


Rappels si  $\hat{g}$  est un estimateur du paramètre d'intérêt  $g(\theta)$ , le biais en  $\theta$  est  $B_{\hat{g}}(\theta) = \mathbb{E}(\hat{g}) - g(\theta)$ , avec  $X_1, \dots, X_n$  iid de loi  $\mathcal{L}_\theta$ .



Exemples (suite de la séance 5)

①  $X_1, \dots, X_n$  iid de loi  $\mathcal{B}(\theta)$ . On s'intéresse au paramètre  $g(\theta) = \theta(1-\theta)$  dont l'estimateur naturel est  $\hat{g} = \bar{X}_n(1-\bar{X}_n)$ . Pour calculer son biais, on a vu que

$$\mathbb{E}(\bar{X}_n^2) = \frac{1}{n^2} \sum_{i,j=1}^n \mathbb{E}(X_i X_j)$$

$$\text{or } \mathbb{E}(X_i X_j) = \begin{cases} \mathbb{E}(X_i) \mathbb{E}(X_j) & \text{si } i \neq j, \text{ car alors } X_i \text{ est indépendante de } X_j \\ \mathbb{E}(X_i^2) = \mathbb{E}(X_i) & \text{si } i = j, \text{ car } X_i^2 = X_i \end{cases}$$

$$= \begin{cases} \theta^2 & \text{si } i \neq j \\ \theta & \text{si } i = j \end{cases} \quad \text{car } X_i \sim \mathcal{B}(\theta), \text{ d'où } \mathbb{E}(X_i) = \theta$$

$$\text{Donc } \mathbb{E}(\bar{X}_n^2) = \frac{1}{n^2} \sum_{i=1}^n \mathbb{E}(X_i^2) + \frac{1}{n^2} \sum_{\substack{i,j=1 \\ i \neq j}}^n \mathbb{E}(X_i X_j) = \frac{1}{n^2} \sum_{i=1}^n \theta + \frac{1}{n^2} \sum_{\substack{i,j=1 \\ i \neq j}}^n \theta^2$$

$$= \frac{1}{n^2} \times n\theta + \frac{1}{n^2} \theta^2 \sum_{\substack{i,j=1 \\ i \neq j}}^n 1$$

nb de couples

$(i,j)$  tq  $i,j=1, \dots, n$  et  $i \neq j$

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


Absc,

$$\mathbb{E}(\hat{g}) = \mathbb{E}(\bar{X}_n(1-\bar{X}_n)) = \mathbb{E}(\bar{X}_n) - \mathbb{E}(\bar{X}_n^2) = \theta - \left( \frac{\theta + \theta^2(n-1)}{n} \right)$$

Par suite, le biais de  $\hat{g}$  en  $\theta$  vaut:

$$\begin{aligned} B_{\hat{g}}(\theta) &= \mathbb{E}(\hat{g}) - g(\theta) = \mathbb{E}(\hat{g}) - \theta(1-\theta) = \theta - \frac{\theta + \theta^2(n-1)}{n} - \theta(1-\theta) \\ &= \frac{\cancel{n\theta} - \theta - \cancel{\theta^2 n} + \theta^2 - \cancel{n\theta} + \cancel{n\theta^2}}{n} = \frac{\theta^2 - \theta}{n} = \frac{\theta(\theta-1)}{n} \neq 0 \end{aligned}$$

et  $\hat{g}$  est donc biaisé



Il y a  $n^2 - n$  points rouges qui correspondent aux couples  $(i,j)$  tq  $i,j=1, \dots, n$  et  $i \neq j$

② Dans le modèle statistique décrit par le  $n$ -échantillon  $X_1, \dots, X_n$  i.i.d de loi  $g(\theta)$  avec  $\theta \in ]0, 1[$ . L'estimateur par induction du paramètre  $\theta$  est

$$\hat{\theta} = \frac{1}{\bar{X}_n} \quad (\text{cf fin du chapitre précédent})$$

Il n'est pas possible de calculer son biais, on se rabat donc vers une majoration du biais. Alors :

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

Rappel  $Z$  v.a. :

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

or,  $X_1, \dots, X_n$  de loi  $g(\theta)$  donc  $X_i \geq 1 \quad \forall i = 1, \dots, n$  et  $\bar{X}_n = \frac{1}{n} \sum_{i=1}^n X_i \geq \frac{1}{n} \sum_{i=1}^n 1 = 1$

Alors

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

Rappel CS

$Z, Z'$  v.a.

$$\mathbb{E}(ZZ')^2 \leq \mathbb{E}(Z^2)\mathbb{E}(Z'^2)$$

On applique CS avec  $z = |1 - \theta \bar{X}_n|$  et  $z' = 1$  :

$$|B_{\frac{1}{\theta}}(\theta)| \leq \mathbb{E}(|1 - \theta \bar{X}_n|) \leq \sqrt{\mathbb{E}((1 - \theta \bar{X}_n)^2) \times \underbrace{\mathbb{E}(1^2)}_{=1}} = \sqrt{\mathbb{E}((1 - \theta \bar{X}_n)^2)}$$

Or,

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

On a  $\mathbb{E}(X_1) = \frac{1}{\theta}$  car  $X_1 \sim \mathcal{G}(\theta)$  (cf feuille TD1) d'où comme  $X_i \sim \mathcal{G}(\theta)$  :

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

Alors

$$\begin{aligned} \mathbb{E}((1 - \theta \bar{X}_n)^2) &= \theta^2 \mathbb{E}\left(\left(\mathbb{E}(\bar{X}_n) - \bar{X}_n\right)^2\right) = \theta^2 \text{var}(\bar{X}_n) = \theta^2 \text{var}\left(\frac{1}{n} \sum_{i=1}^n X_i\right) \\ &= \frac{\theta^2}{n^2} \text{var}\left(\sum_{i=1}^n X_i\right) = \frac{\theta^2}{n^2} \sum_{i=1}^n \text{var}(X_i), \text{ car } X_1, \dots, X_n \text{ indépendantes} \\ &= \frac{\theta^2}{n^2} \sum_{i=1}^n \text{var}(X_1) \text{ car } X_1, \dots, X_n \text{ de même loi} \\ &= \frac{\theta^2}{n} \text{var}(X_1) = \frac{\theta^2}{n} \frac{1-\theta}{\theta^2} \text{ car } X_1 \sim \mathcal{G}(\theta), \text{ cf feuille TD1} \end{aligned}$$

$$\text{Abs, } |B_{\hat{g}}(\theta)| \leq \sqrt{E((1-\theta)\bar{X}_n)^2} \leq \sqrt{\frac{1-\theta}{n}} \leq \frac{1}{\sqrt{n}} \text{ car } \theta \in ]0,1[.$$

### 3 - Risque quadratique

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

$$R_{\hat{g}}(\theta) = E((\hat{g} - g(\theta))^2) \quad g(\theta) : \text{paramètre d'intérêt.}$$

On veut des estimateurs qui ont un risque quadratique le + faible possible. Si c'est le cas, alors  $\hat{g} \approx g(\theta)$  en moyenne quadratique, c'est donc un "bon" estimateur. Cela nous permet de classer les estimateurs :

Définition Soient  $\theta \in \Theta$  et  $X_1, \dots, X_n$  un échantillon iid de la loi  $\mathcal{L}_\theta$ . On note  $\hat{g}_1 = \hat{g}_1(X_1, \dots, X_n)$  et  $\hat{g}_2 = \hat{g}_2(X_1, \dots, X_n)$  deux estimateurs de  $g(\theta)$ . Si

$$R_{\hat{g}_1}(\theta) \leq R_{\hat{g}_2}(\theta) \quad \forall \theta \in \Theta,$$

on dit que  $\hat{g}_1$  est préférable à  $\hat{g}_2$

## Exemples

① Dans le modèle de Bernoulli décrit par le  $n$ -échantillon  $X_1, \dots, X_n$  iid de loi  $\mathcal{B}(\theta)$ ,  $\theta \in ]0, 1[$ , avec  $\theta$  comme paramètre d'intérêt.

On s'intéresse aux 2 est. vecteurs  $\hat{\theta}_1 = \bar{X}_n$  et  $\hat{\theta}_2 = X_1$ . On a

$$\begin{aligned} R_{\hat{\theta}_1}(\theta) &= \mathbb{E} \left( (\hat{\theta}_1 - \theta)^2 \right) = \mathbb{E} \left( (\bar{X}_n - \theta)^2 \right). \text{ Or, } \mathbb{E}(\bar{X}_n) = \frac{1}{n} \sum_{i=1}^n \mathbb{E}(X_i) = \theta \\ &= \mathbb{E} \left( (\bar{X}_n - \mathbb{E}(\bar{X}_n))^2 \right) = \text{Var}(\bar{X}_n) = \text{Var} \left( \frac{1}{n} \sum_{i=1}^n X_i \right) = \frac{1}{n^2} \text{Var} \left( \sum_{i=1}^n X_i \right) \\ &\stackrel{\substack{\uparrow \\ \text{indép.}}}{=} \frac{1}{n^2} \sum_{i=1}^n \text{Var}(X_i) \stackrel{\substack{\uparrow \\ \text{m \textit{me} loi}}}{=} \frac{1}{n^2} \sum_{i=1}^n \text{Var}(X_1) = \frac{1}{n^2} \sum_{i=1}^n \theta(1-\theta) = \frac{\theta(1-\theta)}{n} \end{aligned}$$

On voit  $R_{\hat{\theta}_1}(\theta) \rightarrow 0$  : la qualité de l'estimateur  $\hat{\theta}_1$  augmente à mesure que l'on reproduit les expériences aléatoires

$$R_{\hat{\theta}_2}(\theta) = \theta(1-\theta) \text{ car } \hat{\theta}_2 = \hat{\theta}_1 \text{ si } n=1$$

Alors, si  $n \geq 2$ ,  $R_{\hat{\theta}_1}(\theta) \leq R_{\hat{\theta}_2}(\theta) \forall \theta \in ]0, 1[$  donc  $\hat{\theta}_1$  est préférable à  $\hat{\theta}_2$ .

② Dans le modèle statistique décrit par le  $n$ -échantillon  $X_1, \dots, X_n$  iid de loi  $\mathcal{P}(\theta)$  avec  $\theta > 0$  et  $\theta$  comme paramètre d'intérêt.

Calculer le risque quadratique de  $\bar{X}_n$ .

$$R_{\bar{X}_n}(\theta) = \mathbb{E} \left( (\bar{X}_n - \theta)^2 \right)$$

Rappel si  $Z \sim \mathcal{P}(\theta)$ ,

$$\mathbb{E}(Z) = \text{var}(Z) = \theta$$

$$\mathbb{E}(\bar{X}_n) = \frac{1}{n} \sum_{i=1}^n \mathbb{E}(X_i) \underset{X_i \sim \mathcal{P}(\theta)}{=} \frac{1}{n} \sum_{i=1}^n \theta = \theta$$

$$\text{var}(Z) = \mathbb{E} \left( (Z - \mathbb{E}(Z))^2 \right)$$

$$\begin{aligned} \text{Donc } R_{\bar{X}_n}(\theta) &= \mathbb{E} \left( (\bar{X}_n - \mathbb{E}(\bar{X}_n))^2 \right) = \text{var}(\bar{X}_n) = \frac{1}{n^2} \text{var} \left( \sum_{i=1}^n X_i \right) \underset{\text{iid}}{=} \frac{1}{n^2} \sum_{i=1}^n \text{var}(X_i) \\ &\underset{\text{indép.}}{=} \frac{1}{n^2} \sum_{i=1}^n \text{var}(X_1) = \frac{n}{n^2} \text{var}(X_1) = \frac{1}{n} \text{var}(X_1) = \frac{\theta}{n} \text{ car } X_1 \sim \mathcal{P}(\theta). \end{aligned}$$

③ Dans le modèle stat décrit par le  $n$ -échantillon  $X_1, \dots, X_n$  iid de loi  $\mathcal{P}(\theta)$ ,  $\theta \in \mathbb{Z}_+, \mathbb{C}$ , et  $g(\theta) = \frac{1}{\theta}$  comme paramètre d'intérêt.

$\bar{X}_n$  est un estimateur naturel de  $\frac{1}{\theta}$  (car  $\bar{X}_n \stackrel{\text{LGN}}{\sim} \mathbb{E}(X_1) = \frac{1}{\theta}$ )

$$R_{\bar{X}_n}(\theta) = \mathbb{E} \left( (\bar{X}_n - \frac{1}{\theta})^2 \right) = \mathbb{E} \left( (\bar{X}_n - \mathbb{E}(\bar{X}_n))^2 \right) \\ = \text{var}(\bar{X}_n) = \dots = \frac{\text{var}(X_1)}{n} = \frac{1-\theta}{n\theta^2} \text{ car } X_1 \sim \mathcal{G}(\theta).$$

Rappel si  $Z \sim \mathcal{G}(\theta)$ ,

$$\mathbb{E}(Z) = \frac{1}{\theta} \text{ et}$$

$$\text{var}(Z) = \frac{1-\theta}{\theta^2}$$

Si maintenant le paramètre d'intérêt est  $\theta$ . Alors  $\hat{\theta} = \frac{1}{\bar{X}_n}$  est un estimateur naturel. Evaluons le risque de  $\hat{\theta}$  :

$$R_{\hat{\theta}}(\theta) = \mathbb{E} \left( (\hat{\theta} - \theta)^2 \right) = \mathbb{E} \left( \left( \frac{1}{\bar{X}_n} - \theta \right)^2 \right) : \text{majorer ce risque pour la prochaine séance de CM.}$$