

Ch. 8 INTERVALLE DE CONFIANCE

Méthodes d'estimation

Estimation du paramètre $\boldsymbol{\theta} = [\theta_1, \dots, \theta_m]^\top$

1. L'estimation ponctuelle :

Pour estimer la vraie valeur $\boldsymbol{\theta}_0$ du paramètre inconnu $\boldsymbol{\theta}$ on utilise une fonction (statistique) qui dépend de l'échantillon (X_1, \dots, X_n) .

(a) On utilise les estimateurs dits *naturels* :

i. \bar{X} pour estimer $\mu = E(X)$

ii. S^2 pour estimer $V(X) = \sigma^2$

iii. f_n pour estimer p

(b) On construit l'E.M.V.

2. L'estimation par Intervalle De Confiance :

- (a) On associe au paramètre θ un intervalle, dit de *confiance*, dans lequel se trouve la vraie valeur θ_0 du paramètre θ , avec une probabilité fixée d'avance, $1 - \alpha$, α étant *le risque ou le niveau de confiance*.

- (b) Cet intervalle dépend **seulement de l'échantillon** et il sera calculé à l'aide d'une **fonction (statistique) dont on connaît la loi**.

Intervalle De Confiance

Modélisation

Definition 1. Soient :

- Un espace probabilisé (Ω, \mathcal{A}, P)
- Une v.a. X dont la loi dépend d'un paramètre Θ avec $\theta \in \Theta \subset \mathbb{R}$
- La famille $\mathcal{I}(\Theta) = \{I_x(\theta) \mid x \in \mathcal{B}_{\mathbb{R}}\}$ d'intervalles de Θ
- On se fixe $\alpha \in [0, 1]$; α est appelé niveau de confiance.
- On souhaite trouver deux statistiques
 $T_1 = T_1(X_1, \dots, X_n)$ et $T_2 = T_2(X_1, \dots, X_n)$.
t.q. $P_\theta(\theta \in I_\alpha) = 1 - \alpha$ avec $I_\alpha = [T_1, T_2]$;

I_α ainsi défini, est appelé I.D.C. pour θ au niveau ou au risque α .

Remarques

- On peut avoir $P_{\theta}(\theta \in I_{\alpha}) \geq 1 - \alpha$
i.e. un intervalle de confiance avec risque minimal α .
- Les bornes étant construites d'une façon aléatoire à partir d'une v.a. sont aussi des v.a.
- Il n'y a pas d'unicité des I.D.C. et il faut donner des critères associés aux problèmes posés.
- **Choix optimal** : C'est le choix de l'intervalle de longueur minimale.

Type de l'I.D.C.

La détermination des bornes de l'I.D.C. dépend du partage du risque α en α_1 et α_2 .

Deux cas se présentent :

1. **Intervalle Bilatéral** de la forme $[a, b]$
avec $\alpha = \alpha_1 + \alpha_2$; $\alpha_1 \neq 0$, $\alpha_2 \neq 0$.

(a) *Symétrique* $\alpha_1 = \alpha_2 = \frac{\alpha}{2}$.

(b) *Asymétrique* ou *Dissymétrique* $\alpha = \alpha_1 + \alpha_2$; $\alpha_1 \neq \alpha_2$.

I.D.C. bilatéral

Symétrique

Dissymétrique

2. Intervalle unilatéral

(a) *Bloqué à gauche* : $[a, +\infty[$: $\alpha_1 = a$ et $\alpha_2 = 0$.

Intervalle utilisé dans le cas où $\theta > a$
(exemples : durée de vie, résistance à la rupture, etc.).

(b) *Bloqué à droite* : $] -\infty, b]$: $\alpha_1 = 0$ et $\alpha_2 = b$

Intervalle utilisé dans le cas où $\theta < b$
(exemples : nombre de pièces défectueuses, temps d'attente, etc.).

Intervalle unilatéral

Bloqué à gauche :

Bloqué à droite :

Construction d'un I.D.C.

Soit $\theta \in \Theta$ le paramètre inconnu.

1. On considère une fonction monotone $u(x, \theta)$ qui dépend d'une statistique.
2. On définit α , $\alpha \in [0, 1]$

On pose :

$$P_{\theta} [u_1 < u(x, \theta) < u_2] = 1 - \alpha ;$$

3. On peut écrire :

$$P_{\theta} [\beta_1(u_1) \leq \theta \leq \beta_2(u_2)] = 1 - \alpha ;$$

4. L'I.D.C. pour θ est : $I_{\alpha} = [\beta_1(x); \beta_2(x)]$

On utilise les fonctions dites *pivotal*es

Supposons que $(X_1, \dots, X_n) \sim \mathcal{N}(\mu, \sigma^2)$.

1. **I.D.C** pour $\theta = \mu = E(X)$. On utilise la loi de \bar{X}

(a) **Si la variance σ^2 est connue.**

$$\sqrt{n} \frac{\bar{X} - \theta}{\sigma} \sim \mathcal{N}(0, 1)$$

(b) **Si la variance σ^2 est inconnue.**

On utilise l'estimateur de σ^2 ,

$$s^2 = \frac{1}{n-1} \sum_{j=1}^n (X_j - \bar{X})^2 \text{ ou } s_1^2 = \frac{1}{n} \sum_{j=1}^n (X_j - \bar{X})^2 .$$

$$\sqrt{n} \frac{\bar{X} - \theta}{s} \sim t(\nu), \quad \nu = n - 1 \text{ d.d.l.}$$

(loi de Student ou t-distribution)

2. I.D.C pour $\sigma^2 = V(X)$, On pose $\theta = \sigma^2$.

(a) Si la moyenne $\mu = E(X)$ est connue.

On sait que $\frac{X-\mu}{\sigma} \sim N(0, 1)$; $\left(\frac{X-\mu}{\sigma}\right)^2 \sim \chi^2(\nu)$ $\nu = 1$ d.d.l.

et donc : $\frac{1}{\theta} \sum_{j=1}^n (X_j - \mu)^2 \sim \chi^2(\nu)$, $\nu = n$ d.d.l.

(b) Si la moyenne est inconnue on utilise la loi de S^2

$\frac{1}{\theta}(n-1) \cdot s^2 = \frac{(n-1)S^2}{\sigma^2} \sim \chi^2(\nu)$, $\nu = n-1$ d.d.l.

Avec $s^2 = \frac{1}{n-1} \sum_{j=1}^n (X_j - \bar{X})^2$

Pour le cas où $X \sim \mathcal{L}$, \mathcal{L} loi quelconque et un **grand** échantillon on utilise le **T.C.L.**

1. Supposons que $X \sim \mathcal{B}(n, p)$. On pose $\theta = p$.

$$t(X; \theta) = \lim_{n \rightarrow \infty} \frac{X - n\theta}{\sqrt{n\theta(1-\theta)}} \sim \mathcal{N}(0, 1)$$

2. Si $X \sim \mathcal{P}(\lambda)$. On pose $\theta = \lambda$.

$$\lim_{n \rightarrow \infty} \sqrt{n} \frac{\bar{X} - \theta}{\sqrt{\theta}} \sim \mathcal{N}(0, 1)$$

Intervalles de Confiance pour la Moyenne $\mu = E(X)$

Il y a deux cas :

1. Loi normale $\mathcal{N}(\mu, \sigma^2)$ avec variance connue

(a) On construit la fonction $Z_n(\mu) = \frac{\bar{X} - \mu}{\sigma} \sqrt{n} \sim N(0, 1)$

(b) On cherche a, b tels que : $P_\mu \left[a \leq \frac{\bar{X} - \mu}{\sigma} \sqrt{n} \leq b \right] = 1 - \alpha$

(c) Pour un I.D.C. symétrique, on prend $\alpha_1 = \alpha_2 = \frac{\alpha}{2}$

(d) L'intervalle pour μ sera : $I_\alpha = \left[\bar{X} - \frac{\sigma}{\sqrt{n}} z_{\frac{\alpha}{2}} ; \bar{X} + \frac{\sigma}{\sqrt{n}} z_{\frac{\alpha}{2}} \right]$

(e) La longueur de l'intervalle est : $2 z_{\alpha/2} \frac{\sigma}{\sqrt{n}} = 2c$

(f) Á partir de cette formule on peut calculer la taille minimale de l'échantillon nécessaire pour obtenir une longueur $2c$

L'intervalle symétrique, pour un α fixé, est l'intervalle optimal, c.a.d. le plus précis.

2. Loi normale $\mathcal{N}(\mu, \sigma^2)$ avec variance inconnue

(a) On utilise l'estimateur $s^2 = \frac{1}{n-1} \sum_{j=1}^n (X_j - \bar{X})^2$.

(b) La v.a. $T_n(\mu) = \sqrt{n} \frac{\bar{X} - \mu}{s} \sim t(\nu)$, avec $\nu = n - 1$ suit une *Loi de Student* ou *t-distribution*.

(c) On cherche a, b t.q : $P_\mu \left[a \leq \sqrt{n} \frac{\bar{X} - \mu}{s} \leq b \right] = 1 - \alpha$

(d) Pour un intervalle symétrique on a :

$$I_\alpha = \left[\bar{X} - t_{n-1; \frac{\alpha}{2}} \frac{s}{\sqrt{n}} ; \bar{X} + t_{n-1; \frac{\alpha}{2}} \frac{s}{\sqrt{n}} \right]$$

- Rq** :1. La longueur de l'intervalle est minimale si l'intervalle est symétrique.
2. Si on veut que l'intervalle ait une longueur égale à $2c$, alors il faut prendre

$$n = \left[\frac{t_{n-1; \alpha/2} \cdot s}{c} \right]^2$$

Intervalle De Confiance pour les Variances

Il y a deux cas :

1. Loi normale $\mathcal{N}(\mu, \sigma^2)$ avec moyenne connue
Intervalle pour $\theta = \sigma^2$

(a) On pose $\theta = \sigma^2$

(b) $U(\sigma^2) = \frac{ns_{\mu}^2}{\sigma^2} \sim \chi^2(\nu); \quad \nu = n \quad d.d.l.$

avec $s_{\mu}^2 = \frac{1}{n} \sum_{j=1}^n (X_j - \mu)^2$.

(c) On cherche a, b t.q :

$$P_{\sigma^2} \left[a \leq \frac{ns_{\mu}^2}{\sigma^2} \leq b \right] = 1 - \alpha$$

(d) $I_{\alpha} = \left[\frac{ns_{\mu}^2}{b}, \frac{ns_{\mu}^2}{a} \right]$

(e) La longueur de l'intervalle est : $\left(\frac{1}{a} - \frac{1}{b} \right) ns_{\mu}^2$

(f) Dans le cas d'un intervalle symétrique :

$$a = \chi_{n;1-\alpha/2}^2 \quad ; \quad b = \chi_{n;\alpha/2}^2$$

2. Loi normale $\mathcal{N}(\mu, \sigma^2)$ avec moyenne inconnue Intervalle pour $\theta = \sigma^2$

(a) On utilise pour μ son estimateur $\bar{X} = \frac{1}{n} \sum_{i=1}^n x_i$.

(b) On utilise la fonction $S^2 = \frac{1}{n-1} \sum_{j=1}^n (X_j - \bar{X})^2$.

(c) On a vu que : $\frac{(n-1)S^2}{\sigma^2} \sim \chi_{n-1}^2$.

(d) On cherche a, b t.q.

$$P_{\sigma^2} \left[a \leq \frac{ns^2}{\sigma^2} \leq b \right] = 1 - \alpha$$

(e) $I_\alpha = \left[\frac{ns^2}{b}, \frac{ns^2}{a} \right]$

(f) Longueur de l'intervalle est : $\left(\frac{1}{a} - \frac{1}{b} \right) (n - 1) s_X^2$

(g) Pour un intervalle symétrique :

$$a = \chi_{n-1; 1-\alpha/2}^2 \quad ; \quad b = \chi_{n-1; \alpha/2}^2$$

I.D.C pour $\theta = p$

Pour $n=40$ essais on a calculé $f_n = \frac{24}{40} = 0.6$

Étapes

1. $u(x; \theta) = \frac{f_n - p}{\sqrt{\frac{p(1-p)}{n}}} \sim N(0, 1)$

2. Soit $\alpha = 0.05$

3. $P \left[t_1 \leq \frac{f_n - p}{\sqrt{\frac{p(1-p)}{n}}} \leq t_2 \right] = 1 - \alpha$

4. $I_\alpha = \left[f_n - t_1 \sqrt{\frac{p(1-p)}{n}} ; f_n + t_2 \sqrt{\frac{p(1-p)}{n}} \right]$

Problème : $\theta = p$ se trouve dans les bornes !!

5. Calcul de l'I.D.C.

(a) Méth.-1 : **Par excès** :

i. On maximise $f(p) = p(1 - p)$

ii. $f'(p) = 1 - 2p$ et $f'(p) = 0 \Rightarrow p = \frac{1}{2}$

iii. $I_\alpha = \left[f_n - t_{\frac{\alpha}{2}} \sqrt{\frac{\frac{1}{2}(1-\frac{1}{2})}{n}} ; f_n + t_{\frac{\alpha}{2}} \sqrt{\frac{\frac{1}{2}(1-\frac{1}{2})}{n}} \right]$

iv. **A.N** : $I_\alpha = [0.445 ; 0.7549]$

(b) Méth.-2 : On utilise f_n qui est l'estimateur de p

i. On pose , $\hat{p} = f_n$

ii. $I_\alpha = \left[f_n - t_1 \sqrt{\frac{\hat{p}(1-\hat{p})}{n}} \quad ; \quad f_n + t_2 \sqrt{\frac{\hat{p}(1-\hat{p})}{n}} \right]$

iii. **A.N** : $I_\alpha = [0.448 ; 0.752]$

(c) Méth.-3 :

On utilise les *Abaques* ou méthode des ellipses, pour un I.D.C. symétrique.

i. On a :
$$P \left[t_1 \leq \frac{f_n - p}{\sqrt{\frac{p(1-p)}{n}}} \leq t_2 \right] = 1 - \alpha$$

ii. La résolution en p se fait de façon direct :

$$\left(\frac{f_n - p}{\sqrt{\frac{p(1-p)}{n}}} \right)^2 \leq t^2 \Leftrightarrow p^2 \left(1 + \frac{t^2}{n} \right) - 2p \left(f_n + \frac{t^2}{2n} \right) + f_n^2 \leq 0 \quad (I)$$

iii. On vérifie qu'il existe deux racines $p_i, i = 1, 2$ avec $0 \leq p_i \leq 1$ et l'inégalité (I) est vraie pour $p_1 \leq p \leq p_2$

iv. $I_\alpha = [p_1, p_2]$

R.q :

- La méthode par excès donne l'intervalle le moins précis
- L'intervalle le plus précis est donné par les *Abaques*.