

Para el examen de no paramétrica, estudiar
→ Libro All of statistics capítulos 7 y 8.

3. Estadística NO paramétrica

→ Es importante que estudien y entiendan el proceso de la inferencia estadística, es uno de las preguntas del examen

1:- $FA \rightarrow$ datos $x_1, \dots, x_n$

2:- $\exists$ una v.c. X que pueda describir el comportamiento agregado de los datos que genera el FA.

en este caso $X \sim F(x)$
ya que estamos en el caso no paramétrico

3:- Método de recolección de datos $X_1, \dots, X_n$ una m.c. de $X \sim F(x)$

4:- En estadística No paramétrica siempre nos interesa alguna característica de X ,

$$\mu = E(X)$$

$$\sigma^2 = \text{Var}(X)$$

$$\gamma = \frac{E(X^3)}{\left(\sqrt{\text{Var}(X)}\right)^3}$$

... etc.

desarrollar es elegir por hacer estimación puntual
y por integrar de μ , σ^2 , γ , ..., etc.

para alcanzar este objetivo, primero necesitamos
estimar $f(x)$

¿por qué? ¡ $f(x)$ no nos interesa!

$$\mu = E(X) = \int x f(x) dx$$

$$\text{pero } \underline{\underline{f(x) = \frac{dF(x)}{dx}}}$$

notación más
general

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

$$\underline{\underline{\mu = T_1(F)}}$$

$$\sigma^2 = T_2(F) = E(X^2) - E(X)^2$$

$$= \int x^2 dF(x) - \mu^2$$

La idea que debe quedar clara es que si estimamos $F(x)$ eso nos permitirá estimar μ , σ^2 , γ , etc.

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

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

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

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

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

estimator consistente per $F(x)$ in tutti punti $x \in \mathbb{R}$.

Dem

$$1) \quad Y_i = \mathbb{I}(X_i \leq x), \text{ per } i=1, 2, \dots, n$$

$\Rightarrow Y_1, Y_2, \dots, Y_n$ s. m.c. di $\text{Bernoulli}(F(x))$

$$P(Y=1) = P(X \leq x) = F(x)$$

$$\Rightarrow \bar{Y}_n = \frac{1}{n} \sum Y_i = \hat{F}_n(x)$$

$$\Rightarrow E(\bar{Y}_n) = F(x) \quad \checkmark$$

$$2) \quad \text{Var}(\bar{Y}_n) = \frac{1}{n^2} \cdot n \cdot F(x)(1-F(x)) \\ = \frac{1}{n} F(x)(1-F(x))$$

$$3) \quad E(M_{F(x)}(\hat{F}_n(x))) = \text{Var}(\hat{F}_n(x)) + \cancel{\text{Scorretto}}_{F(x)}^0(\hat{F}_n^2) \\ = \frac{1}{n} F(x)(1-F(x))$$

$$4) \quad \hat{F}_n(x) \xrightarrow{P} F(x)$$

per cui si segue che

$$\lim_{n \rightarrow \infty} E(M_{F(x)}(\hat{F}_n(x))) = 0 \Rightarrow \hat{F}_n(x) \xrightarrow{P} F(x)$$

$$\hat{f}_n(x) \xrightarrow{L^2} f(x)$$

Sean $X_1, X_2, \dots, X_n$ una sucesión de v.c. y X de v.c.

$$\Rightarrow X_n \xrightarrow{L^2} X$$

$\Leftrightarrow$

$$\lim_{n \rightarrow \infty} \mathbb{E}((X_n - X)^2) = 0$$

Proposición

Sea $X_1, X_2, \dots, X_n$ una sucesión de v.c. y X de v.c.

$$\text{Si } X_n \xrightarrow{L^2} X \Rightarrow X_n \xrightarrow{P} X$$

Para demostrar esto primero se demuestra la desigualdad de Markov

Si X es una v.c. no negativa y $\epsilon > 0$

$$\Rightarrow P(X \geq \epsilon) \leq \frac{\mathbb{E}(X)}{\epsilon}$$

Dem

$$\mathbb{E}(X) = \int_0^{\infty} y f_X(y) dy =$$

$$= \int_0^\varepsilon y f(y) dy + \int_\varepsilon^\infty y f(y) dy$$

$$\geq \int_\varepsilon^\infty y f(y) dy \geq \varepsilon \int_\varepsilon^\infty f(y) dy$$

$$= \varepsilon P(\Phi \geq \varepsilon)$$

$$\Rightarrow P(\Phi \geq \varepsilon) \leq E(\Phi) / \varepsilon$$

Haciendo $\Phi = |X_n - X|$ se tiene el resultado

$$\Rightarrow \hat{F}_n(x) \xrightarrow{P} F(x)$$

Teorema (Glivenko-Cantelli)

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

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

$\Rightarrow$ se sabe que $\hat{F}_n(x)$ es un buen estimador puntual de $F(x)$ para cualquier $x \in \mathbb{R}$

Funciones estadísticas

¿ Por qué es relevante estimar $F(x)$?

Si $\underline{X}$ es capaz de describir el fenómeno de interés

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

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

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

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

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

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

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

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 sustituir por $\hat{F}_n$

Definición (Funcional estadístico lineal)

Si

$$T(F) = \int g(x) dF(x) \quad \text{para alguna función } \underline{g}$$

$\Rightarrow T$ es un funcional estadístico lineal