}}_{= z_2} \right) \right)^2$$

$$\leq \underbrace{\mathbb{E}[(\hat{g}(x_1, \dots, x_n) - g(\theta))^2]}_{= R_{\hat{g}}(\theta)} \underbrace{\mathbb{E}\left[\left(\frac{\partial \ln L(\theta; x_1, \dots, x_n)}{\partial \theta}\right)^2\right]}_{= I(\theta), \text{ car } \mathbb{E}\left(\frac{\partial \ln L(\theta; x_1, \dots, x_n)}{\partial \theta}\right) = 0.}$$

Donc

$$g'(\theta)^2 \leq R_{\hat{g}}(\theta) I(\theta) \Leftrightarrow \boxed{R_{\hat{g}}(\theta) \geq \frac{g'(\theta)^2}{I(\theta)}}$$

Corollaire Dans le modèle de Bernoulli décrit par les n -échantillons X_1, \dots, X_n iid de lois $\mathcal{B}(\theta)$, $\theta \in]0, 1[$, et θ comme paramètre d'intérêt, la moyenne empirique \bar{X}_n est préférable à tous les estimateurs sans biais.

Preuve Soient $\theta \in]0, 1[$ et X_1, \dots, X_n iid de loi $\mathcal{B}(\theta)$. Calculons

$$I(\theta) = \text{var} \left(\frac{\partial \ln L(\theta; X_1, \dots, X_n)}{\partial \theta} \right)$$

Comme $X_i \sim \mathcal{B}(\theta)$, i.e. $\mathbb{P}(X_i=1) = \theta$ et $\mathbb{P}(X_i=0) = 1-\theta$. Ainsi, si $y \in \{0, 1\}$:

$$\mathbb{P}(X_i=y) = \theta^y (1-\theta)^{1-y} = \begin{cases} \theta & \text{si } y=1 \\ 1-\theta & y=0 \end{cases}$$

Alors, pour $y_1, \dots, y_n \in \{0, 1\}$:

$$\begin{aligned} L(\theta; y_1, \dots, y_n) & \stackrel{\text{dét}}{=} \mathbb{P}(X_1=y_1, \dots, X_n=y_n) = \prod_{i=1}^n \mathbb{P}(X_i=y_i) \text{ car } X_1, \dots, X_n \text{ indep.} \\ & = \prod_{i=1}^n \theta^{y_i} (1-\theta)^{1-y_i} = \theta^{\sum_{i=1}^n y_i} (1-\theta)^{n - \sum_{i=1}^n y_i} \end{aligned}$$

Notons $\bar{y}_n = \frac{1}{n} \sum_{i=1}^n y_i$, d'où

$$L(\theta; y_1, \dots, y_n) = \theta^{n \bar{y}_n} (1-\theta)^{n(1-\bar{y}_n)}$$

Par suite,

$$\ln L(\theta; y_1, \dots, y_n) = n \bar{y}_n \ln \theta + n(1-\bar{y}_n) \ln(1-\theta) \quad \text{"log-vraisemblance"}$$

d'où

$$\frac{\partial \ln L(\theta; y_1, \dots, y_n)}{\partial \theta} = \frac{n \bar{y}_n}{\theta} - \frac{n(1-\bar{y}_n)}{1-\theta}$$

$$\text{On a vu que } \text{var}(\bar{X}_n) = \frac{\theta(1-\theta)}{n}, \text{ d'où}$$

Rappel $\forall a, b \in \mathbb{R}$

$$\text{var}(aZ+b) = a^2 \text{var}(Z)$$

$$I(\theta) = \text{var}\left(\frac{\partial \ln L(\theta; X_1, \dots, X_n)}{\partial \theta}\right) = \text{var}\left(\frac{n \bar{X}_n}{\theta} - \frac{n(1-\bar{X}_n)}{1-\theta}\right)$$

$$= \text{var}\left(\left(\frac{n}{\theta} + \frac{n}{1-\theta}\right) \bar{X}_n - \frac{n}{1-\theta}\right) = \left(\frac{n}{\theta} + \frac{n}{1-\theta}\right)^2 \text{var}(\bar{X}_n)$$

$$= \frac{n^2}{\theta^2(1-\theta)^2} \frac{\theta(1-\theta)}{n} = \frac{n}{\theta(1-\theta)}$$

De plus, comme $g(\theta) = \theta$, on a $g'(\theta) = 1$. Est alors $\hat{\theta}$ un estimateur sans biais de θ . D'après le théo. de Cramer-Rao :

$$R_{\hat{\theta}}(\theta) = \frac{g'(\theta)^2}{I(\theta)} = \frac{1}{\frac{n}{\theta(1-\theta)}} = \frac{\theta(1-\theta)}{n}$$

Or, on a déjà vu que $R_{\bar{X}_n}(\theta) = \frac{\theta(1-\theta)}{n}$, d'où

$$R_{\hat{\theta}}(\theta) \geq R_{\bar{X}_n}(\theta)$$

ce qui montre que \bar{X}_n est préférable à tout autre estimateur sans biais.

—————|

On vient de montrer que dans le modèle de Bernoulli, \bar{X}_n est préférable à tous les estimateurs sans biais de θ . Mais existe-t-il un autre estimateur

sans biais, noté $\hat{\theta}_0$, tel que

$R_{\hat{\theta}_0}(\theta) \leq R_{\hat{\theta}}(\theta)$, pour tout estimateur $\hat{\theta}$ sans biais ?

Supposons par l'absurde, qu'un tel estimateur $\hat{\theta}_0$ existe. Pour $x \in \mathbb{R}$, notons

$$\hat{\psi}_x = \hat{\theta}_0 + x(\hat{\theta}_0 - \bar{X}_n)$$

Alors, $\hat{\psi}_x$ est sans biais :

$$\begin{aligned} \mathbb{E}(\hat{\psi}_x) &= \mathbb{E}(\hat{\theta}_0) + x(\mathbb{E}(\hat{\theta}_0) - \mathbb{E}(\bar{X}_n)) \\ &= \theta + x(\theta - \theta), \text{ car } \hat{\theta}_0 \text{ et } \bar{X}_n \text{ sont sans biais} \\ &= \theta \end{aligned}$$

Par suite, par hypothèse sur $\hat{\theta}_0$:

$$R_{\hat{\theta}_0}(\theta) \leq R_{\hat{\psi}_x}(\theta)$$

Puis, on calcule :

$$\begin{aligned} R_{\hat{\psi}_x}(\theta) &= \mathbb{E}(\underbrace{(\hat{\psi}_x - \theta)^2}_{\text{déb}}) = \mathbb{E}((\hat{\theta}_0 - \theta + x(\hat{\theta}_0 - \bar{X}_n))^2) \\ &= \mathbb{E}((\hat{\theta}_0 - \theta)^2) + x^2 \mathbb{E}((\hat{\theta}_0 - \bar{X}_n)^2) + 2x \mathbb{E}((\hat{\theta}_0 - \theta)(\hat{\theta}_0 - \bar{X}_n)) \\ &= R_{\hat{\theta}_0}(\theta) \end{aligned}$$

On a donc

$$x^2 \mathbb{E}((\hat{\theta}_0 - x_n)^2) + 2x \mathbb{E}((\hat{\theta}_0 - \theta)(\hat{\theta}_0 - \bar{x}_n)) = \mathcal{R}_{\hat{\theta}_0}(\theta) - \mathcal{R}_{\hat{\theta}_0}(\theta) \geq 0 \text{ par hyp.}$$

Ce polynôme de degré 2 en x a donc 0 ou 1 racine, son discriminant vaut

$$\Delta = 4 \mathbb{E}((\hat{\theta}_0 - \theta)(\hat{\theta}_0 - \bar{x}_n))^2$$

Comme le polynôme en x ne prend que des valeurs ≥ 0 , cela impose

$\Delta = 0$, autrement dit

$$\mathbb{E}((\hat{\theta}_0 - \theta)(\hat{\theta}_0 - \bar{x}_n)) = 0$$

On peut montrer de même, avec l'estimateur $\hat{\psi}_x = \bar{x}_n + x(\bar{x}_n - \hat{\theta}_0)$, que

$$\mathbb{E}((\bar{x}_n - \theta)(\hat{\theta}_0 - \bar{x}_n)) = 0$$

Alors,

$$\mathbb{E}((\hat{\theta}_0 - \bar{x}_n)^2) = \mathbb{E}((\hat{\theta}_0 - \bar{x}_n)(\hat{\theta}_0 - \bar{x}_n)) = \mathbb{E}((\hat{\theta}_0 - \theta + \theta - \bar{x}_n)(\hat{\theta}_0 - \bar{x}_n))$$

$$= \underbrace{\mathbb{E}((\hat{\theta}_0 - \theta)(\hat{\theta}_0 - \bar{X}_n))}_{=0} - \underbrace{\mathbb{E}((\bar{X}_n - \theta)(\hat{\theta}_0 - \bar{X}_n))}_{=0}$$

Donc $\mathbb{E}((\hat{\theta}_0 - \bar{X}_n)^2) = 0 \Rightarrow \boxed{\hat{\theta}_0 = \bar{X}_n}$: \bar{X}_n est le seul estimateur sans biais qui soit préférable à tous les autres estimateurs sans biais.

Exercice Modèle de Poisson: X_1, \dots, X_n iid de la $\mathcal{P}(\theta)$, $\theta > 0$.

On sait que $\mathbb{E}(X_i) = \theta$. Comme, d'après la LGN: $\bar{X}_n \approx \mathbb{E}(X_i) = \theta$, \bar{X}_n est un estimateur "naturel" de θ . Alors, \bar{X}_n est sans biais, d'où

$$R_{\bar{X}_n}(\theta) = \text{var}(\bar{X}_n) = \text{var}\left(\frac{1}{n} \sum_{i=1}^n X_i\right) = \frac{\text{var}(X_1)}{n}, \text{ car } X_1, \dots, X_n \text{ iid}$$

$$= \frac{\theta}{n}.$$

Calculons maintenant $I(\theta) = \text{var}\left(\frac{\partial \ln L(\theta; X_1, \dots, X_n)}{\partial \theta}\right)$.

On a $\mathbb{P}(X_i = y) = e^{-\theta} \frac{\theta^y}{y!}$, $y \in \mathbb{N}$. car $X_i \sim \mathcal{P}(\theta)$.

Ainsi, $\forall y_1, \dots, y_n \in \mathbb{N}$:

$$L(\theta; y_1, \dots, y_n) = \overset{\text{def}}{P}(X_1 = y_1, \dots, X_n = y_n) = \prod_{i=1}^n P(X_i = y_i) \text{ par indep. de } X_1, \dots, X_n$$

$$= \prod_{i=1}^n e^{-\theta} \frac{\theta^{y_i}}{y_i!} = \frac{e^{-n\theta}}{\prod_{i=1}^n y_i!} \underbrace{\theta^{\sum_{i=1}^n y_i}}_{= e^{n\bar{y}_n \ln \theta}} \quad \bar{y}_n = \frac{1}{n} \sum_{i=1}^n y_i$$

Puis,

$$\ln L(\theta; y_1, \dots, y_n) = -n\theta + n\bar{y}_n \ln(\theta) - \ln\left(\prod_{i=1}^n y_i!\right),$$

et, de ce fait:

$$\frac{\partial \ln L(\theta; y_1, \dots, y_n)}{\partial \theta} = -n + \frac{n\bar{y}_n}{\theta}$$

Par suite,

$$\begin{aligned} I(\theta) &= \text{var}\left(\frac{\partial \ln L(\theta; X_1, \dots, X_n)}{\partial \theta}\right) = \text{var}\left(-n + \frac{n}{\theta} \bar{X}_n\right) = \frac{n^2}{\theta^2} \underbrace{\text{var}(\bar{X}_n)}_{= \frac{\theta}{n}, \text{ cf + haut}} \\ &= \frac{n^2}{\theta^2} \frac{\theta}{n} = \frac{n}{\theta} \end{aligned}$$

D'après le théo. de Cramer-Rao, pour tout estimateur sans biais $\hat{\theta}$ de θ ,

$$R_{\hat{\theta}}(\theta) \geq \frac{1}{I(\theta)} = \frac{\theta}{n} = R_{\bar{X}_n}(\theta)$$

Donc \bar{X}_n est préférable à tous les estimateurs sans biais de θ .