

Rappels . On dispose d'observations $x_1, \dots, x_n \in \mathcal{O} \subset \mathbb{Z}$ qui sont issues de n expériences indépendantes et identiques .

- Ces n observations sont des réalisations de la loi \mathcal{L}_{θ^*} , $\theta^* \in \Theta$

- θ^* inconnu \rightarrow on introduit la notion de n -échantillon, qui est une suite de variables X_1, \dots, X_n de loi \mathcal{L}_{θ} , pour un $\theta \in \Theta$.

2. Paramètre d'intérêt et estimateur

Le **paramètre d'intérêt** de l'étude statistique est le paramètre dont on veut une approximation . Cela peut être θ , mais cela peut aussi être une fonction de θ . Dans toute la suite, le paramètre d'intérêt sera $g(\theta)$, avec $g: \Theta \rightarrow \mathbb{R}$.

Comment lier $g(\theta)$ aux observations x_1, \dots, x_n ? Il faut définir une notion pour approcher $g(\theta)$, c'est un estimateur .

Définition (Estimateur) Soit $\theta \in \Theta$ et x_1, \dots, x_n un échantillon i.i.d. de la loi \mathcal{L}_θ .
Un estimateur de $g(\theta)$ est une v.a. \hat{g} qui ne dépend que de x_1, \dots, x_n et qui est à valeurs dans $g(\Theta)$.

Intérêt de cette notion x_1, \dots, x_n sont des réalisations indépendantes de la loi \mathcal{L}_{θ^*} . Pour x_1, \dots, x_n i.i.d. de loi \mathcal{L}_θ , $\theta \in \Theta$, la vocation d'un estimateur $\hat{g} = \hat{g}(x_1, \dots, x_n)$ est d'être proche du paramètre d'intérêt $g(\theta)$, au sens où, par exemple

$$\mathbb{E} \left((\hat{g} - g(\theta))^2 \right) \approx 0, \quad \forall \theta \in \Theta.$$

Cette proximité est vraie $\forall \theta \in \Theta$, donc en particulier pour θ^* . Comme les x_1, \dots, x_n sont des réalisations des n variés x_1, \dots, x_n de loi \mathcal{L}_{θ^*} , on en déduit

$$\hat{g}(x_1, \dots, x_n) \approx g(\theta^*)$$

Pour construire des estimateurs, on utilise souvent la LGN. Elle dit que si X_1, X_2, \dots est une suite de va iid, alors

$$\lim_{n \rightarrow \infty} \mathbb{E} \left(\left(\frac{1}{n} \sum_{i=1}^n X_i - \mathbb{E}(X_1) \right)^2 \right) = 0.$$

Ces moyennes $\frac{1}{n} \sum_{i=1}^n X_i$ jouent un rôle majeur dans la construction des estimateurs. On leur donne donc un nom.

Définition (Moyenne empirique). La moyenne empirique de l'échantillon

X_1, \dots, X_n est $\boxed{\bar{X}_n = \frac{1}{n} \sum_{i=1}^n X_i}$

Par exemple, si l'espérance de la loi \mathcal{L}_θ est θ , alors un estimateur du paramètre θ est ? Soit X_1, \dots, X_n un n -échantillon iid de loi \mathcal{L}_θ .

Alors $\bar{X}_n = \frac{1}{n} \sum_{i=1}^n X_i \approx \mathbb{E}(X_1) = \theta$, car $X_1 \sim \mathcal{L}_\theta$. Donc \bar{X}_n est un estimateur naturel de θ . ↑
LGN

Définition (Estimateur par insertion) si $\hat{\theta}$ est un estimateur de θ , alors $g(\hat{\theta})$ est l'estimateur par insertion de $g(\theta)$.

Exemples

① Dans le modèle du jeu de pile ou face. On introduit le n -échantillon X_1, \dots, X_n iid de la $\mathcal{B}(\theta)$, $\theta \in]0, 1[$. On a $\mathbb{E}(X_1) = \sum_{k=0}^1 k \mathbb{P}(X_1=k)$
 $= 0 \times \mathbb{P}(X_1=0) + 1 \times \mathbb{P}(X_1=1) = \mathbb{P}(X_1=1) = \theta$, car $X_1 \sim \mathcal{B}(\theta)$. Donc par la LGN:

$$\bar{X}_n = \frac{1}{n} \sum_{i=1}^n x_i \approx \mathbb{E}(X_1) = \theta \quad (\text{pour } n \text{ grand}).$$

Donc \bar{X}_n est un estimateur naturel de θ - si le paramètre d'intérêt est maintenant $\theta(1-\theta)$ (la variance de la loi $\mathcal{B}(\theta)$), alors l'estimateur (par insertion) est $\bar{X}_n(1-\bar{X}_n)$

② Dans le modèle statistique décrit par le n -échantillon X_1, \dots, X_n iid de la loi $\mathcal{P}(\theta)$ avec $\theta > 0$. On a $\mathbb{E}(X_1) = \theta$ car

$$\mathbb{E}(X_1) = \sum_{k \in \mathbb{N}} k \mathbb{P}(X_1 = k) = \sum_{k \geq 0} k e^{-\theta} \frac{\theta^k}{k!} = e^{-\theta} \sum_{k \geq 0} k \frac{\theta^k}{k!}$$

$$= e^{-\theta} \sum_{k \geq 1} k \frac{\theta^k}{k!} = e^{-\theta} \sum_{k \geq 1} \frac{\theta^k}{(k-1)!}$$

$$= \theta e^{-\theta} \sum_{k \geq 1} \frac{\theta^{k-1}}{(k-1)!} = \theta e^{-\theta} \sum_{\substack{l \geq 0 \\ l = k-1}} \frac{\theta^l}{l!}$$

$$= \theta e^{-\theta} e^{\theta} = \theta.$$

Rappel

$$\sum_{l \geq 0} \frac{\theta^l}{l!} = e^{\theta}$$

Par la LBN, on a $\bar{X}_n = \frac{1}{n} \sum_{i=1}^n X_i \approx \mathbb{E}(X_1) = \theta$, donc \bar{X}_n est un estimateur naturel de θ .

③ Dans le modèle statistique décrit par l'échantillon X_1, \dots, X_n iid de loi $\mathcal{G}(\theta)$, avec $\theta \in]0, 1[$. On considère le paramètre d'intérêt θ .

On cherche un estimateur naturel pour θ . On a montré en TD que

$E(X_i) = \frac{1}{\theta}$ car $X_i \sim \mathcal{G}(\theta)$. Par la LGN:

$$\bar{X}_n \approx E(X_i) = \frac{1}{\theta} \quad (\text{à grand } n).$$

Donc $\frac{1}{\bar{X}_n} \approx \theta \Rightarrow \frac{1}{\bar{X}_n}$ estimateur naturel de θ .