

CAPÍTULO 1:

- Un estadístico es una función de las observaciones muestrales, ej: $g(x_1, \dots, x_n) = \frac{1}{n} \sum_{i=1}^n x_i$.
- Parámetro poblacionales
media = $\mu = \frac{1}{N} \sum_{i=1}^N x_i$
varianza = $\sigma^2 = \frac{1}{N} \sum_{i=1}^N (x_i - \mu)^2$
proporción = $p = \frac{X}{N} = \frac{\text{éxitos}}{\text{pruebas}}$.

- Estadísticos
media $\bar{X} = \frac{1}{n} \sum x_i$
varianza $S^2 = \frac{1}{n-1} \sum (x_i - \bar{X})^2$
proporción $p_x = \frac{x}{n}$.

Lemma $E[\bar{X}] = \mu$, $\text{var}(\bar{X}) = \frac{\sigma^2}{n}$.

- La desviación típica de $\bar{X} = \sigma/\sqrt{n}$.

- Teorema $x_i \sim N(\mu, \sigma)$, $\bar{X} \rightarrow N(\mu, \sigma/\sqrt{n})$.

- $x_i \sim N(\mu, \sigma)$, $z_i = \frac{x_i - \mu}{\sigma} \sim N(0, 1)$
y $\sum z_i \sim \chi^2_n$.

- $x_i \sim N(\mu, \sigma)$, $T = \frac{\bar{X} - \mu}{S/\sqrt{n}} \sim t_{n-1}$.

- Teorema (Fisher) $x_i \sim N(\mu, \sigma)$ entonces:
 $\bar{X} \pm S^2$, $\frac{(n-1)S^2}{\sigma^2} \rightarrow \chi^2_{n-1}$, $\frac{\bar{X} - \mu}{S/\sqrt{n}} \rightarrow t_{n-1}$.

- Distribución de la proporción muestral:

$$x_i \sim \text{Ber}(p), X = \sum x_i \sim \text{Bin}(n, p), p = \frac{X}{n}.$$

Ya que $E[p] = \frac{np}{n} = p$, $\text{var}(p) = \frac{np(1-p)}{n^2} = \frac{p(1-p)}{n}$

$$\left[\begin{array}{l} E[X^2] = nE[x_i^2] + 2\binom{n}{2}E[x_i x_j] \\ = np + n(n-1)p^2 \\ E[X]^2 = (np)^2 \quad \dots \text{var}(X) = np - np^2 \\ = np(1-p). \end{array} \right]$$

\hookrightarrow Instead, $\text{var}(X) = \frac{1}{n^2} \text{var}(X_i) = \frac{n \cdot p(1-p)}{n^2} = \frac{p(1-p)}{n}$.

\hookrightarrow by CLT $p \rightarrow N(p, \sqrt{\frac{p(1-p)}{n}})$.

- Distribución de la diferencia de proporciones:

$$x_i \sim \text{Ber}(p_x), y_i \sim \text{Ber}(p_y) \Rightarrow \hat{p}_x - \hat{p}_y = \frac{X}{n_x} - \frac{Y}{n_y}$$
$$X = \sum x_i \quad Y = \sum y_i$$

\therefore CLT says $\hat{p}_x - \hat{p}_y \rightarrow N(p_x - p_y, \sqrt{\frac{p_x(1-p_x)}{n_x} + \frac{p_y(1-p_y)}{n_y}})$

! Página 48 (380) pdf tabla resumen.

CAPÍTULO 2 - Estimación puntual.

- Un estadístico muestral que quiere aproximar el valor de un parámetro se llama estimador. Este proceso se llama estimación. También se puede llevar a cabo una contrastación de hipótesis.

↳ $\theta(x_1, \dots, x_n)$: estimador

$\theta(x_1, \dots, x_n)$: estimación puntual

- Error cuadrático medio del estimador $\hat{\theta}$ es $E_{cm}(\hat{\theta}) = E[(\hat{\theta} - \theta)^2] = \text{var}(\hat{\theta}) + (E[\hat{\theta}] - \theta)^2$
 $= \text{var}(\hat{\theta}) + \underbrace{\text{sesgo}(\hat{\theta})^2}_{:= \text{bias}!}$

- $\hat{\theta}$ es insesgado/centrado si $\text{sesgo}(\hat{\theta}) = 0$.
ej: $s^2 = \frac{1}{n-1} \sum (x_i - \bar{x})^2$, $E[s^2] = \sigma^2$ ∴ centrado!

- $\hat{\theta}_0$ es insesgado y uniformemente de mínima varianza (UMVUE) si $\text{var}(\hat{\theta}_0) \leq \text{var}(\hat{\theta})$.

- Cota de Cramér-Rao-Fisher:

$$\text{var}(\hat{\theta}) \geq \frac{[1 + b'(\theta)]^2}{E\left[\frac{\partial \ln f(x_1, \dots, x_n; \theta)}{\partial \theta}\right]^2} \quad \text{bias} = \text{sesgo}(\theta)$$

$= I^{-1}(\theta)$

- Un estimador es eficiente si es insesgado y tiene mínima varianza (ie. $\Leftrightarrow \text{var}(\hat{\theta}) = \text{cota FR}$). La eficiencia es $= \frac{\text{cota FR}}{\text{var}(\hat{\theta})}$,
eficiencia relativa de $\hat{\theta}_1, \hat{\theta}_2$ es $\frac{\text{var}(\hat{\theta}_2)}{\text{var}(\hat{\theta}_1)}$,

- $\{\hat{\theta}_n\}$ son consistentes si $\hat{\theta}_n \xrightarrow{IP} \theta$
Son consistentes en media cuadrática si $\hat{\theta}_n \xrightarrow{L^2} \theta$.
(in $L^2 \rightarrow$ in prob).

- $T(x_1, \dots, x_n)$ es suficiente para el parámetro θ si $f_T(x_1, \dots, x_n | T=t)$ no depende de θ .

Tes suficiente si y solo si \exists una descomposición $f(x_1, \dots, x_n; \theta) = g(T(x_1, \dots, x_n); \theta) h(x_1, \dots, x_n)$.

- Eficiente \rightarrow suficiente.

CAPÍTULO 3 - Métodos de obtención de estimadores

• Método de los momentos :

① Supongamos que hay k parámetros $\theta_1, \dots, \theta_k$.

$$\text{let } \alpha_i = E[x^i] = \int x^i f(x; \theta_1, \dots, \theta_k) dx.$$

② Let $a_1 = \frac{1}{n} \sum x_i$, $a_2 = \frac{1}{n} \sum x_i^2$, ..., $a_k = \frac{1}{n} \sum x_i^k$.

③ Halla las solución a
$$\begin{cases} \alpha_1(\theta_1, \dots, \theta_k) = a_1 \\ \vdots \\ \alpha_k(\theta_1, \dots, \theta_k) = a_k \end{cases}$$

La solución $\hat{\theta}_1, \dots, \hat{\theta}_k$ son los estimadores.

↳ Propiedades

- Insensibilidad
- Consistencia
- Normalidad asintótica

} Aún así no es un muy método (mejor MLE).

• Método de la máxima verosimilitud :

Dejemos que $L(x; \theta) = f(x_1, \dots, x_n; \theta)$, lo que llamamos verosimilitud. Entonces,

$$\hat{\theta}(x_1, \dots, x_n) = \underset{\theta \in \mathcal{R}}{\text{argmax}} L(x_1, \dots, x_n; \theta).$$

↳ Estimador de máx. verosimilitud (EMV).

Propiedades :

- Consistentes
- Asintóticamente insesgados
- Si $\exists \hat{\theta}$ eficientes $\Rightarrow \hat{\theta}$ es EMV (\Leftarrow no es cierto).
- Eficiencia asintótica
- $\hat{\theta} \rightarrow N(\theta, \sqrt{\text{var}(\hat{\theta})})$

$$\text{donde } \text{var}(\hat{\theta}) = \frac{1}{n E[I(\theta)^2]} = \text{wta de FER.}$$

- Suficiente

CAPÍTULO 4

- Un intervalo de confianza $[\underline{\theta}(x_1, \dots, x_n), \bar{\theta}(x_1, \dots, x_n)]$ es un intervalo aleatorio. Confianza del $100(1-\alpha)\%$.
 si $P[\underline{\theta}(x_1, \dots, x_n) \leq \theta \leq \bar{\theta}(x_1, \dots, x_n)] = 1-\alpha$.
 \hookrightarrow Intervalos bilaterales

Métodos:

① método pivotal: escoger $T(x_1, \dots, x_n; \theta)$ que dependa de θ ,

ej: $x_i \sim N(\mu, \sigma) \Rightarrow \bar{X} = \frac{1}{n} \sum x_i \sim N(\mu, \frac{\sigma}{\sqrt{n}})$

$\Rightarrow \frac{\bar{X} - \mu}{\sigma/\sqrt{n}} \sim N(0,1)$.

$\text{var} = \frac{1}{n^2} (\sigma^2 + \dots + \sigma^2)$
 $= \frac{\sigma^2}{n}$
 so $\text{std} = \sigma/\sqrt{n}$.

② Método de Neyman?

$N(\mu, \sigma^2)$, σ conocido $\Rightarrow \frac{\bar{X} - \mu}{\sigma/\sqrt{n}} \rightarrow N(0,1)$

$N(\mu, \sigma^2)$, σ desconocido $\Rightarrow \frac{\bar{X} - \mu}{S/\sqrt{n}} \rightarrow t_{n-1}$

$N(\mu, \sigma^2)$, μ desconocida $\Rightarrow \frac{(n-1)S^2}{\sigma^2} \rightarrow \chi^2_{n-1}$.

μ conocida $\Rightarrow \sum \frac{(x_i - \mu)^2}{\sigma^2} \rightarrow \chi^2_n$.

... similar para $x_i \sim N(\mu_x, \sigma_x^2)$, $y_i \sim N(\mu_y, \sigma_y^2)$.

Casos no normales:

* Desigualdad de Chebychev: si $E[x_i] = \mu$, $\text{var}(x_i) = \sigma^2$ entonces

$P(|\bar{X} - \mu| \geq k \frac{\sigma}{\sqrt{n}}) \leq \frac{1}{k^2}$

$\Rightarrow P(|\bar{X} - \mu| \leq k \frac{\sigma}{\sqrt{n}}) \geq 1 - \frac{\sigma^2}{nk^2}$...

* muestras grandes (utilizar CLT):

① $\hat{\theta} \rightarrow N(\theta, \sqrt{\text{var}(\hat{\theta})})$, $\text{var}(\hat{\theta}) = \frac{1}{n E[I'(\theta)^2]}$

$\therefore \frac{\hat{\theta} - \theta}{\sqrt{\text{var}(\hat{\theta})}} \rightarrow N(0,1)$... $I(\theta) = \ln f(x; \theta)$

② CLT: sabemos que en general

$\frac{\bar{X} - \mu}{\sigma/\sqrt{n}} \rightarrow N(0,1)$.

• Proposición (para muestras pequeñas):

EMV: $\hat{p} = \frac{X}{n}$, $P(\hat{p} = x) = P(X = nx) = \binom{n}{nx} p^{nx} (1-p)^{n-nx}$
 For $x = 0, \frac{1}{n}, \dots, 1$.

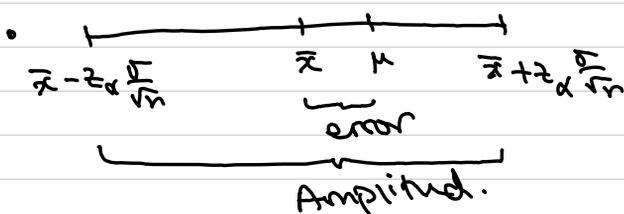
Así que para encontrar C.I

has de hacer manualmente $P(\hat{p} \leq p_0)$...

hasta llegar a $P(\hat{p} \leq p_0) \leq \alpha/2$, $P(\hat{p} \geq p_1) \leq \alpha/2$

$\therefore \text{CI} = [p_0, p_1]$.

(Para muestras grandes usa ①).



CAPÍTULO 5

- Hipótesis paramétricas \mathcal{X} : si $\theta \dots$.
 - ↳ Simple \mathcal{X} : $\theta = \theta_0$.
 - Compuesta \mathcal{X} : $\theta \neq \theta_0$ o $\theta > \theta_0$ o \dots
- Hipótesis nula \mathcal{X}_0 se acepta provisionalmente.
 - $\mathcal{X}_0: \theta \in \mathcal{R}_0 \subseteq \mathcal{R}$. Hipótesis alternativa,
 - $\mathcal{X}_1: \theta \in \mathcal{R}_1 \subseteq \mathcal{R}$ tal que $\mathcal{R}_0 \cap \mathcal{R}_1 = \emptyset$
 $\mathcal{R}_0 \cup \mathcal{R}_1 = \mathcal{R}$.
 - \mathcal{X}_0 es cierta si $\theta \in \mathcal{R}_0$, falsa cuando $\theta \in \mathcal{R}_1 = \mathcal{R}_1^c$.
- El conjunto de observaciones muestrales tal que rechazamos \mathcal{X}_0 es la región crítica C . El complemento es la región de aceptación \bar{C} .
 $\therefore \mathcal{R}^n = C \cup \bar{C}$.

Errores	\mathcal{X}_0 cierta	\mathcal{X}_0 falsa
Aceptamos \mathcal{X}_0	✓	Error tipo II β
Rechazamos \mathcal{X}_0	Error tipo I α	✓

- Talla o tamaño para el error de tipo I es
 $\alpha = \max_{\theta \in \mathcal{R}_0} P(\text{rechazo } \mathcal{X}_0 \mid \mathcal{X}_0 \text{ es cierta})$
- Talla o tamaño para el error de tipo II
 $\beta = \max_{\theta \in \mathcal{R}_1} P(\text{Acept } \mathcal{X}_0 \mid \mathcal{X}_0 \text{ es falsa})$.
- Un test es ideal si $\alpha = \beta = 0$.
- Nótese que el nivel de confianza es precisamente $1 - \alpha$ (aunque aquí ignoramos β).
- La potencia de un test es $= P(\text{Rechazar } \mathcal{X}_0 \mid \theta)$
 - si $\theta \in \mathcal{R}_0$, potencia = $\alpha(\theta)$
 - si $\theta \in \mathcal{R}_1$, potencia = $1 - \beta(\theta)$.
- \therefore Queremos un test con una potencia grande en \mathcal{R}_1 y pequeña en \mathcal{R}_0 .

Fases para realizar un contraste o test de hipótesis:

- 1) Formular $\mathcal{X}_0, \mathcal{X}_1$,
- 2) Determinar un test estadístico
- 3) Seleccionar α
- 4) Determinar la región crítica
- 5) Seleccionar aleatoriamente la muestra T y determinar el resultado.

CAPITULO 6

ej: $X_i \sim N(\mu, \sigma^2)$, σ conocida, then

$$\frac{\bar{X} - \mu}{\sigma/\sqrt{n}} \sim N(0,1) \text{ por lo tanto si}$$

$$H_0: \mu = \mu_0 \Rightarrow \frac{\bar{X} - \mu_0}{\sigma/\sqrt{n}} \sim N(0,1) \text{ on } H_0$$

$$H_1: \mu \neq \mu_0$$

$$\therefore -z_{\alpha/2} < \frac{\bar{X} - \mu_0}{\sigma/\sqrt{n}} < z_{\alpha/2}$$

región de aceptación

$$\text{Si } H_0: \mu > \mu_0$$

$$H_1: \mu \leq \mu_0$$

Aceptación si

$$-z_{\alpha/2} < \frac{\bar{X} - \mu_0}{\sigma/\sqrt{n}}$$

• Relación entre I.C y contraste de hipótesis:

Si nuestro I.C al nivel $100(1-\alpha)\%$ es $[\underline{\theta}, \bar{\theta}]$

quiere decir que $P(\underline{\theta} \leq \theta \leq \bar{\theta}) = 1 - \alpha$.

Si contrastamos la hipótesis $H_0: \theta = \theta_0$
 $H_1: \theta \neq \theta_0$

entonces rechazamos H_0 si $\theta \notin [\underline{\theta}, \bar{\theta}]$.

• $N(\mu, \sigma^2)$, σ desconocido ... $t = \frac{\bar{X} - \mu_0}{s/\sqrt{n}} \rightarrow t_{n-1} \quad n < 30$
 $\rightarrow N(0,1) \quad n \geq 30$

$$\text{donde } S = \frac{1}{n-1} \sum (x_i - \bar{x})^2 \dots$$

Tipo de t-test

def: any test where the t-distribution is used.

• $N(\mu, \sigma^2)$ queremos contrastar

$$\text{sobre } \sigma, \chi^2 := \frac{1}{\sigma_0^2} \sum (x_i - \mu)^2 \sim \chi_n^2 \dots$$

$$\text{Si } \mu \text{ es desconocido } \chi^2 = \frac{1}{\sigma_0^2} \sum (x_i - \bar{x})^2 \sim \chi_{n-1}^2$$

∴ lo mismo para el resto — memorizar tabla?

• El p-valor es el menor nivel de significación observado para que la hipótesis nula sea rechazada.

$$\text{i.e. } P(Z > z) \text{ or } P(T > t) \text{ for a test test...}$$

CAPÍTULO 7

• Test no paramétricos — nuevos potentes.

• Contraste de bondad de ajuste:

* contraste χ^2 de Pearson de bondad de ajuste

X variable aleatoria, distribución $F_0(x)$, S_1, \dots, S_k partición de subconjuntos de X ,
 $p_i = P(X \in S_i)$, $\sum p_i = 1$.

\mathcal{H}_0 : Muestra procede de $F_0(x)$

\mathcal{H}_1 : " no " "

let $O_i = \# \text{observaciones en } X \in S_i = n_i$
 $\therefore n_1 + \dots + n_k = n$.

$$\therefore P(n_1, \dots, n_k) = \frac{n!}{n_1! \dots n_k!} p_1^{n_1} \dots p_k^{n_k}$$

y $N_i \sim B(n, p_i)$

Si es correcta esperamos que $n_i \approx E[N_i] = np_i$

$$\therefore \chi^2 = \sum_{i=1}^k \frac{(O_i - E_i)^2}{E_i} = \sum_{i=1}^k \frac{(n_i - np_i)^2}{np_i} \sim \chi_{k-1}^2$$

$\hookrightarrow \chi^2 = \text{estadística de bondad de ajuste.}$

* Si $\mathcal{H}_0: F_0(x; \theta_1, \dots, \theta_k)$, $\mathcal{H}_1: F(x) \neq F_0$

y $\hat{\theta}_i$ so los EMV entonces

$$\chi^2 = \sum_{i=1}^k \frac{(n_i - np_i(\hat{\theta}_1, \dots, \hat{\theta}_k))^2}{np_i(\hat{\theta}_1, \dots, \hat{\theta}_k)} \rightarrow \chi_{k-h-1}^2$$

* Contraste de Kolmogorov-Smirnov:

let $F_n(x) = \frac{N(x)}{n}$, $N(x) = \# \text{observaciones } \leq x$.

let $D_n = \max_{x \in \mathbb{R}} |F_0(x) - F_n(x)|$

El test para $\mathcal{H}_0: F(x) = F_0(x)$ utiliza

$$P(D_n > D_\alpha | \mathcal{H}_0) = \alpha$$

\uparrow se obtiene en una tabla

* Contraste de normalidad de Lilliefors.

• Contrastes de aleatoriedad

\hookrightarrow Testeamos X_i son iid.

* Contraste de rachas de Wald-Wolfowitz.

\hookrightarrow eg. HTHTHT

\uparrow parece aleatorio

HTHTHTTTTT

\uparrow no parece.

Análisis: let $R = \# \text{ de rachas} = R_1 + R_2$

($R_1 = \# \text{ rachas H}$, $R_2 = \# \text{ rachas T}$). Si observamos n_1 Hs y n_2 Ts, $n = n_1 + n_2$. Entonces,

$$P(R=r) = \frac{2 \binom{n_1-1}{r_2-1} \binom{n_2-1}{r_1-1}}{\binom{n}{r_2-1} \binom{n}{r_1-1}} \leftarrow \text{Escoges donde empezar cada racha por H y T.}$$

Existen tablas por lo que $P(R \leq k_{\alpha/2}) \leq \alpha/2$ y pues $[0, k_{\alpha/2}]$, $[k_{\alpha/2}, n]$ es la región crítica.

$$\text{Para } R \rightarrow \infty, R \rightarrow N\left(\frac{2n_1 n_2}{n}, \sqrt{\frac{2n_1 n_2 (2n_1 n_2 - n)}{n^2 (n-1)}}\right)$$

* Si hay variaciones cíclicas no funciona.

• Contraste de localización:

* muestra de una distⁿ $F(x)$, $0 < p < 1$ y $c_p(F)$ es el cuantil de orden p de $F(x)$. Tipokis

$\mathcal{H}_0: c_p(F) = k_0$

$\mathcal{H}_1: c_p(F) \neq k_0 \rightarrow \text{ie. } P(X \leq k_0) = p$

$$\text{let } S = \# \{X_i > k_0\} \text{ so } P(S=s) = \binom{n}{s} p^s (1-p)^{n-s}$$

$$\therefore \text{Utilizar } P(S \leq k_{\alpha/2}) \approx \alpha/2 \dots$$

* Similar si conocemos la mediana en distribuciones simétricas (test de rangos-signos de Wilcoxon).

Población	Parámetros	Estadístico + dist.
$N(\mu, \sigma^2)$ σ conocido	μ	$z = \frac{\bar{x} - \mu}{\sigma/\sqrt{n}} \sim N(0,1)$
$N(\mu, \sigma^2)$ σ descon.	μ	$t = \frac{\bar{x} - \mu}{s/\sqrt{n}} \sim t_{n-1}$ donde $s^2 = \frac{1}{n-1} \sum (x_i - \bar{x})^2 \rightarrow \sigma^2$
$N(\mu, \sigma^2)$ μ conocido	σ^2	$\chi^2 = \frac{\sum (x_i - \mu)^2}{\sigma^2} \sim \chi^2_n$
$N(\mu, \sigma^2)$ μ descon.	σ^2	$\chi^2 = \frac{(n-1)s^2}{\sigma^2} = \frac{\sum (x_i - \bar{x})^2}{\sigma^2} \sim \chi^2_{n-1}$
$N(\mu_x, \sigma_x^2)$ $N(\mu_y, \sigma_y^2)$ σ_x, σ_y con.	$\mu_x - \mu_y$	$z = \frac{\bar{x} - \bar{y} - (\mu_x - \mu_y)}{\sqrt{\frac{\sigma_x^2}{n_x} + \frac{\sigma_y^2}{n_y}}} \sim N(0,1)$
$N(\mu_x, \sigma_x^2)$ $N(\mu_y, \sigma_y^2)$ σ_x, σ_y descon. $\sigma_x = \sigma_y$	$\mu_x - \mu_y$	$t = \frac{\bar{x} - \bar{y} - (\mu_x - \mu_y)}{s' \sqrt{\frac{1}{n_x} + \frac{1}{n_y}}} \sim t_{n_x + n_y - 2}$ $s'^2 = \frac{(n_x - 1)s_x^2 + (n_y - 1)s_y^2}{n_x - 1 + n_y - 1}$
} If $\sigma_x \neq \sigma_y$	$\mu_x - \mu_y$	$t = \frac{\bar{x} - \bar{y} - (\mu_x - \mu_y)}{\sqrt{s_x^2/n_x + s_y^2/n_y}} \sim t_v$ $v = \dots ?$
$N(\mu_x, \sigma_x^2)$ $N(\mu_y, \sigma_y^2)$ μ_x, μ_y con.	test $\sigma_x^2 = \sigma_y^2$	$F = \frac{n_x \sum (x_i - \mu_x)^2}{n_y \sum (y_i - \mu_y)^2} \sim F_{n_x, n_y}$
$B(1, p)$	test $p = p_0$	$\hat{p} = \frac{x}{n}, z = \frac{\hat{p} - p_0}{\sqrt{\frac{p_0(1-p_0)}{n}}} \sim N(0,1)$