

ECN 7060, cours 12

William McCausland

2021-12-07

Introduction, estimation par intervalle

- ▶ Estimateur par intervalle $[L(X), U(X)]$, estimation par intervalle $[L(x), U(x)]$.
- ▶ Les propriétés fréquentistes concernent la probabilité de couverture


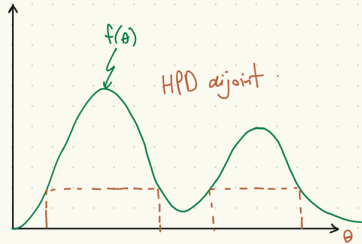
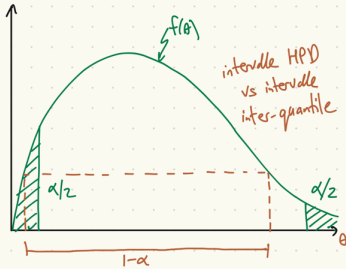
$$P_{\theta}[L(X) \leq \theta \leq U(X)].$$

- ▶ souvent une fonction de θ , pas toujours (idéalement non)
 - ▶ restrictions sur le modèle pour obtenir cette non-dépendance
 - ▶ coefficient de confiance $\inf_{\theta} P_{\theta}(L(X) \leq \theta \leq U(X))$.
 - ▶ arbitrage : haute probabilité de couverture v. intervalle court
- ▶ Les propriétés bayésiennes concernent la probabilité

$$P[L(x) \leq \theta \leq U(x)|x] \quad \text{ou} \quad P[l \leq \theta \leq u|x]$$

- ▶ Stratégie symétrique : $L(x)$ et $U(x)$ sont les quantiles $\alpha/2$ et $1 - \alpha/2$ de θ , $U(x) - L(x)$ n'est pas forcément minimale
- ▶ Intervalle de haute probabilité *a posteriori* : $U(x) - L(x)$ minimale sous la contrainte $P[L(x) \leq \theta \leq U(x)|x] = 1 - \alpha$.

Régions de haute probabilité et intervalles interquartile



Estimation par ensemble

- ▶ Estimateur par ensemble $C(X)$, où $C(X) \subseteq \Theta$.
- ▶ Estimation par ensemble $C(x)$.
- ▶ Probabilité d'intérêt fréquentiste : $P_\theta(\theta \in C(X))$.
 - ▶ θ est fixe
 - ▶ la région $C(X)$ est aléatoire
 - ▶ analyse *ex ante*
- ▶ Probabilité d'intérêt bayésienne : $P(\theta \in C(x)|x)$.
 - ▶ x est fixe (l'échantillon observé)
 - ▶ l'élément θ est aléatoire (la probabilité est conditionnelle)
 - ▶ analyse *ex post*

Inversion d'une statistique test

- ▶ Pour chaque θ_0 , soit $A(\theta_0)$ la région de non-rejet pour un test de niveau α de l'hypothèse nulle $H_0 : \theta = \theta_0$.
- ▶ Alors $A(\theta)$ vérifie $P_\theta[X \notin A(\theta)] \leq \alpha$ et l'inégalité est sharp.
- ▶ Définiez, pour chaque $x \in \mathcal{X}$, $C(x) = \{\theta : x \in A(\theta)\}$.
- ▶ Notez que $x \in A(\theta) \Leftrightarrow \theta \in C(x)$.
- ▶ Résultat : $C(X)$ est une région de confiance avec coefficient de confiance $(1 - \alpha)$.
- ▶ Preuve :
 - ▶ Puisque le niveau du test est de α ,

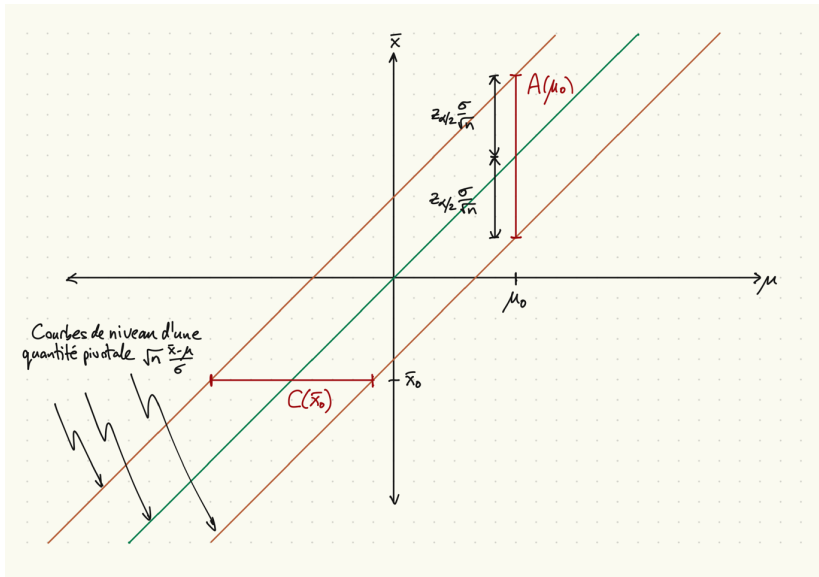
$$P_\theta[X \notin A(\theta)] \leq \alpha.$$

- ▶ Alors

$$P_\theta[\theta \in C(X)] = P_\theta[X \in A(\theta)] \geq (1 - \alpha).$$

- ▶ La première inégalité est sharp donc la deuxième l'est aussi.

$C(\bar{x})$ et $A(\theta)$ pour un exemple gaussien



Exemple gaussien, σ^2 connu

- ▶ Supposons que $X_1, \dots, X_n \sim \text{iid } N(\mu, \sigma^2)$, σ^2 connu.
- ▶ Encore, $\bar{X} \equiv n^{-1} \sum_{i=1}^n X_i$, $S^2 \equiv (n-1)^{-1} \sum_{i=1}^n (X_i - \bar{X})^2$.
- ▶ Statistique LRT pour $H_0: \mu = \mu_0$ contre $H_1: \mu \neq \mu_0$:

$$\lambda(x) = \frac{\exp\left[-\frac{1}{2\sigma^2} \sum_{i=1}^n (x_i - \mu_0)^2\right]}{\exp\left[-\frac{1}{2\sigma^2} \sum_{i=1}^n (x_i - \bar{x})^2\right]}$$

- ▶ Puisque $\sum_{i=1}^n (x_i - \mu_0)^2 = \sum_{i=1}^n (x_i - \bar{x})^2 + n(\bar{x} - \mu_0)^2$,

$$\lambda(x) = \exp[-n(\bar{x} - \mu_0)^2 / (2\sigma^2)].$$

- ▶ La loi de \bar{X} est connue : $\bar{X} \sim N(\mu, \sigma^2/n)$
- ▶ Pour le test avec $A(\mu_0) = \{x: |\bar{x} - \mu_0| \leq z_{\alpha/2}\sigma/\sqrt{n}\}$, la probabilité de rejet quand $\mu = \mu_0$ est de α .
- ▶ Conditions équivalentes à $x \in A(\mu_0)$:

$$\begin{aligned} |\bar{x} - \mu_0| \leq z_{\alpha/2}\sigma/\sqrt{n} &\Leftrightarrow -z_{\alpha/2}\sigma/\sqrt{n} \leq \mu_0 - \bar{x} \leq z_{\alpha/2}\sigma/\sqrt{n} \\ &\Leftrightarrow \bar{x} - z_{\alpha/2}\sigma/\sqrt{n} \leq \mu_0 \leq \bar{x} + z_{\alpha/2}\sigma/\sqrt{n} \end{aligned}$$

- ▶ Alors $P[\bar{X} - z_{\alpha/2}\sigma/\sqrt{n} \leq \mu_0 \leq \bar{X} + z_{\alpha/2}\sigma/\sqrt{n}] = 1 - \alpha$.

Quantités pivotales

- ▶ Une fonction $Q(X, \theta)$ est pivotale si sa loi ne dépend pas de θ .
- ▶ Interprétation bayésienne : sa loi ne dépend pas de $f(\theta)$
- ▶ Famille $f(x|\mu) = f_0(x - \mu)$: $Q(X, \theta) = \bar{X} - \mu$ est pivotale.
- ▶ Preuve :
 - ▶ Soit $Z_i \sim f_0(z)$. Sa distribution ne dépend pas de μ .
 - ▶ Si $X_i \sim f(x|\mu) = f_0(x - \mu)$,

$$(X_1, \dots, X_n) \sim (Z_1 + \mu, \dots, Z_n + \mu)$$

$$\bar{X} - \mu \sim \frac{1}{n} \sum_{i=1}^n (Z_i + \mu) - \mu = \bar{Z}$$

- ▶ La loi de \bar{Z} (et de $Q(X, \theta) = \bar{X} - \mu$) ne dépend pas de μ .
- ▶ Famille $f(x|\sigma) = \frac{1}{\sigma} f_0(x/\sigma)$: $Q(X, \sigma^2) = \bar{X}/\sigma$ est pivotale.
- ▶ Famille $f(x|\mu, \sigma^2) = \frac{1}{\sigma} f_0((x - \mu)/\sigma)$: $Q_1(X, \theta) = (\bar{X} - \mu)/\sigma$, $Q_2(X, \theta) = (\bar{X} - \mu)/S$, $Q_3(X, \theta) = S/\sigma$ sont pivotales.

Utiliser une quantité pivotale pour construire un ensemble de confiance

- ▶ Supposez que $Q(X, \theta)$ est une quantité pivotale, \mathcal{A} est un ensemble.
- ▶ $C(X) = \{\theta: Q(X, \theta) \in \mathcal{A}\}$ est un estimateur par ensemble de θ dont la probabilité $P_\theta(C(X))$ ne dépend pas de θ .
- ▶ Stratégie : trouver une quantité pivotale $Q(X, \theta)$ et un ensemble \mathcal{A} avec de bonnes propriétés ($C(X)$ petit, $P_\theta(C(X))$ grand).

Exemples gaussiens I

- ▶ Supposons que $X_1, \dots, X_n \sim \text{iid } N(\mu, \sigma^2)$.
- ▶ Quantités pivotales :
 - ▶ $Z = \sqrt{n}(\bar{X} - \mu)/\sigma \sim N(0, 1)$,
 - ▶ $T_{n-1} = \sqrt{n}(\bar{X} - \mu)/S \sim t(n-1)$.
 - ▶ $(n-1)S^2/\sigma^2 \sim \chi_{n-1}^2$.
- ▶ Cas où σ^2 est connu :

$$1 - \alpha = P_{\theta}(-z_{\alpha/2} \leq -Z \leq z_{\alpha/2}) = P_{\theta}(\mu \in C(X)).$$

où $C(X)$ est l'estimateur par ensemble suivant

$$C(X) = \{\mu : \bar{X} - z_{\alpha/2}\sigma/\sqrt{n} \leq \mu \leq \bar{X} + z_{\alpha/2}\sigma/\sqrt{n}\}.$$

Exemples gaussiens II

- ▶ Cas où σ^2 n'est pas connu, intervalle pour μ :

$$1 - \alpha = P_{\theta}(-t_{n-1, \alpha/2} \leq -T_{n-1} \leq t_{n-1, \alpha/2}) = P_{\theta}(C(X)),$$

où

$$C(X) = \{\mu : \bar{X} - t_{n-1, \alpha/2} S / \sqrt{n} \leq \mu \leq \bar{X} + t_{n-1, \alpha/2} S / \sqrt{n}\}.$$

- ▶ Cas où σ^2 n'est pas connu, intervalle pour σ^2 :

$$1 - \alpha = P_{\theta}(\chi_{n-1, 1-\alpha/2} \leq (n-1)S^2 / \sigma^2 \leq \chi_{n-1, \alpha/2}) = P_{\theta}(C(X)),$$

où

$$C(X) = \left\{ \sigma^2 : \frac{(n-1)S^2}{\chi_{n-1, \alpha/2}} \leq \sigma^2 \leq \frac{(n-1)S^2}{\chi_{n-1, 1-\alpha/2}} \right\}.$$

Un aparté

- ▶ Soit T une variable aléatoire avec fonction de répartition F inversible.
- ▶ $F(t)$ est une fonction, $F(T)$ est une variable aléatoire avec une loi sur $[0, 1]$.
- ▶ Proposition : $F(T) \sim U(0, 1)$.
- ▶ Preuve :
 - ▶ Soit G la fonction de répartition de $F(T)$.
 - ▶ Pour $u \in [0, 1]$,

$$G(u) = P[F(T) \leq u] = P[T \leq F^{-1}(u)] = F[F^{-1}(u)] = u.$$

- ▶ Alors $F(T) \sim U(0, 1)$.

Pivot de la fonction de répartition

- ▶ Soit T une statistique avec fonction de répartition $F_T(t|\theta)$.
- ▶ Si F_T est toujours inversible (c.-à-d. pour tous θ), $F_T(T|\theta) \sim U(0, 1)$, une loi qui ne dépend pas de θ .
- ▶ Supposons que T est stochastiquement croissante en θ .
- ▶ C'est à dire que $F_T(t, \theta)$ est décroissante en θ .
- ▶ Pour t donné, soit $\theta_L(t)$ et $\theta_U(t)$ les solutions de

$$F_T(t|\theta_U(t)) = \alpha_1 \quad F_T(\theta_L(t)) = 1 - \alpha_2.$$

- ▶ Pour tous t, θ ,

$$\theta > \theta_U(t) \Leftrightarrow F_T(t, \theta) < \alpha_1$$

$$\theta < \theta_L(t) \Leftrightarrow F_T(t, \theta) > 1 - \alpha_2$$

- ▶ Considérer l'intervalle de confiance $[\theta_L(T), \theta_U(T)]$:

$$\{t: \theta_L(t) \leq \theta \leq \theta_U(t)\} = \{t: \alpha_1 \leq F_T(t|\theta) \leq 1 - \alpha_2\},$$

$$P_\theta[\theta_L(T) \leq \theta \leq \theta_U(T)] = P_\theta[\alpha_1 \leq F_T(T|\theta) \leq 1 - \alpha_2] = 1 - \alpha_1 - \alpha_2.$$

Graphique, pivot de la fonction de répartition

