

# estimación intervalar

Carlos Carleos, Norberto Corral, Teresa López

10 de diciembre de 2022

## Índice

<b>1. definición</b>	<b>2</b>
<b>2. advertencia</b>	<b>2</b>
<b>3. ejemplo</b>	<b>2</b>
<b>4. método pivotal</b>	<b>2</b>
4.1. ejemplo . . . . .	2
4.2. pivote genérico . . . . .	2
4.3. comparación de intervalos . . . . .	3
<b>5. EXTRA método de Neyman</b>	<b>5</b>
<b>6. método asintótico</b>	<b>5</b>
6.1. pivote para EMV . . . . .	5
6.2. TCL . . . . .	5
6.3. método delta . . . . .	6
<b>7. remuestreo autosuficiente o bústrap (<i>bootstrap</i>)</b>	<b>7</b>
7.1. definición . . . . .	7
7.2. hipótesis . . . . .	7
7.3. método gaussiano . . . . .	7
7.4. método percentil . . . . .	8
7.4.1. teorema . . . . .	8
7.4.2. <b>EXTRA</b> corrección de sesgo . . . . .	9
7.5. método básico . . . . .	9
7.6. método $t$ ó estudentizado . . . . .	10
7.7. método paramétrico . . . . .	10
7.8. ejemplo . . . . .	10
<b>8. determinar tamaño muestral</b>	<b>13</b>
8.1. $\sigma$ conocida . . . . .	13
8.1.1. caso gaussiano . . . . .	13
8.1.2. caso general . . . . .	13
8.2. $\sigma$ desconocida . . . . .	14
8.3. consecuencias . . . . .	14

## 1. definición

- $X \hookrightarrow F_\theta, \theta \in \Theta$
- $\vec{X} = X_1, \dots, X_n$  muestra aleatoria simple de  $X$
- $\alpha \in (0, 1)$ ,  $\alpha$  pequeño;  $1 - \alpha$  se llama **coeficiente de confianza**
- $T_1$  y  $T_2$  estadígrafos tales que  $\forall \theta \in \Theta, \Pr_\theta\{\vec{x} \in X(\Omega)^n \mid T_1(\vec{x}) \leq g(\theta) \leq T_2(\vec{x})\} \geq 1 - \alpha$
- $[T_1(\vec{X}), T_2(\vec{X})]$  es una **horquilla** o **intervalo de confianza** (IC) para  $g(\theta)$  a nivel  $1 - \alpha$

## 2. advertencia

- dada una realización muestral  $\vec{x}_0$ , en inferencia frecuentista (la muestra) no se puede afirmar que  $\Pr\{\theta \in [T_1(\vec{x}_0), T_2(\vec{x}_0)]\} \geq 1 - \alpha$
- se trata de intervalos de *confianza*, no de *probabilidad*

## 3. ejemplo

$$X \hookrightarrow N(\mu, 1) \implies \frac{\bar{X} - \mu}{1/\sqrt{n}} \hookrightarrow N(0, 1) \implies \text{IC} = \bar{X} \pm z_{1-\frac{\alpha}{2}} \frac{1}{\sqrt{n}} = \left[ \bar{X} - z_{1-\frac{\alpha}{2}} \frac{1}{\sqrt{n}}, \bar{X} + z_{1-\frac{\alpha}{2}} \frac{1}{\sqrt{n}} \right] \text{ con } \Pr[N(0, 1) \leq z_{1-\frac{\alpha}{2}}] = 1 - \frac{\alpha}{2}$$

## 4. método pivotal

- la función  $T(\vec{X}, \theta)$  es un **pivote** si su distribución de probabilidad no depende de  $\theta$  (está completamente especificada)
- algoritmo para construir IC mediante un pivote
  1. elegir  $\alpha_1 + \alpha_2 = \alpha$  (habitualmente,  $\alpha_1 = \alpha_2 = \frac{\alpha}{2}$ )
  2. buscar  $c_1$  y  $c_2$  tales que  $\Pr(T < c_1) \leq \alpha_1$  y  $\Pr(T \leq c_2) \geq 1 - \alpha_2$
  3. expresar  $c_1 \leq T(\vec{x}, \theta) \leq c_2$  como intervalo en torno a  $\theta$

### 4.1. ejemplo

$X \hookrightarrow N(\mu, \sigma) \implies$  pivotes:

- $\frac{\bar{X} - \mu}{\hat{S}/\sqrt{n}} \hookrightarrow t_{n-1} \implies \text{IC} = \bar{X} \pm t_{n-1, 1-\frac{\alpha}{2}} \frac{\hat{S}}{\sqrt{n}} = \left[ \bar{X} - t_{n-1, 1-\frac{\alpha}{2}} \frac{\hat{S}}{\sqrt{n}}, \bar{X} + t_{n-1, 1-\frac{\alpha}{2}} \frac{\hat{S}}{\sqrt{n}} \right] \text{ con } \Pr[t_{n-1} \leq t_{n-1, 1-\frac{\alpha}{2}}] = 1 - \frac{\alpha}{2}$
- $\frac{(n-1)\hat{S}^2}{\sigma^2} \hookrightarrow \chi_{n-1}^2 \implies \text{IC} = \left[ \frac{(n-1)\hat{S}^2}{\chi_{n-1, 1-\frac{\alpha}{2}}^2}, \frac{(n-1)\hat{S}^2}{\chi_{n-1, \frac{\alpha}{2}}^2} \right]$

### 4.2. pivote genérico

$X \hookrightarrow F_\theta$  absolutamente continua  $\implies$  puede usarse el pivote  $-\sum \ln F_\theta(X_i) \hookrightarrow \gamma(n, 1)$  pues

- $F_X(X) \hookrightarrow U(0, 1)$
- $-\ln U(0, 1) \hookrightarrow \text{Exp}(1)$
- $\sum_{i=1}^n \text{Exp}(\lambda)$  independientes  $\hookrightarrow \gamma(n, \lambda)$

### 4.3. comparación de intervalos

- motivo
  - pueden existir varios pivotes
  - con un mismo pivote, pueden escogerse  $\alpha_1$  y  $\alpha_2$  de varias maneras
- criterio
  - preferir el intervalo de amplitud (esperada) mínima
- ejemplo:  $X \hookrightarrow U(0, \theta)$ ; dos procedimientos
  - pivote genérico:
    - $F(x) = \frac{x}{\theta} \implies -\sum \ln \frac{X_i}{\theta} \hookrightarrow \gamma(n, 1)$
    - $a = -\sum \ln \frac{X_i}{\theta} = -\ln \prod \frac{X_i}{\theta} \implies e^{-a} = \frac{\prod X_i}{\theta^n} \implies \theta^n = \frac{\prod X_i}{e^{-a}} \implies \theta = \sqrt[n]{e^a \prod X_i}$
    - sean  $a$  y  $b$  tales que  $\Pr[a \leq \gamma(n, 1) \leq b] = 1 - \alpha$
    - $\Pr[a \leq \gamma(n, 1) \leq b] = \Pr\left[\sqrt[n]{e^a \prod X_i} \leq \theta \leq \sqrt[n]{e^b \prod X_i}\right] \implies \text{amplitud } L = \sqrt[n]{e^b \prod X_i} - \sqrt[n]{e^a \prod X_i} = \sqrt[n]{\prod X_i} \left(\sqrt[n]{e^b} - \sqrt[n]{e^a}\right)$
    - $E\left[\sqrt[n]{\prod X_i}\right] = E\left[\prod \sqrt[n]{X_i}\right] = \prod E\left[\sqrt[n]{X_i}\right] = E^n\left[\sqrt[n]{X}\right]$
    - $E\left(X^{\frac{1}{n}}\right) = \int_0^\theta x^{\frac{1}{n}} \frac{1}{\theta} dx = \left.\frac{1}{\theta} \frac{x^{\frac{1}{n}+1}}{\frac{1}{n}+1}\right|_{x=0}^{x=\theta} = \frac{n}{n+1} \theta^{\frac{1}{n}}$
    - $E(L) = \theta \left(\frac{n}{n+1}\right)^n \left(e^{\frac{b}{n}} - e^{\frac{a}{n}}\right)$
  - pivote basado en un estimador, como  $X_{(n)}$ 
    - $U = \frac{X_{(n)}}{\theta} \hookrightarrow F_{U(0,1)}(u)^n = u^n \forall u \in (0, 1)$
    - $1 - \alpha = \Pr\left[a \leq \frac{X_{(n)}}{\theta} \leq b\right] \implies a = \sqrt[n]{\alpha_1}, b = \sqrt[n]{1 - \alpha_2} \implies \Pr\left[\frac{X_{(n)}}{\sqrt[n]{1 - \alpha_2}} \leq \theta \leq \frac{X_{(n)}}{\sqrt[n]{\alpha_1}}\right]$
    - $E(L) = \frac{n}{n+1} \theta \left(\frac{1}{\sqrt[n]{\alpha_1}} - \frac{1}{\sqrt[n]{1 - \alpha_2}}\right)$
    - minimizar la amplitud esperada:  $L(\alpha_1) = \frac{n}{n+1} \theta \left(\frac{1}{\sqrt[n]{\alpha_1}} - \frac{1}{\sqrt[n]{1 - \alpha + \alpha_1}}\right)$
    - $\frac{\partial L}{\partial \alpha_1} = \frac{n}{n+1} \theta^{\frac{1}{n}} \left(-\frac{1}{\alpha_1^{\frac{1}{n}+1}} + \frac{1}{(1 - \alpha + \alpha_1)^{\frac{1}{n}+1}}\right) < 0$  si  $\alpha_1 < 1 - \alpha + \alpha_1 \iff 0 < 1 - \alpha \implies L$  decreciente  $\implies$  mínimo con  $\alpha_1 = \alpha$  y  $\alpha_2 = 0$

```
### X = U(0,zita)
longitudesEsperadas <- function (n, alfa, zita)
{
  ## pivote genérico con alfa1=alfa2
  a <- qgamma(alfa/2,n,1)
  b <- qgamma(1-alfa/2,n,1)
  L1 <- zita * (n/(n+1))^n * (exp(b/n)-exp(a/n))
  ## pivote genérico con alfa1 y alfa2 óptimos
  fL2 <- function (alfa1)
  {
    a <- qgamma(alfa1,n,1)
    b <- qgamma(1-alfa+alfa1,n,1)
    zita * (n/(n+1))^n * (exp(b/n)-exp(a/n))
  }
  L2 <- optimize (fL2, c(0,alfa)) $ objective
}
```

```

## pivote EMV
L3 <- n/(n+1) * zita * (1/alfa^(1/n)-1)
## genérico Simétrico y Óptimo, y EMV
c (genéricoS=L1, genéricoŪ=L2, EMV=L3)
}
n <- 100
alfa <- .05
zita <- 1
longitudesEsperadas (n, alfa, zita)
intervalos <- function (x, alfa)
{
  n <- length (x)
  ## pivote genérico...
  T <- prod (x)
  extremo <- function (a) (exp(a)*T)^(1/n)
  ## ...con alfa1=alfa2
  a <- qgamma (alfa/2, n, 1)
  b <- qgamma (1-alfa/2, n, 1)
  Gs1 <- extremo (a)
  Gs2 <- extremo (b)
  L1 <- Gs2 - Gs1
  ## ...con alfa1 y alfa2 óptimos
  fL2 <- function (alfa1)
  {
    a <- qgamma(alfa1,n,1)
    b <- qgamma(1-alfa+alfa1,n,1)
    zita * (n/(n+1))^n * (exp(b/n)-exp(a/n))
  }
  alfa1 <- optimize (fL2, c(0,alfa)) $ minimum
  a <- qgamma (alfa1, n, 1)
  b <- qgamma (1-alfa+alfa1, n, 1)
  Go1 <- extremo (a)
  Go2 <- extremo (b)
  L2 <- Go2 - Go1
  ## pivote EMV
  T <- max (x)
  E1 <- T
  E2 <- T / alfa^(1/n)
  L3 <- E2 - E1
  rbind (genéricoS = c(inf=Gs1, sup=Gs2, lon=L1),
        genéricoŪ = c(inf=Go1, sup=Go2, lon=L2),
        EMV      = c(ind=E1, sup=E2, lon=L3))
}
intervalos (runif(100,0,zita), alfa)
## cobertura
apply (replicate (1e5,
{
  x <- runif (100, 0, zita)
  intervalos.x <- intervalos (x, alfa)
  cubre <- apply (intervalos.x, 1,
    function (inf.sup.lon)
      inf.sup.lon["inf"] <= zita &

```

```

                                zita <= inf.sup.lon["sup"])
}),
1,
mean)
1 - alfa # confianza

### ejemplo de ejecución

> longitudesEsperadas (n, alfa, zita)
genéricoS genéricoĀ EMV
0.39988706 0.39445253 0.03010946

> intervalos (runif(100,0,zita), alfa) # zita=1
                                inf      sup      lon
genéricoS 1.0131663 1.498898 0.48573135
genéricoĀ 0.9963855 1.475516 0.47913018
EMV       0.9925257 1.022709 0.03018326

genéricoS genéricoĀ EMV # coberturas
0.95001 0.95001 0.95082
> 1 - alfa # confianza
[1] 0.95

```

## 5. EXTRA método de Neyman

- parámetro  $\theta$ , confianza  $1 - \alpha$ , estimador  $T$
- para cada  $\theta \in \Theta$  hallar  $a(\theta)$  y  $b(\theta)$  tales que  $\Pr_{\theta}[a(\theta) \leq T \leq b(\theta)] \geq 1 - \alpha$
- sea  $C = \{(\theta, t) \mid \theta \in \Theta, t \in [a(\theta), b(\theta)]\} \subset \mathbb{R}^2$
- dada la realización muestral  $\vec{x}_0$  y  $t_0 = T(\vec{x}_0)$ , se tiene la horquilla IC =  $\{\theta \mid (\theta, t_0) \in C\}$

## 6. método asintótico

### 6.1. pivote para EMV

$n$  grande  $\implies (\hat{\theta}_{MV} - \theta)\sqrt{nI(\theta)} \rightsquigarrow N(0, 1)$

### 6.2. TCL

ejemplo:

- $X \rightsquigarrow B(1, p) \xrightarrow{\text{TCL}} \frac{\bar{X} - p}{\sqrt{\frac{p(1-p)}{n}}} \rightsquigarrow N(0, 1) \implies 1 - \alpha = \Pr \left[ -z_{1-\frac{\alpha}{2}} \leq \frac{\bar{X} - p}{\sqrt{\frac{p(1-p)}{n}}} \leq +z_{1-\frac{\alpha}{2}} \right]$   
 $= \Pr \left[ \left| \frac{\bar{X} - p}{\sqrt{\frac{p(1-p)}{n}}} \right| \leq z_{1-\frac{\alpha}{2}} \right] = \Pr \left[ \frac{(\bar{X} - p)^2}{\frac{p(1-p)}{n}} \leq z_{1-\frac{\alpha}{2}}^2 \right] \implies \text{IC} =$   
 $\left[ -\frac{z_{1-\frac{\alpha}{2}} \sqrt{z_{1-\frac{\alpha}{2}}^2 + (4\bar{X} - 4\bar{X}^2)n - z_{1-\frac{\alpha}{2}}^2 - 2\bar{X}n}}{2z_{1-\frac{\alpha}{2}}^2 + 2n}, \frac{z_{1-\frac{\alpha}{2}} \sqrt{z_{1-\frac{\alpha}{2}}^2 + (4\bar{X} - 4\bar{X}^2)n + z_{1-\frac{\alpha}{2}}^2 + 2\bar{X}n}}{2z_{1-\frac{\alpha}{2}}^2 + 2n} \right]$
- si  $n$  es grande, se puede considerar  $\frac{\bar{X} - p}{\sqrt{\frac{\bar{X}(1-\bar{X})}{n}}} \rightsquigarrow N(0, 1) \implies \text{IC} = \bar{X} \pm z_{1-\frac{\alpha}{2}} \sqrt{\frac{\bar{X}(1-\bar{X})}{n}}$

### 6.3. método delta

- cuando se trata de una transformación de un estadígrafo con distribución asintótica asegurada por el TCL
- ejemplo

- $X \hookrightarrow P(\lambda) \implies E(X) = \lambda, D(X) = \sqrt{\lambda}$

- TCL  $\implies \frac{\bar{X}-\lambda}{\sqrt{\frac{\lambda}{n}}} \overset{\sim}{\hookrightarrow} N(0,1)$

**versión primera** despejando  $\lambda$ :  $\frac{(\bar{X}-\lambda)^2}{\frac{\lambda}{n}} \overset{\sim}{\hookrightarrow} \chi_1^2 \implies \Pr \left[ \frac{(\bar{X}-\lambda)^2}{\frac{\lambda}{n}} < a \right] = 1 - \alpha \implies$   
 $\Pr \left[ \bar{X}^2 + \lambda^2 - 2\bar{X}\lambda < \frac{a}{n}\lambda \right] = 1 - \alpha \implies \Pr \left[ \lambda^2 + \left(-2\bar{X} - \frac{a}{n}\right)\lambda + \bar{X}^2 < 0 \right] = 1 - \alpha \implies$   
 $\Pr \left[ \lambda \in \left( \bar{X} + \frac{a}{2n} \pm \sqrt{\frac{a^2}{4n^2} + \frac{a\bar{X}}{n}} \right) \right] = 1 - \alpha$

**versión segunda** sustituyendo  $\lambda$  en el denominador por su estimador:  $\frac{\bar{X}-\lambda}{\sqrt{\frac{\bar{X}}{n}}} \overset{\sim}{\hookrightarrow} N(0,1) \implies \text{IC} =$   
 $\bar{X} \pm z\sqrt{\frac{\bar{X}}{n}}$

- método  $\delta \implies \sqrt{\bar{X}} \overset{\sim}{\hookrightarrow} N\left(\sqrt{\lambda}, \frac{1}{2\sqrt{\lambda}}\right) \implies \text{IC} = \left(\sqrt{\bar{X}} \pm \frac{z}{2\sqrt{\bar{X}}}\right)^2$

- nótese que los intervalos TCL2 y  $\delta$  tienen la misma amplitud:

- IC TCL:  $\left(\bar{X} + z\sqrt{\frac{\lambda}{n}}\right) - \left(\bar{X} - z\sqrt{\frac{\lambda}{n}}\right) = 2z\sqrt{\frac{\lambda}{n}}$

- IC  $\delta$ :  $\left(\sqrt{\bar{X}} + \frac{z}{2\sqrt{\bar{X}}}\right)^2 - \left(\sqrt{\bar{X}} - \frac{z}{2\sqrt{\bar{X}}}\right)^2 = \left(\bar{X} + \frac{z^2}{4n}\right) + 2\sqrt{\bar{X}}\frac{z}{2\sqrt{\bar{X}}} - \left(\bar{X} + \frac{z^2}{4n}\right) - 2\sqrt{\bar{X}}\frac{z}{2\sqrt{\bar{X}}} = 2z\sqrt{\frac{\bar{X}}{n}}$

```
## X = P(1) => E(X)=1 D(X)=raiz(1)
n = 30                                # tamaño muestral
l = 5                                  # parámetro
a = 0.05                               # alfa, 1-confianza
resul = replicate (1e5,
{
  X = rpois (n, 1)
  T = mean(X)
  ## TCL => (T - l) / raiz(1/n) = N(0,1) => (T - l)^2 / (1/n) = (Ji^2)_1
  ## {Pr[(Ji^2)_1 < ji] = 1-a} => IC: (T-l)^2 < ji 1/n =>
  ## => T^2 + l^2 - 2 T l - ji 1/n < 0 =>
  ## => l^2 + (-2T - ji/n) l + T^2 < 0 =>
  ji = qchisq(1-a,1)
  Itcl1 = T + ji/2/n + c(-1,1)*sqrt(ji^2/n^2/4+ji*T/n)
  ## TCL => T = N(l,raiz(1/n)) => IC = T +/- z raiz(1/n)
  ## => IC = T +/- z raiz(T/n)
  z = qnorm(1-a/2)
  Itcl2 = T + c(-1,1)*z*sqrt(T/n)
  ## delta => raiz(T) = N(raiz(1),1/[2raiz(n)])
  Idelta = (sqrt(T) + c(-1,1)*z/(2*sqrt(n)))^2
  ## longitudes y coberturas:
  c (Ltcl1 = diff(Itcl1), Ltcl2 = diff(Itcl2), Ldelta = diff(Idelta),
    Ctcl1 = Itcl1[1] <= l & l <= Itcl1[2],
    Ctcl2 = Itcl2[1] <= l & l <= Itcl2[2],
    Cdelta = Idelta[1] <= l & l <= Idelta[2])
})
```

```
apply(resul,1,mean)
```

```
### ejemplo de ejecución:
```

Ltcl1	Ltcl2	Ldelta	Ctcl1	Ctcl2	Cdelta
1.604105	1.598978	1.598978	0.954893	0.952269	0.950206

## 7. remuestreo autosuficiente o bústrap (*bootstrap*)

### 7.1. definición

- población  $X \hookrightarrow F_\theta$ , estimador  $\hat{\theta} = T$ , realización muestral  $\vec{x}_0 = (x_{01}, \dots, x_{0n})$
- **objetivo:** aproximar la distribución de  $T$
- **idea:** considerar  $\vec{x}_0$  como una población nueva, con distribución  $F_n$  (la ojiva empírica), es decir,  $\forall i \in \{1, \dots, n\}$ ,  $\Pr(x_{0i}) = \frac{1}{n}$
- algoritmo general: iterar  $B$  veces
  - obtener  $\vec{x}^*$  muestra de tamaño  $n$  con reposición a partir de  $\vec{x}_0$
  - calcular  $t^* = T(\vec{x}^*)$

	Población	Muestra	Parámetro	Estimador
original	$X$	$\vec{x}$	$\theta$	$t = T(\vec{x})$
bústrap	$\vec{x}_0$	$\vec{x}^*$	$t_0 = T(\vec{x}_0)$	$t^* = T(\vec{x}^*)$

- **étimo:** *bootstrap* es una parte del calzado (identificado a veces con la oreja) y se usa en una expresión inglesa que significa obtener algo en principio imposible; Pedro Gil aludía a la expresión duros a cuatro pesetas (€ a 80 c) para ilustrar el método

### 7.2. hipótesis

se supone que se cumple alguna de las siguientes:

**hipótesis A**  $F_n$  es una buena aproximación de  $F_\theta$ , luego la distribución de  $T^*$  es similar a la de  $T$

**hipótesis B**  $T^* - t_0$  tiene distribución parecida a  $T - \theta$

**hipótesis C**  $\frac{T^* - t_0}{D(T^*)}$  tiene distribución parecida a  $\frac{T - \theta}{D(T)}$  donde  $D(T) = \sigma_T$  es el desvío típico de  $T$

### 7.3. método gaussiano

- (aunque es habitual estimar la varianza del estimador, este método no suele usarse para intervalos; aquí se presenta para introducir intuitivamente el bústrap percentil)
- supone  $V(T) = V(T^*)$  (implicado por hipótesis A ó B) y distribución aproximadamente gaussiana de  $T$
- estimación bústrap de  $V(T)$ 
  - generar  $B$  muestras bústrap  $\vec{x}_1^*, \dots, \vec{x}_B^*$
  - aplicar el estimador a cada muestra:  $\forall i \in \{1, \dots, B\}$ ,  $t_i^* = T(\vec{x}_i^*)$
  - estimar la varianza  $V(T^*)$  a partir de la (cuasi)varianza muestral  $\hat{V}(T^*) = \hat{S}_{T^*}^2 = \frac{\sum_{i=1}^B (t_i^* - \bar{t}^*)^2}{B-1}$  donde  $\bar{t}^* = \frac{1}{n} \sum t_i^*$
- $T \overset{\sim}{\hookrightarrow} N(\theta, \sigma_T) \implies \text{IC} = T \pm z\hat{\sigma}_T = T(\vec{x}_0) \pm z\hat{\sigma}_T = t_0 \pm z\hat{\sigma}_T$

- $\pm z$  son los cuantiles de órdenes  $\frac{\alpha}{2}$  y  $1 - \frac{\alpha}{2}$  de una gaussiana típica,  $N(0, 1)$
- los extremos del IC son los cuantiles de órdenes  $\frac{\alpha}{2}$  y  $1 - \frac{\alpha}{2}$  de una distribución gaussiana  $N(t_0, \hat{\sigma}_T)$
- $T^* \overset{\sim}{\hookrightarrow} N(t_0, \sigma_{T^*}) \implies 1 - \alpha = \Pr^*(t_0 - z\hat{\sigma}_{T^*} \leq T^* \leq t_0 + z\hat{\sigma}_{T^*}) \implies \text{IC}^* = t_0 \pm z\hat{\sigma}_{T^*}$ 
  - $\Pr_\theta$  indica la probabilidad asociada a  $F_\theta$  y  $\Pr^*$  indica la probabilidad asociada a  $F_n$
  - los extremos del  $\text{IC}^*$  son los cuantiles de órdenes  $\frac{\alpha}{2}$  y  $1 - \frac{\alpha}{2}$  de una distribución gaussiana  $N(t_0, \sigma_{T^*})$ , teóricamente
  - los extremos del  $\text{IC}^*$  son los cuantiles de órdenes  $\frac{\alpha}{2}$  y  $1 - \frac{\alpha}{2}$  de la distribución bústrap, en la práctica

## 7.4. método percentil

- supone hipótesis A
- basado en que
  - $1 - \alpha = \Pr(a \leq T \leq b) \approx \Pr^*(a \leq T^* \leq b)$
  - $T$  aproximadamente insesgado, luego  $a \leq \theta \leq b$  y
    - $\hat{a} = T_1 = \hat{T}_{\frac{\alpha}{2}} = \widehat{\text{cuantil } \frac{\alpha}{2} \text{ de } T}$
    - $\hat{b} = T_2 = \hat{T}_{1-\frac{\alpha}{2}} = \widehat{\text{cuantil } 1 - \frac{\alpha}{2} \text{ de } T}$
  - existe una transformación  $g$  tal que  $g(T)$  es simétrica centrada en  $g(\theta)$ ; Efron y Tibshirani, An introduction to the bootstrap, 13.3:
    - en inferencia clásica existe un amplio catálogo de transformaciones para conseguir acercar la distribución de un estimador a la situación ideal  $T \hookrightarrow N(\theta, \sigma_T)$
    - el método percentil extiende la utilidad del método gaussiano sin necesidad de conocer dicho catálogo
- los extremos del  $\text{IC}^*$  son los cuantiles de órdenes  $\frac{\alpha}{2}$  y  $1 - \frac{\alpha}{2}$  de la distribución bústrap (generalización de la idea del método gaussiano)
  - obtener  $a$  y  $b$  como cuantiles de órdenes respectivos  $\frac{\alpha}{2}$  y  $1 - \frac{\alpha}{2}$  de la distribución de  $T^*$
  - $\text{IC}^* = [a, b]$
- el bústrap percentil no funciona bien con estimadores como  $X_{(1)}$  y  $X_{(n)}$

### 7.4.1. teorema

#### 1. enunciado

- si existe  $g$  creciente tal que  $g(T) - g(\theta)$  tiene la misma distribución  $\Psi$  que  $g(T^*) - g(T)$ , simétrica respecto al origen,
- entonces el intervalo «percentil»  $[a, b]$  cumple la cobertura probabilística

#### 2. demostración

- por la simetría,  $\Psi(-x) = 1 - \Psi(x)$
- sea  $\psi_\alpha$  el cuantil de orden  $\alpha$  de  $\Psi$ , luego  $\psi_\alpha = -\psi_{1-\alpha}$
- $1 - \alpha = \Pr_\theta \left[ -\psi_{1-\frac{\alpha}{2}} \leq g(T) - g(\theta) \leq \psi_{1-\frac{\alpha}{2}} \right] \approx \Pr^* \left[ -\psi_{1-\frac{\alpha}{2}} \leq g(T^*) - g(T) \leq \psi_{1-\frac{\alpha}{2}} \right]$
- extremo inferior del intervalo:  $\frac{\alpha}{2} = \Pr^*[g(T^*) - g(T) < -\psi_{1-\frac{\alpha}{2}}] = \Pr^*[g(T^*) < g(T) - \psi_{1-\frac{\alpha}{2}}] = \Pr^*[T^* < g^{-1}(g(T) - \psi_{1-\frac{\alpha}{2}})]$  luego  $g^{-1}(g(T) - \psi_{1-\frac{\alpha}{2}}) = F_{T^*}^{-1}\left(\frac{\alpha}{2}\right)$
- análogamente para el extremo superior:  $g^{-1}(g(T) + \psi_{1-\frac{\alpha}{2}}) = F_{T^*}^{-1}\left(1 - \frac{\alpha}{2}\right)$



$$\begin{aligned}
& \Pr \left[ -\psi_{1-\frac{\alpha}{2}} \leq g(T) - g(\theta) \leq \psi_{1-\frac{\alpha}{2}} \right] = \Pr \left[ -g(T) - \psi_{1-\frac{\alpha}{2}} \leq -g(\theta) \leq -g(T) + \psi_{1-\frac{\alpha}{2}} \right] = \\
& \Pr \left[ g(T) + \psi_{1-\frac{\alpha}{2}} \geq g(\theta) \geq g(T) - \psi_{1-\frac{\alpha}{2}} \right] = \Pr \left[ g^{-1}(g(T) + \psi_{1-\frac{\alpha}{2}}) \geq \theta \geq g^{-1}(g(T) - \psi_{1-\frac{\alpha}{2}}) \right] = \\
& \Pr \left[ g^{-1}(g(T) - \psi_{1-\frac{\alpha}{2}}) \leq \theta \leq g^{-1}(g(T) + \psi_{1-\frac{\alpha}{2}}) \right] = \Pr \left[ F_{T^*}^{-1} \left( \frac{\alpha}{2} \right) \leq g(T) - g(\theta) \leq F_{T^*}^{-1} \left( 1 - \frac{\alpha}{2} \right) \right] \\
& \implies \text{IC} = \left[ F_{T^*}^{-1} \left( \frac{\alpha}{2} \right), F_{T^*}^{-1} \left( 1 - \frac{\alpha}{2} \right) \right]
\end{aligned}$$

### 3. EXTRA necesidad de la simetría

- sean  $\alpha_1$  y  $\alpha_2$  tales que  $\alpha_1 + \alpha_2 = \alpha$
- sean  $c_1$  y  $c_2$  tales que  $\alpha_1 = \Psi(c_1)$  ;  $1 - \alpha_2 = \Psi(c_2)$
- $1 - \alpha = \Pr_{\theta} [c_1 \leq g(T) - g(\theta) \leq c_2] \approx \Pr^* [c_1 \leq g(T^*) - g(T) \leq c_2]$
- extremo inferior del intervalo:  $\frac{\alpha}{2} = \Pr^* [g(T^*) - g(T) < c_1] = \Pr^* [g(T^*) < g(T) + c_1] = \Pr^* [T^* < g^{-1}(g(T) + c_1)]$  luego  $g^{-1}(g(T) + c_1) = F_{T^*}^{-1} \left( \frac{\alpha}{2} \right)$
- análogamente para el extremo superior:  $g^{-1}(g(T) + c_2) = F_{T^*}^{-1} \left( 1 - \frac{\alpha}{2} \right)$
- $\Pr [c_1 \leq g(T) - g(\theta) \leq c_2] = \Pr [-g(T) + c_1 \leq -g(\theta) \leq -g(T) + c_2] = \Pr [g(T) - c_1 \geq g(\theta) \geq g(T) - c_2] = \Pr [g^{-1}(g(T) - c_1) \geq \theta \geq g^{-1}(g(T) - c_2)] = \Pr [g^{-1}(g(T) - c_2) \leq \theta \leq g^{-1}(g(T) - c_1)] = \langle \text{aquí necesitamos } c_1 = -c_2 \rangle = \Pr \left[ F_{T^*}^{-1} \left( \frac{\alpha}{2} \right) \leq g(T) - g(\theta) \leq F_{T^*}^{-1} \left( 1 - \frac{\alpha}{2} \right) \right] \implies \text{IC} = \left[ F_{T^*}^{-1} \left( \frac{\alpha}{2} \right), F_{T^*}^{-1} \left( 1 - \frac{\alpha}{2} \right) \right]$

#### 7.4.2. EXTRA corrección de sesgo

- el método percentil suele suponer  $\Psi \sim N(0, \sigma)$
- generalización:  $\frac{g(T) - g(\theta)}{\sigma} \hookrightarrow N(-z_0, 1)$
- $z_0$  y  $\sigma$  desconocidos ;  $z_0$  estimable:
  - $p = \Pr^* [T^* \leq T] \implies$  estimable mediante bústrap como  $\hat{p} = F_{T^*}^{-1}(T)$
  - $p = \Pr^* [T^* \leq T] = \Pr^* \left[ \frac{gT^* - gT}{\sigma} \leq 0 \right] = \Phi(z_0) \implies \hat{z}_0 = \Phi^{-1}(\hat{p})$
- $1 - \alpha = \Pr \left[ z_{\alpha_1} \leq \frac{gT - g\theta}{\sigma} + z_0 \leq z_{1-\alpha_2} \right] = \Pr [g^{-1}(gT + \sigma(z_0 + z_{\alpha_1})) \leq \theta \leq g^{-1}(gT + \sigma(z_0 + z_{1-\alpha_2}))]$   
 $\implies \text{I.C.} = [g^{-1}(gT + \sigma(z_0 + z_{\alpha_1})), g^{-1}(gT + \sigma(z_0 + z_{1-\alpha_2}))]$
- extremo inferior:  $\Pr^* [T^* \leq g^{-1}(gT + \sigma(z_0 + z_{\alpha_1}))] = \Pr^* \left[ \frac{gT^* - gT}{\sigma} + z_0 \leq 2z_0 + z_{\alpha_1} \right] = \Pr^* [N(0, 1) \leq 2z_0 + z_{\alpha_1}] = \Phi(2z_0 + z_{\alpha_1}) \implies g^{-1}(gT + \sigma(z_0 + z_{\alpha_1})) = F_{T^*}^{-1}(\Phi(2z_0 + z_{\alpha_1}))$
- extremo superior, análogamente:  $g^{-1}(gT + \sigma(z_0 + z_{1-\alpha_2})) = F_{T^*}^{-1}(\Phi(2z_0 + z_{1-\alpha_2}))$

#### 7.5. método básico

- supone hipótesis B
- basado en que  $1 - \alpha = \Pr(a \leq T - \theta \leq b) \approx \Pr^*(a \leq T^* - t_0 \leq b)$
- obtener  $a$  y  $b$  como cuantiles de órdenes respectivos  $\frac{\alpha}{2}$  y  $1 - \frac{\alpha}{2}$  de la distribución de  $T^* - t_0$
- $1 - \alpha = \Pr(a \leq T - \theta \leq b) = \Pr(a - T \leq -\theta \leq b - \theta) = \Pr(T - a \geq -\theta \geq T - b) = \Pr(T - b \leq \theta \leq T - a)$   
 $\implies \text{IC} = [T - b, T - a] = [t_0 - b, t_0 - a]$

## 7.6. método $t$ ó estudentizado

- supone hipótesis C
- étimo: si  $X \hookrightarrow N(\theta, \sigma)$ ,  $T = \bar{X}$  y  $\hat{D}(T) = \frac{\hat{\sigma}}{\sqrt{n}}$ , entonces  $\frac{T-\theta}{\hat{D}(T)} \hookrightarrow t_{n-1}$ 
  - Efron y Tibshirani, en *An introduction to the bootstrap*, 12.4, sugieren que sirve de aproximación para distribuciones arbitrarias: en 1908, Gosset *el Estudiante* derivó la aproximación  $\frac{T-\theta}{\hat{D}(T)} \overset{\sim}{\hookrightarrow} t_{n-1}$  para el caso  $T = \bar{X}$
- a menudo  $\frac{T^*-t_0}{\hat{D}(T^*)}$  es más estable que  $T^* - t_0$
- basado en que  $1 - \alpha = \Pr\left(a \leq \frac{T-\theta}{\hat{D}(T)} \leq b\right) \approx \Pr^*\left(a \leq \frac{T^*-t_0}{\hat{D}(T^*)} \leq b\right)$
- para calcular  $\hat{D}(T^*)$  requiere expresión explícita de la varianza de  $T$  (véase ejemplo siguiente) o usar sobre la muestra bústrap  $\bar{x}^*$ 
  - otro bústrap (anidado)
  - remuestreo herramental
- obtener  $a$  y  $b$  como cuantiles de órdenes respectivos  $\frac{\alpha}{2}$  y  $1 - \frac{\alpha}{2}$  de la distribución de  $\frac{T^*-t_0}{\hat{D}(T^*)}$
- $1 - \alpha = \Pr\left(a \leq \frac{T-\theta}{\hat{D}(T)} \leq b\right) = \Pr\left(T - b\hat{D}(T) \leq \theta \leq T - a\hat{D}(T)\right) \implies \text{IC} = [T - b\hat{D}(T), T - a\hat{D}(T)] = [t_0 - bd_0, T - ad_0]$
- $d_0$  se puede obtener como desvío típico de  $T^*$  o, si está disponible, a través de la expresión explícita de la varianza de  $T$

## 7.7. método paramétrico

- los métodos anteriores son **no paramétricos** ; el remuestreo se realiza a partir de la distribución empírica  $F_n$
- en el bústrap **paramétrico** se sustituye el remuestreo  $F_n$  por el remuestreo a partir de  $F_{\hat{\theta}}$ , la supuesta distribución de  $X$  con los parámetros sustituidos por estimaciones
- el resto de pasos son los mismos que en bústrap no paramétrico
- ventajas
  - no paramétrico: evita establecer una familia paramétrica de distribuciones para  $X$
  - paramétrico:
    - produce resultados más precisos que las fórmulas clásicas asintóticas y puede usarse en problemas para los que no existe fórmula (Efron y Tibshirani, *An introduction to the bootstrap*, 6.5)
    - funciona también cuando el estimador es  $X_{(1)}$  y  $X_{(n)}$  (en tales casos, un remuestreo no paramétrico produciría una mayoría de remuestras con el mismo valor del estimador)

## 7.8. ejemplo

- $X \hookrightarrow N(\mu, \sigma)$
- se busca IC para  $\sigma^2$
- $\frac{(n-1)\hat{S}^2}{\sigma^2} \hookrightarrow \chi_{n-1}^2 \implies V\left[\frac{(n-1)\hat{S}^2}{\sigma^2}\right] = 2(n-1) \implies V(\hat{S}^2) = \frac{2\sigma^4}{n-1} \implies D(\hat{S}^2) = \sigma^2 \sqrt{\frac{2}{n-1}}$

```

a = 0.05 # alfa, 1 - confianza
n = 30 # tamaño muestral
mu = 0
sigma2 = 100 # parámetro de interés
sigma = sqrt(sigma2)
longitudesYcoberturas = function (x0)
{
  T = var # estimador = cuasivarianza = S^2
  t0 = T(x0)
  B = 1e3 # número de muestras bústrap
  distri = replicate (B, # distribuciones bústrap
  {
    xB = sample (x0, replace=TRUE) # muestra bústrap x*
    tB = T(xB) # t*
    c (percentil = tB,
        básico = tB - t0,
        t = (tB - t0) / (tB*sqrt(2/(n-1))))
  })
  cuantiles = apply (distri, 1, function (x) quantile(x,c(a/2,1-a/2)))
  Ipercentil = cuantiles[,"percentil"]
  Ibásico = t0 - rev(cuantiles[,"básico"])
  It = t0 - rev(cuantiles[,"t"]) * (t0*sqrt(2/(n-1)))
  intervalos = rbind (Iteórico = (n-1)*t0/qchisq(c(1-a/2,a/2),n-1),
                      Ipercentil, Ibásico, It)
  longitudes = apply (intervalos, 1, diff)
  coberturas = apply (intervalos, 1, function (x) x[1]<=sigma2&sigma2<=x[2])
  cbind (intervalos, longitudes, coberturas)
}
x0 = rnorm (n, mu, sigma)
longitudesYcoberturas(x0)
resul = replicate (1e4,
{
  x0 = rnorm (n, mu, sigma)
  lYc = longitudesYcoberturas(x0)
  list (longitudes = lYc[,"longitudes"],
        coberturas = lYc[,"coberturas"])
})
apply(do.call(rbind,resul["longitudes",]),2,mean)
apply(do.call(rbind,resul["coberturas",]),2,mean)

```

### ejemplo de ejecución

```

## > x0 = rnorm (n, mu, sigma)
## > longitudesYcoberturas(x0)
##           2.5%   97.5% longitudes coberturas
## Iteórico   65.36465 186.2409 120.87627      1
## Ipercentil 58.29280 148.3789  90.08614      1
## Ibásico   57.73288 147.8190  90.08614      1
## It        71.57701 182.1941 110.61711      1

## > apply(do.call(rbind,resul["longitudes",]),2,mean)
##   Iteórico Ipercentil   Ibásico      It

```

```
## 117.4148 92.0845 92.0845 117.5555
## > apply(do.call(rbind,resul["coberturas",]),2,mean)
## Iteórico Ipercentil Ibásico It
## 0.9475 0.8811 0.8785 0.9130
```

mismo ejemplo con bústrap paramétrico:

```
a = 0.05 # alfa, 1 - confianza
n = 30 # tamaño muestral
mu = 0
sigma2 = 100 # parámetro de interés
sigma = sqrt(sigma2)
longitudesYcoberturas = function (x0)
{
  T = var # estimador = cuasivarianza = S^2
  t0 = T(x0)
  B = 1e3 # número de muestras bústrap
  muE = mean(x0) ; sigmaE = sd(x0) # PARÁMETROS ESTIMADOS para remuestreo
  distri = replicate (B, # distribuciones bústrap
  {
    xB = rnorm (n, muE, sigmaE) # muestra bústrap x* PARAMÉTRICA
    tB = T(xB) # t*
    c (percentil = tB,
        básico = tB - t0,
        t = (tB - t0) / (tB*sqrt(2/(n-1))))
  })
  cuantiles = apply (distri, 1, function (x) quantile(x,c(a/2,1-a/2)))
  Ipercentil = cuantiles[,"percentil"]
  Ibásico = t0 - rev(cuantiles[,"básico"])
  It = t0 - rev(cuantiles[,"t"]) * (t0*sqrt(2/(n-1)))
  intervalos = rbind (Iteórico = (n-1)*t0/qchisq(c(1-a/2,a/2),n-1),
                    Ipercentil, Ibásico, It)
  longitudes = apply (intervalos, 1, diff)
  coberturas = apply (intervalos, 1, function (x) x[1]<=sigma2&sigma2<=x[2])
  cbind (intervalos, longitudes, coberturas)
}
x0 = rnorm (n, mu, sigma)
longitudesYcoberturas(x0)
resul = replicate (1e4,
{
  x0 = rnorm (n, mu, sigma)
  lYc = longitudesYcoberturas(x0)
  list (longitudes = lYc[,"longitudes"],
        coberturas = lYc[,"coberturas"])
})
apply(do.call(rbind,resul["longitudes",]),2,mean)
apply(do.call(rbind,resul["coberturas",]),2,mean)
```

### ejemplo de ejecución

```
## > x0 = rnorm (n, mu, sigma)
## > longitudesYcoberturas(x0)
## 2.5% 97.5% longitudes coberturas
```

```
## Iteórico 40.24300 114.66280 74.41979 1
## Ipercentil 35.33351 100.31189 64.97838 1
## Ibásico 26.58481 91.56319 64.97838 0
## It 40.13180 113.93423 73.80243 1

## > apply(do.call(rbind,resul["longitudes",]),2,mean)
## Iteórico Ipercentil Ibásico It
## 116.7928 101.3657 101.3657 116.1387
## > apply(do.call(rbind,resul["coberturas",]),2,mean)
## Iteórico Ipercentil Ibásico It
## 0.9538 0.9287 0.8893 0.9510
```

## 8. determinar tamaño muestral

- error  $\epsilon$  de un intervalo
  - semiamplitud de un intervalo
  - si  $IC = T \pm z\sigma_T$ , entonces  $\epsilon = z\sigma_T$
- objetivo: hallar mínimo tamaño muestral  $n$  necesario para
  - obtener un error menor que  $\epsilon$
  - dada cierta confianza  $1 - \alpha$
- $\Pr[\theta \in T \pm z\sigma_T] \geq 1 - \alpha \implies \text{¿}n\text{?}$

### 8.1. $\sigma$ conocida

#### 8.1.1. caso gaussiano

- $X \hookrightarrow N(\mu, \sigma)$
- $\theta = \mu = E(X)$
- $T = \bar{X} \implies IC = \bar{X} \pm z_{1-\frac{\alpha}{2}} \frac{\sigma}{\sqrt{n}}$
- $z_{1-\frac{\alpha}{2}} \sigma \sqrt{n} \leq \epsilon \implies n \geq \frac{z_{1-\frac{\alpha}{2}}^2 \sigma^2}{\epsilon^2}$

#### 8.1.2. caso general

##### 1. TCL

- como caso gaussiano, pero asegurando  $n > 30, 50, 100 \dots$  según la asimetría de la población

##### 2. desigualdad de Chebichev

- $\Pr[|X - \mu| > k\sigma] \leq \frac{1}{k^2}$
- $\Pr[|T - \mu_T| \leq \epsilon] \geq \frac{\sigma_T^2}{\epsilon^2} \geq 1 - \alpha$
- $\Pr[|\bar{X} - \mu| \leq \epsilon] \geq \frac{\sigma^2}{\frac{\epsilon^2}{n}} \geq 1 - \alpha \implies n \geq \frac{\sigma^2}{\alpha\epsilon^2}$

## 8.2. $\sigma$ desconocida

- estimar  $\sigma$  a partir de una muestra piloto
- acotar  $\sigma$

- caso gaussiano: si  $\sigma \leq \sigma_0$  entonces  $n \geq \frac{z_{1-\frac{\alpha}{2}}^2 \sigma_0^2}{\epsilon^2}$

- caso bernuli:

- $X \hookrightarrow B(1, p)$ ,  $n$  grande  $\implies \bar{X} \overset{\sim}{\hookrightarrow} N\left(p, \sqrt{\frac{p(1-p)}{n}}\right) \implies \text{IC} = \bar{X} \pm z_{1-\frac{\alpha}{2}} \sqrt{\frac{p(1-p)}{n}} \implies$

- $z_{1-\frac{\alpha}{2}} \sqrt{\frac{p(1-p)}{n}} \leq \epsilon \implies z_{1-\frac{\alpha}{2}}^2 \frac{p(1-p)}{n} \leq \epsilon^2 \implies n \geq z_{1-\frac{\alpha}{2}}^2 \frac{p(1-p)}{\epsilon^2}$

- $\forall p \in (0, 1), p(1-p) \leq \frac{1}{4} \implies \text{tomar } n \geq z_{1-\frac{\alpha}{2}}^2 \frac{1}{4\epsilon^2}$

```
unoMenosAlfas <- c (.9, .95, .99)      #confianzas
epsilones <- c (.05, .02, .01, 0.001) #errores
tabla <- outer (unoMenosAlfas, epsilones,
               function (alfa1, eps)
               {
                 alfa <- 1 - alfa1
                 z <- qnorm (1-alfa/2)
                 ceiling (z^2 / (4 * eps^2))
               })
dimnames(tabla) <- list (conf=unoMenosAlfas, err=epsilones)
tabla
```

```
      err
conf  0.05 0.02 0.01 0.001
  0.9   271 1691 6764 676386
  0.95  385 2401 9604 960365
  0.99  664 4147 16588 1658725
```

## 8.3. consecuencias

$n$  crece si

- aumenta la confianza  $1 - \alpha$
- disminuye el error  $\epsilon$
- aumenta la dispersión  $\sigma$