

TD 4 : Estimations et intervalles de confiance

I Estimateurs

Exercice 1. Nous considérons dans chacun des cas ci-dessous un n -échantillon X_1, \dots, X_n de loi p_θ . Déterminer à chaque fois $\hat{\theta}_n$ l'estimateur du maximum de vraisemblance de θ , puis étudier ses propriétés (biais, consistance).

- p_θ est la loi géométrique de paramètre $\theta \in]0, 1[$.
- p_θ est la loi Normale $\mathcal{N}(\theta)$ avec $\theta = (m, \sigma^2) \in \mathbb{R} \times]0, +\infty[$.
- p_θ est la loi $\mathcal{E}(\lambda)$ translaté de $\theta > 0$, (c'est-à-dire de densité $\lambda e^{-\lambda(x-\theta)} \mathbb{1}_{[\theta, +\infty[}(x)$) où $\lambda > 0$ est un paramètre supposé connu. On montrera que $\hat{\theta}_n \sim \theta + \mathcal{E}(n\lambda)$. Quel autre estimateur « naturel » fournit la méthode des moments ?
- p_θ est la loi de densité f_θ avec $\theta \in]1/2, 1[$, où

$$\forall x \in \mathbb{R} \quad f_\theta(x) = \frac{\theta}{1-\theta} x^{(2\theta-1)/(1-\theta)} \mathbb{1}_{]0,1[}(x)$$

Exercice 2. Soit T une variable aléatoire réelle dont la densité est donnée par :

$$f(x) = \begin{cases} \frac{2x}{R^2} & \text{si } 0 \leq x \leq R, \\ 0 & \text{sinon} \end{cases}$$

Soient aussi T_1, \dots, T_n n variables aléatoires indépendantes de même loi que T . On pose

$$X_n = \frac{1}{n} \sum_{i=1}^n T_i \quad \text{et} \quad Y_n = \sup_{1 \leq i \leq n} T_i$$

- Calculer $\mathbb{E}[T]$ et $\text{Var}(T)$.
- Calculer $\mathbb{E}[X_n]$ et $\text{Var}(X_n)$.
- Calculer la densité f_n de Y_n , puis son espérance et sa variance.
- Construire à partir de X_n et de Y_n respectivement deux estimateurs \hat{X}_n et \hat{Y}_n sans biais de R . Ces deux estimateurs sont-ils consistants ?

II Intervalles de confiance

Exercice 3 (Elimination de la dépendance en θ). Nous avons vu en cours que, dans le modèle de Bernoulli (où $\theta \in]0, 1[$ est le paramètre recherché), si \bar{X}_n désigne la moyenne empirique de l'échantillon alors

$$\sqrt{n} \frac{\bar{X}_n - \theta}{\sqrt{\bar{X}_n(1 - \bar{X}_n)}} \xrightarrow[n \rightarrow +\infty]{\mathcal{L}} \mathcal{N}(0, 1)$$

(Nous avons utilisé le TCL, la convergence en probabilité de $\sqrt{\bar{X}_n(1 - \bar{X}_n)}$ vers $\sqrt{\theta(1 - \theta)}$ puis le lemme de Slutsky). Ceci nous a permis d'obtenir un intervalle de confiance de θ . Nous allons voir maintenant une autre méthode :

1) En utilisant le TCL et la méthode Delta, trouver une fonction g telle que

$$\sqrt{n} (g(\bar{X}_n) - g(\theta)) \xrightarrow[n \rightarrow +\infty]{\mathcal{L}} \mathcal{N}(0, 1).$$

Indice : La fonction Arcsin est dérivable sur $] - 1, 1[$ et $\text{Arcsin}'(x) = (1 - x^2)^{-1/2}$, pour tout $x \in] - 1, 1[$.

2) En déduire un intervalle de confiance de niveau $1 - \alpha$ pour θ , que l'on exprimera en fonction des quantiles q_r de $\mathcal{N}(0, 1)$.

Exercice 4. Un standard téléphonique reçoit N appels par heures où N suit une loi de Poisson de paramètre λ . Une étude portant sur 80 heures a donné un nombre moyen de 21 appels par heures. Déterminer l'intervalle de confiance asymptotique à 95% du nombre moyen d'appels par heure λ . *Indication* : si $Y \sim \mathcal{N}(0, 1)$ et $t = 1,960$, alors $\mathbb{P}(Y \leq t) \approx 0,975$.

Exercice 5. Une usine fabrique des câbles. On suppose que la charge maximale supportée par un câble, exprimée en tonnes, est une variable aléatoire réelle qui suit une loi normale $\mathcal{N}(\mu, 1/4)$. Une étude portant sur 50 câbles a donné une moyenne des charges maximales supportées égale à 12,2 tonnes.

1) Déterminer l'intervalle de confiance à 99% de la charge maximale moyenne μ de tous les câbles fabriqués par l'usine. *Indication* : si $Y \sim \mathcal{N}(0, 1)$ et $t = 2,575$, alors $\mathbb{P}(Y \leq t) \approx 0,995$.

2) Déterminer la taille minimale n de l'échantillon étudié pour que la longueur de l'intervalle de confiance à 99% soit inférieure ou égale à 0,2.

Exercice 6. (Lien entre intervalles de confiance asymptotiques et non-asymptotiques)

On admettra le théorème suivant :

Borne de Berry-Essen : Soient X_1, \dots, X_n des v.a. i.i.d. telles que $\mathbb{E}[X_1] = 0$ et $\mathbb{E}[X_1^2] = \sigma^2$. On suppose que $\rho = \mathbb{E}[|X_1|^3] < \infty$. Si on définit

$$F_n(x) = \mathbb{P} \left(\frac{X_1 + \dots + X_n}{\sigma\sqrt{n}} \leq x \right) \quad \text{et} \quad \Phi(x) = \mathbb{P}(\mathcal{N}(0, 1) \leq x),$$

alors pour tout $x \in \mathbb{R}$

$$|F_n(x) - \Phi(x)| \leq \frac{3\rho}{\sigma^3\sqrt{n}}.$$

En déduire un intervalle de confiance non-asymptotique de niveau $1 - \alpha$ dans le modèle de Bernoulli, à partir des intervalles obtenus grâce au théorème central limite et en supposant que $\theta_0 \in [\delta, 1 - \delta]$ pour un $\delta \in]0, 1/2[$ (de sorte que $\sigma^2 \geq \delta(1 - \delta) > 0$).

