

## Intervalle de confiance

**Définition 1.** Soient  $Y$  une v.a. réelle et  $\alpha \in ]0, 1[$ . On appelle quantile d'ordre  $\alpha$  de  $Y$  le nombre  $q_\alpha$  tel que

$$q_\alpha = \inf \{y \in \mathbb{R} : F_Y(y) \geq \alpha\}.$$

### Propriétés:

1. On a  $\mathbb{P}(Y \leq q_\alpha) = F_Y(q_\alpha) = \alpha$ .
2. Si  $Y$  est une v.a. continue la fonction  $q_\alpha : ]0, 1[ \rightarrow \{x : f_Y(x) > 0\}$  est bijective et continue.
3. Si  $Y$  est une v.a. continue alors pour tout  $0 \leq \beta \leq \gamma \leq 1$  :

$$\mathbb{P}(q_\beta < Y \leq q_\gamma) = \mathbb{P}(Y \leq q_\gamma) - \mathbb{P}(Y \leq q_\beta) = \gamma - \beta.$$

4. Si  $f_Y$  est une fonction paire (= la loi de  $Y$  est symétrique autour de zéro,  $-Y$  a la même loi de  $Y$ ) alors  $q_{1-\alpha} = -q_\alpha$ .
5.  $q_{1/2}$  est la médiane.  $q_{1/4}$  le premier quartile.

### Problème

Une entreprise reçoit d'un de ses fournisseurs un lot de pièces qui doit "normalement" contenir une proportion  $\theta \leq 10\%$  de pièces défectueuses. L'entreprise voudrait, par examen d'un échantillon de taille  $n$ , décider entre  $\theta \leq 10\%$  et  $\theta > 10\%$ , sachant qu'elle acceptera le lot dans le premier cas et le rejettera dans le deuxième cas.

On définit

$$X_i = \begin{cases} 1 & \text{si la pièce prélevée est défectueuse;} \\ 0 & \text{sinon.} \end{cases}$$

$X_1, \dots, X_n$  sont  $n$  variables iid de loi de Bernoulli de paramètre  $\theta$  qui composent l'échantillon  $\mathbf{X}$ . L'EMV est  $\hat{\theta}_n = \bar{X}_n$  (égale à l'estimateur par méthode des moments).

Supposons  $n = 100$  et que on observe  $\bar{X}_n = 0.195$ .

**Question:** Quelle décision l'entreprise doit prendre? Accepter ou rejeter le lot? Et, sur quel critère l'entreprise doit se baser pour prendre sa décision?

**Définition 2.** Soit  $\mathcal{P} = \{\mathbb{P}_\theta : \theta \in \Theta\}$  un modèle paramétrique. On dispose d'un échantillon  $\mathbf{X} = (X_1, \dots, X_n)$  de  $n$  v.a. iid  $\sim \mathbb{P}_\theta$ . Soient  $A_n$  et  $B_n$  deux statistiques. On dira que  $[A_n, B_n]$  est un intervalle de confiance de niveau  $1 - \alpha$  pour  $\theta$  si

$$\mathbb{P}_\theta(A_n \leq \theta \leq B_n) = 1 - \alpha$$

pour tout  $\theta \in \Theta$ .

On dira que  $[A_n, B_n]$  est un intervalle de confiance de niveau asymptotiquement égal à  $1 - \alpha$  pour  $\theta$  si

$$\lim_{n \rightarrow \infty} \mathbb{P}_\theta(A_n \leq \theta \leq B_n) = 1 - \alpha$$

pour tout  $\theta \in \Theta$ .

**Remarque:** Dans les applications on utilise souvent les valeurs  $\alpha = 0.05, 0.01$ .

**Exemple 3.** Soit  $X \sim \mathcal{N}(\mu, 1)$ ,  $\mu \in \mathbb{R}$  notre modèle paramétrique. Soient  $\zeta_\alpha$  les quantiles de la v.a. Gaussienne standard (centrée et réduite). On pose  $A_n = \bar{X}_n - \zeta_\gamma/\sqrt{n}$  et  $B_n = \bar{X}_n - \zeta_\beta/\sqrt{n}$ .

On veut déterminer  $\beta$  et  $\gamma$  dans  $[0, 1]$  tels que  $[A_n, B_n]$  soit un intervalle de confiance de niveau  $1 - \alpha$  pour  $\mu$ .

La v.a.  $\bar{X}_n$  est une Gaussienne de moyenne  $\mu$  et variance  $1/n$  donc

$$\begin{aligned} \mathbb{P}(A_n \leq \mu \leq B_n) &= \mathbb{P}(A_n \leq \mu, \mu \leq B_n) = \mathbb{P}(\bar{X}_n - \zeta_\gamma/\sqrt{n} \leq \mu, \mu \leq \bar{X}_n - \zeta_\beta/\sqrt{n}) \\ &= \mathbb{P}(\sqrt{n}(\bar{X}_n - \mu) \leq \zeta_\gamma, \zeta_\beta \leq \sqrt{n}(\bar{X}_n - \mu)) = \mathbb{P}(\zeta_\beta \leq \sqrt{n}(\bar{X}_n - \mu) \leq \zeta_\gamma) \\ &= \mathbb{P}(\zeta_\beta \leq Z \leq \zeta_\gamma) = \mathbb{P}(Z \leq \zeta_\gamma) - \mathbb{P}(Z \leq \zeta_\beta) \end{aligned}$$

où  $Z \sim \mathcal{N}(0, 1)$ . Par la définition des quantiles Gaussiens on a que  $\mathbb{P}(Z \leq \zeta_r) = r$  pour tout  $r \in ]0, 1[$  et donc

$$1 - \alpha = \mathbb{P}(A_n \leq \mu \leq B_n) = \gamma - \beta$$

est la condition à imposer sur  $\gamma, \beta$  pour avoir un intervalle de confiance à niveau  $1 - \alpha$ .

**Remarque 4.**

- Il existe un nombre infini des intervalles de confiance de niveau  $1 - \alpha$ .
- Si  $\beta \neq 0$  et  $\gamma \neq 1$  on parlera d'un intervalle de confiance bilatérale.
- Si  $\beta = 0$  ( $\gamma = 1 - \alpha$ ) ou si  $\gamma = 1$  ( $\beta = \alpha$ ) on parlera d'un intervalle de confiance unilatéral.
- Si  $\beta = \alpha/2$  et  $\gamma = 1 - \alpha/2$  on parlera d'un intervalle de confiance bilatéral symétrique.
- Valeurs utiles de  $\zeta_\alpha$  :  $\zeta_{1/2} = 0$ ,  $\zeta_{0.9} = 1.28$ ,  $\zeta_{0.95} = 1.645$ ,  $\zeta_{0.975} = 1.96$ ,  $\zeta_{0.995} = 2.58$ .

**Remarque 5.** Dans le cas Gaussien où l'échantillon est tiré de la loi  $\mathcal{N}(\mu, \sigma_0^2)$  avec variance  $\sigma_0^2$  connue, les intervalles plus utilisés sont

- Les intervalles unilatéraux

$$\mathbb{P}(\mu \geq \bar{X}_n - \frac{\sigma_0}{\sqrt{n}} \zeta_{1-\alpha}) = \mathbb{P}(\mu \leq \bar{X}_n + \frac{\sigma_0}{\sqrt{n}} \zeta_{1-\alpha}) = 1 - \alpha;$$

- L'intervalle bilatérale symétrique:

$$\mathbb{P}(\bar{X}_n - \frac{\sigma_0}{\sqrt{n}} \zeta_{1-\alpha/2} \leq \mu \leq \bar{X}_n + \frac{\sigma_0}{\sqrt{n}} \zeta_{1-\alpha/2}) = 1 - \alpha.$$

**Exemple 6.** Reprenons le problème introductif.  $X \sim \text{Ber}(\theta)$ . L'EMV pour  $\theta$  est  $\bar{X}_n$ . Par le TCL:

$$\frac{\sqrt{n}(X_n - \theta)}{\sqrt{\theta(1-\theta)}} \xrightarrow{\mathcal{L}} \mathcal{N}(0, 1)$$

Par la loi des grandes nombres  $\bar{X}_n \xrightarrow{p.s.} \theta$  et donc par le lemme de continuité appliqué à la fonction  $g(x) = \sqrt{x(1-x)}$  on a aussi

$$g(\bar{X}_n) = \sqrt{\bar{X}_n(1-\bar{X}_n)} \xrightarrow{p.s.} \sqrt{\theta(1-\theta)}.$$

On peut conclure par le lemme de Slutsky que

$$\frac{\sqrt{n}(X_n - \theta)}{\sqrt{\bar{X}_n(1-\bar{X}_n)}} = \frac{\sqrt{n}(X_n - \theta)}{\sqrt{\theta(1-\theta)}} \cdot \frac{\sqrt{\theta(1-\theta)}}{\bar{X}_n(1-\bar{X}_n)} \xrightarrow{\mathcal{L}} \mathcal{N}(0, 1).$$

Donc asymptotiquement l'intervalle de confiance symétrique bilatérale pour  $\theta$  est donné par

$$\bar{X}_n - n^{-1/2}(\bar{X}_n(1-\bar{X}_n))^{1/2} \zeta_{1-\alpha/2} \leq \theta \leq \bar{X}_n + n^{-1/2}(\bar{X}_n(1-\bar{X}_n))^{1/2} \zeta_{1-\alpha/2}.$$

**Application:** Si on fixe  $\alpha = 0.05$ . Pour la valeur observé de  $\bar{X}_n = 0.195$  ( $n = 100$ ) on a que l'intervalle de confiance trouvé dans l'exemple précédent est

$$\theta \in [0.117, 0.273]$$

(vérifier). Ce qui permet de rejeter le lot avec niveau de confiance 95%.