

Tema 6. Estimación de sesgos mediante remuestreo

basado en

- B. Efron, R. Tibshirani (1993). An Introduction to the bootstrap.
- O. Kirchkamp (2019). Resampling methods.

Curso 2023/2024

Introducción

- ▶ Aparte del error estándar, existen otras medidas de precisión de los estimadores, como el **sesgo**, es decir, **la diferencia entre la esperanza de un estimador $\hat{\theta}$ y el valor real del parámetro θ .**
- ▶ El bootstrap es una técnica adecuada para estimar sesgos, aunque la técnica de *jackknife* también es útil en este caso.
- ▶ Se puede usar un estimador del sesgo para corregirlo aunque a veces no es una práctica demasiado efectiva.

Introducción

- ▶ El sesgo de un estimador $\hat{\theta} = s(\mathbf{x})$ de un parámetro $\theta = t(F)$ se define como

$$\text{Sesgo}_F(\hat{\theta}, \theta) = E_F [s(\mathbf{x})] - t(F)$$

- ▶ Es inevitable que aparezca variabilidad en el estimador $\hat{\theta}$ pero resulta inconveniente que esta variabilidad esté localizada en alguna parte concreta.
- ▶ Los estimadores insesgados tales que $E_F(\hat{\theta}) = \theta$ resultan ser bastante importantes en la práctica.
- ▶ Los estimadores *plug-in* del tipo $\hat{\theta} = t(\hat{F})$ no son necesariamente insesgados pero suelen tener sesgos pequeños en comparación con sus errores estándar.

Bootstrap para el sesgo

- ▶ Se puede usar el bootstrap para calcular el sesgo de cualquier estimador $\hat{\theta} = s(\mathbf{x})$.
- ▶ El estimador bootstrap del sesgo se define como el estimador del sesgo donde se sustituye F por \hat{F}

$$\text{Sesgo}_{\hat{F}} = E_{\hat{F}} [s(\mathbf{x})] - t(\hat{F})$$

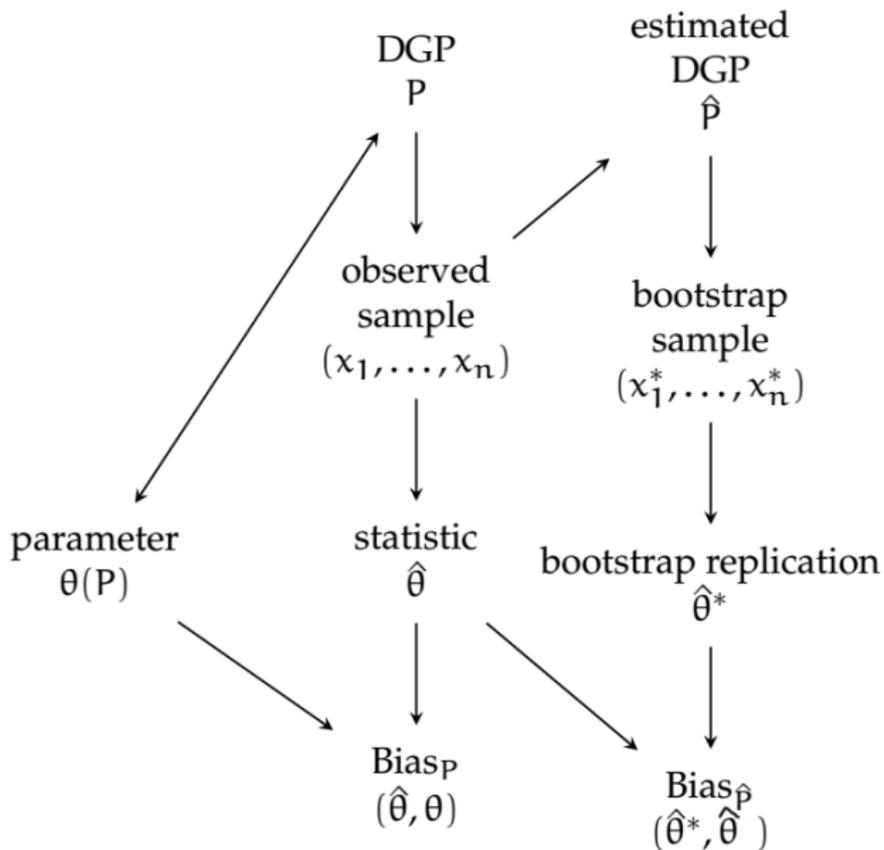
donde $t(\hat{F})$ es el estimador *plug-in* de θ .

- ▶ En la práctica, el estimador bootstrap del sesgo basado en B réplicas es

$$\widehat{\text{Sesgo}}_B = \hat{\theta}^*(\cdot) - t(\hat{F})$$

donde

$$\hat{\theta}^*(\cdot) = \sum_{b=1}^B \frac{\hat{\theta}^*(b)}{B}$$



Ejemplo

- ▶ Se tiene una serie de datos sobre el efecto de unos parches hormonales sobre 8 personas. Dichos parches difunden un medicamento en la sangre.
- ▶ Se mide el nivel de la hormona que aparece después de usar tres parches diferentes: un parche *placebo* (sin hormona), un parche *viejo* y uno *nuevo*.
- ▶ Se trata de estudiar su *bioequivalencia*.
- ▶ El criterio que se utiliza en la agencia estatal norteamericana de medicamentos (*FDA*) es que

$$\frac{|E(\text{nuevo}) - E(\text{viejo})|}{E(\text{viejo}) - E(\text{placebo})} \leq 0,20$$

Ejemplo

- ▶ Es decir, la *FDA* exige que el nuevo tipo de parche se ajuste a la cantidad de hormona que liberaba el antiguo (respecto al placebo) en no más del 20 %.
- ▶ Se denomina como
 - $\mathbf{z} \equiv$ (medida parche viejo – medida placebo)
 - $\mathbf{y} \equiv$ (medida parche nuevo – medida parche viejo)
- ▶ Se asume que las parejas $x_i = (z_i, y_i)$ se obtienen a partir de una distribución bivalente $F \rightarrow \mathbf{x} = (x_1, x_2, \dots, x_8)$.

Ejemplo

- ▶ El parámetro en este caso es entonces

$$\theta = t(F) = \frac{E_F(y)}{E_F(z)} = \frac{E(\text{nuevo}) - E(\text{viejo})}{E(\text{viejo}) - E(\text{placebo})}$$

- ▶ En este caso $t(\cdot)$ es una función que tiene como objeto las parejas de \mathbf{x} y da como resultado el ratio de las esperanzas.
- ▶ El estimador *plug-in* de θ es

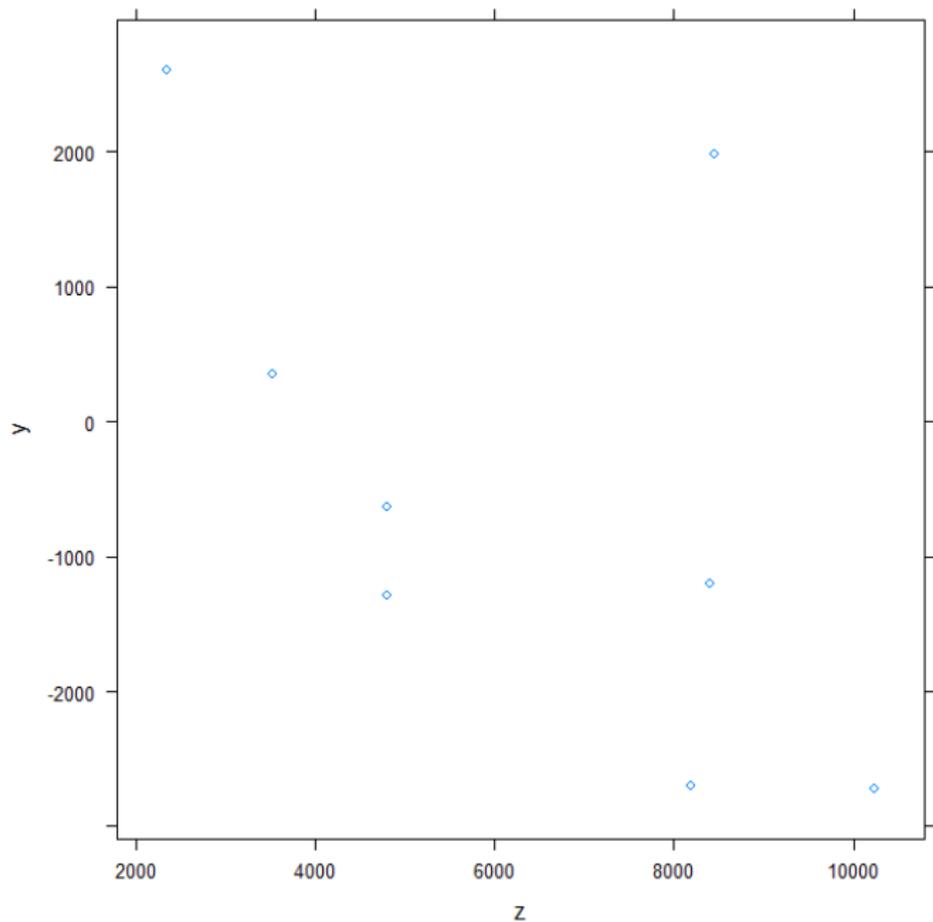
$$\hat{\theta} = t(\hat{F}) = \frac{\bar{y}}{\bar{z}} = \frac{\sum_i y_i / 8}{\sum_i z_i / 8}$$

Ejemplo

- ▶ En el ejemplo,

$$\frac{E(\text{nuevo}) - E(\text{viejo})}{E(\text{viejo}) - E(\text{placebo})} = \frac{E(y)}{E(z)} \approx \frac{\bar{y}}{\bar{z}} = \frac{-452,25}{6342,375} \approx -0,0713$$

```
data(patch, package="bootstrap")  
lattice::xyplot(y ~ z, data=patch)
```



Estimador del sesgo mejorado

- ▶ Se presenta un problema en el cálculo directo del sesgo:

$$\text{Sesgo}_{\hat{f}} = \widehat{\text{Sesgo}}_B = \frac{1}{B} \sum_{b=1}^B \hat{\theta}^{*b} - s(\mathbf{x})$$

- ▶ Ya que en $\frac{1}{B} \sum_{b=1}^B \hat{\theta}^{*b}$ puede que algunas observaciones aparezcan más frecuentemente que otras, mientras que en $s(\mathbf{x})$ todas las observaciones en \mathbf{x} tienen el mismo peso.
- ▶ Sería conveniente, entonces, hacer una *corrección* para considerar los distintos pesos.

Estimador del sesgo mejorado

- ▶ Se considera la noción de **vector de remuestreo**.
- ▶ Se denomina como P_j^* a la proporción de una muestra bootstrap $\mathbf{x}^* = (x_1^*, x_2^*, \dots, x_n^*)$ que es igual al dato j -ésimo original:

$$P_j^* = \frac{\#\{x_i^* = x_j\}}{n}$$

para $j = 1, 2, \dots, n$ y cada $i = 1, 2, \dots, n$.

- ▶ El **vector de remuestreos**

$$\mathbf{P}^* = (P_1^*, P_2^*, \dots, P_n^*)$$

tiene componentes no negativos que suman 1.

Estimador del sesgo mejorado

- ▶ Por ejemplo, en el caso de los datos de los parches, si una muestra bootstrap fuera $\mathbf{x}^* = (x_1, x_6, x_6, x_5, x_7, x_1, x_3, x_8)$ el vector de remuestreos sería

$$\mathbf{P}^* = \left(\frac{2}{8}, 0, \frac{1}{8}, 0, \frac{1}{8}, \frac{2}{8}, \frac{1}{8}, \frac{1}{8} \right)$$

- ▶ Una réplica bootstrap $\hat{\theta}^* = s(\mathbf{x}^*)$ se puede considerar una función del vector de remuestreos \mathbf{P}^* .
- ▶ Por ejemplo en el caso de $\hat{\theta} = \bar{y}/\bar{z}$

$$\hat{\theta}^* = \frac{\bar{y}^*}{\bar{z}^*} = \frac{\sum_{j=1}^8 P_j^* y_j}{\sum_{j=1}^8 P_j^* z_j}$$

Estimador del sesgo mejorado

- ▶ Con esta notación, los datos \mathbf{x} se consideran *fijos* y se considera que las únicas cantidades aleatorias son los P_j^* .
- ▶ De este modo se escribe

$$\hat{\theta}^* = T(\mathbf{P}^*)$$

para indicar que $\hat{\theta}^*$ es una función del vector de remuestreos.

- ▶ Se denomina como \mathbf{P}^0 el vector de longitud n tal que todos sus elementos son iguales a $1/n$

$$\mathbf{P}^0 = \left(\frac{1}{n}, \frac{1}{n}, \dots, \frac{1}{n} \right)$$

Estimador del sesgo mejorado

- ▶ El valor de $T(\mathbf{P}^0)$ es el valor de $\hat{\theta}^*$ cuando cada $P_j^* = \frac{1}{n}$, es decir cuando cada dato original x_j ocurre exactamente una vez en la muestra bootstrap \mathbf{x}^* .
- ▶ Pero esto implica que $\mathbf{x}^* = \mathbf{x}$ excepto en las permutaciones de los elementos. Así el valor del estadístico original es igual al valor observado del estadístico:

$$T(\mathbf{P}^0) = \hat{\theta} = t(\hat{F})$$

Estimador del sesgo mejorado

- ▶ Las B muestras bootstrap $\mathbf{x}^{*1}, \mathbf{x}^{*2}, \dots, \mathbf{x}^{*B}$ dan lugar a los correspondientes vectores de remuestreo $\mathbf{P}^{*1}, \mathbf{P}^{*2}, \dots, \mathbf{P}^{*B}$.
- ▶ Se define como $\bar{\mathbf{P}}^*$ la media de los vectores anteriores

$$\bar{\mathbf{P}}^* = \frac{1}{B} \sum_{b=1}^B \mathbf{P}^{*b}$$

- ▶ De este modo, el mejor estimador bootstrap del sesgo es

$$\overline{\text{Sesgo}}_B = \hat{\theta}^*(\cdot) - T(\bar{\mathbf{P}}^*)$$

donde

$$\hat{\theta}^*(\cdot) = \sum_{b=1}^B \frac{\hat{\theta}^*(b)}{B}$$

Estimador del sesgo mejorado

- ▶ En el ejemplo de los parches se remuestran 400 vectores y se obtiene

$$\bar{\mathbf{P}}^* = (0,1178; 0,1187; 0,1313; 0,1259; 0,1219; 0,1275; 0,1306; 0,1213)$$

- ▶ De modo que

$$T(\bar{\mathbf{P}}^*) = \frac{\sum_{j=1}^8 \bar{P}_j^* y_j}{\sum_{j=1}^8 \bar{P}_j^* z_j} = -0,075$$

- ▶ con lo que

$$\begin{aligned}\overline{\text{Sesgo}}_B &= \hat{\theta}^*(\cdot) - T(\bar{\mathbf{P}}^*) = \\ &= -0,067 - (-0,075) = 0,0080\end{aligned}$$

Corrección del sesgo

- ▶ ¿Para qué se quiere estimar el sesgo de un estimador $\hat{\theta}$?

La razón original es para corregir el estimador $\hat{\theta}$ de modo que sea menos sesgado.

- ▶ Si el sesgo estimado bootstrap es

$$\widehat{\text{sesgo}}_B = \hat{\theta}^*(\cdot) - \hat{\theta}$$

- ▶ Entonces el estimador corregido del sesgo, digamos $\bar{\theta}$, es

$$\begin{aligned}\bar{\theta} &= \hat{\theta} - \widehat{\text{sesgo}}_B \\ &= 2\hat{\theta} - \hat{\theta}^*(\cdot)\end{aligned}$$

Corrección del sesgo

- ▶ Con esto se dice que si $\hat{\theta}^*(\cdot)$ es mayor que $\hat{\theta}$ entonces el estimador de sesgo corregido $\bar{\theta}$ debe ser menor que $\hat{\theta}$.
- ▶ La corrección del sesgo a veces no es conveniente, dado que la estimación del sesgo puede tener una variabilidad alta, con cual, el estimador corregido tendrá también un error estándar alto.