

Para estimar $F(x)$ usando la información de $X_1, X_2, \dots, X_n$ m.a. de X y F se construye la función de distribución acumulada empírica.

$$\hat{F}_n(x) = \frac{1}{n} \sum_{i=1}^n \mathbb{1}(X_i \leq x), \text{ para cada } x \in \mathbb{R}$$

en donde

$$\mathbb{1}(X_i \leq x) = \begin{cases} 1, & \text{si } X_i \leq x \\ 0, & \text{c.c.} \end{cases}$$

Teorema

Para cada $x \in \mathbb{R}$, se tiene que

$$1) \mathbb{E}(\hat{F}_n(x)) = F(x)$$

$$2) \text{Var}(\hat{F}_n(x)) = \frac{F(x)(1-F(x))}{n}$$

$$3) \mathbb{E}(M_{F(x)}(\hat{F}_n)) = \text{Var}(\hat{F}_n(x))$$

$$4) \hat{F}_n(x) \xrightarrow{P} F(x), \text{ en otros palabras } \hat{F}_n(x) \text{ es un}$$

estimador consistente por $F(x)$ en todo punto $x \in \mathbb{R}$.

Todo esto nos indica que $\hat{F}_n(x)$ es un buen estimador de $F(x)$, pero tener algo aún más ¡podemos!

Teorema (Glivenko-Cantelli)

Sea $X_1, X_2, \dots, X_n$ i.i.d. de $X \sim F(x)$. Para $\varepsilon > 0$

$$\Rightarrow \sup_{x \in \mathbb{R}} |\hat{F}_n(x) - F(x)| \xrightarrow{P} 0$$

$\Rightarrow \hat{F}_n(x)$ es un muy buen estimador de $F(x)$

Funciones estadísticas

¿Por qué es relevante estimar $F(x)$?

Si X es capaz de describir el número de intentos

$\Rightarrow$ una cantidad de interés $\mu = \mathbb{E}(X)$

$$\mu = \mathbb{E}(X) = \int_{-\infty}^{\infty} x f(x) dx = \int_{-\infty}^{\infty} x dF(x)$$

recordemos que $f(x) = \frac{d}{dx} F(x)$

$\Rightarrow$ Un buen μ y muchos otros parámetros de interés son funciones de $F(x)$!

Un funcional estadístico $T(F)$ es cualquier función de F

$$\mu = \mathbb{E}(X) = \int x dF(x)$$

$$\sigma^2 = \text{Var}(X) = \int (x - \mu)^2 dF(x)$$

la mediana

$$m = F^{-1}(1/2)$$

Definición (estimador plug-in)

El estimador plug-in de $\theta = T(F)$ se define como

$$\hat{\theta}_n = T(\hat{F}_n)$$

en otras palabras, en donde reemplazamos F en el funcional estadístico sustituyendo por $\hat{F}_n$

Existe un caso especial de funcionales estadísticos $T(F)$, los llamados funcionales estadísticos lineales. Cualquier funcional estadístico de la forma

$$T(F) = \int g(x) dF(x) = \int g(x) f(x) dx$$

es un funcional estadístico lineal.

¿Qué tienen de especial estas funciones estadísticas lineales?

Teorema (estimador plug-in)

Sea $X_1, X_2, \dots, X_n$ una m.c. de $X \sim F(x)$ y

$$\Theta = T(F) = \int g(x) dF(x)$$

una función estadística lineal

$\Rightarrow$ para obtener un estimador de Θ sólo necesitamos (plug-in) $\hat{F}_n(x)$ en donde reemplazamos $F(x)$, i.e.

$$\hat{\Theta}_n = T(\hat{F}_n) = \int g(x) d\hat{F}_n(x)$$

$$= \frac{1}{n} \sum_{i=1}^n g(X_i)$$

resul. de la teoría de la medida

¡Ej, un promedio!

Ejemplo

1) Media

$$\mu = E(X) = \int x dF(x)$$

$$\Rightarrow \hat{\mu}_n = \frac{1}{n} \sum_{i=1}^n X_i$$

2) Varianz

$$\begin{aligned} G^2 = \text{Var}(X) &= \int (x-\mu) dF(x) \\ &= E(X^2) - E(X)^2 \\ &= \int x^2 dF(x) - \mu^2 \end{aligned}$$

$$\begin{aligned} \Rightarrow G_n^2 &= \frac{1}{n} \sum_{i=1}^n X_i^2 - \hat{\mu}_n^2 \\ &= \frac{1}{n} \sum (X_i - \hat{\mu}_n)^2 \end{aligned}$$

Observe dass

$$\begin{aligned} \frac{1}{n} \sum (X_i - \bar{X}_n)^2 &= \frac{1}{n} \sum (X_i^2 - 2\bar{X}_n X_i + \bar{X}_n^2) \\ &= \frac{1}{n} \sum X_i^2 - \frac{2}{n} \bar{X}_n \sum X_i + \bar{X}_n^2 \\ &= \frac{1}{n} \sum X_i^2 - 2\bar{X}_n^2 + \bar{X}_n^2 \\ &= \frac{1}{n} \sum X_i^2 - \bar{X}_n^2 \end{aligned}$$

3) Asymmetrie $\kappa = \frac{E((X-\mu)^3)}{G^3} = \frac{\int (x-\mu)^3 dF(x)}{G^3}$

$$\Rightarrow \hat{\mu}_n = \frac{\frac{1}{n} \sum (x_i - \hat{\mu}_n)}{\left(\frac{1}{n} \sum (x_i - \hat{\mu}_n)^2 \right)^{1/2}}$$

4) Correlación

Sean $(X_1, Y_1), (X_2, Y_2), \dots, (X_n, Y_n)$ una m.c.
de $(X, Y) \sim F(x, y)$

$$\rho = \frac{\text{Cov}(X, Y)}{\sqrt{\text{Var}(X)} \sqrt{\text{Var}(Y)}} = \frac{\text{IE}((X - \text{IE}(X))(Y - \text{IE}(Y)))}{G_X G_Y}$$


$$\hat{\rho}_n = \frac{\frac{1}{n} \sum (x_i - \hat{\mu}_x)(y_i - \hat{\mu}_y)}{\hat{G}_{nx} \hat{G}_{ny}}$$

5) Cuantiles (no es un funcional estadístico lineal)

Sea $F(x)$ una función de distribución estrictamente creciente.
Para $0 < p < 1$ el cuantil p -ésimo se define como

$$T(F) = F^{-1}(p) \Rightarrow T(\hat{F}_n) = \hat{F}_n^{-1}(p)$$

en donde $\hat{F}_n^{-1}(p) = \inf \{ x : \hat{F}_n(x) \geq p \}$



Ya tenemos una forma de obtener estimadores puntuales

de muchos parámetros de una cierta población de interés
 $\sum n \hat{F}(x)$

$$\underline{\theta = T(F)}$$

Pero, ¿cómo obtengo estimadores por intervalo?

si $\mu = E(X)$ y sabemos que $\sigma^2 = \text{Var}(X) < \infty$

podemos utilizar directamente el TCL

Ok y si por alguna razón querés intervalos de confianza
por

$$G = \sqrt{\text{Var}(X)}$$

$$K = \frac{\mathbb{E}((X - \mu)^3)}{G^3}$$

Te damos $\hat{G}_n$ y $\hat{K}_n$ asumiendo
normalidad (no sabemos si eso es cierto)

$\Rightarrow$ aun es necesario

$$\begin{aligned} \text{se}(\hat{G}_n) &= \sqrt{\text{Var}(\hat{G}_n)} = \sqrt{\text{Var}\left(\sqrt{\frac{1}{n} \sum_{i=1}^n (X_i - \hat{\mu}_n)^2}\right)} \\ \text{se}(\hat{K}_n) &= \sqrt{\text{Var}(\hat{K}_n)} \end{aligned}$$

Estimar $\text{Var}(\hat{\theta}_n)$ cuando $\hat{\theta}_n$ es un estimador

NO trivial, es uno de los retos mas grandes en
estadística.

En este caso utilizar el Bootstrap