

Clase 9

viernes, 31 de agosto de 2018

11:34

Cuando tenemos la muestra $X=x$ y tal que $X \sim f(x/\theta)$ con $\theta \in \Theta$

Sea a una acción que se toma y sea A el espacio de las posibles acciones. Podemos definir una función de pérdida $L(\theta, a)$ positiva o nula tal que crece cuando crece la distancia de a a θ .

Por ej. si $\Theta \in \mathbb{R}$ hay 2 funciones de pérdida muy comunes

a) Valor absoluto $L(\theta, a) = |a - \theta|$

b) Pérdida cuadrática $L(\theta, a) = (a - \theta)^2$

Son crecientes con el sentido de cuanto más lejos está a de θ mayor valor tienen y valen 0 en $\theta = a$.

La función de pérdida definida como

$$L(\theta, a) = \begin{cases} (a - \theta)^2 & a < \theta \\ 10(a - \theta)^2 & a \geq \theta \end{cases}$$

esta función penaliza más la
sobre estimación

$$L(\theta, a) = \frac{(a - \theta)^2}{|\theta| + 1} \quad \text{esta función}$$

penaliza más a los casos cuando
 θ es cercano a 0 que cuando $|\theta|$ es
"grande"

¿Cómo juega esta función para determinar
la calidad de un estimador?

Sea $f(x)$ un estimador de θ

Def 5.1 Definimos la función de
riesgo $R(\theta, f)$ como

$$R(\theta, f) = E_{\theta} (L(\theta, f(x)))$$

Puedo a partir de esto comparar estimadores

Sea f_1 y f_2 tengo $R(\theta, f_1)$ y $R(\theta, f_2)$

Si

$$R(\theta, f_1) < R(\theta, f_2) \quad \text{si } \forall \theta \in \Theta$$

Implica que f_1 es un estimador más
adecuado que f_2 .

Si las funciones de riesgo "se cruzan" la decisión no es fácil.

Se pueden "cruzar"! Si veamos un ejemplo

Sean $X_1, \dots, X_n \sim \text{Ber}(p)$

Sea \hat{p} el estimador máximo verosímil

o sea $\hat{p} = \bar{X}$

Si consideramos como función de pérdida la pérdida cuadrática entonces tenemos que

$$R(\theta, \hat{p}) = E_p[(\hat{p} - p)^2] = \text{ECM} = \text{Var}_p(\hat{p}) = \frac{p(1-p)}{n}$$

Sabemos que el $\text{ECM} = \text{Var} + (\text{sesgo})^2$
o sea para un estimador δ

$$\begin{aligned} R(\theta, \delta) &= E_{\theta}[(\delta(x) - \theta)^2] = \\ &= \text{Var}_{\theta}(\delta(x)) + (E_{\theta}(\delta(x)) - \theta)^2 = \\ &= \text{Var}_{\theta}(\delta(x)) + (\text{sesgo}_{\theta} \delta(x))^2 \end{aligned}$$

Volvamos al ejemplo. En el práctico se verá un estimador del estilo

$$\hat{p}_B = \frac{Y + \alpha}{\alpha + \beta + n} \quad \text{con } Y = \sum x_i$$

$\alpha, \beta \text{ ctes.}$

$$\begin{aligned} E(\sigma) &= E_p[(\hat{p}_B - p)^2] = \text{Var}(\hat{p}_B) + (E(\hat{p}_B) - p)^2 \\ &= \text{Var}\left(\frac{Y + \alpha}{\alpha + \beta + n}\right) + \left(E\left(\frac{Y + \alpha}{\alpha + \beta + n}\right) - p\right)^2 \\ &= \frac{np(1-p)}{(\alpha + \beta + n)^2} + \left(\frac{np + \alpha}{\alpha + \beta + n} - p\right)^2 \end{aligned}$$

Como $V(\bar{x}) = \frac{p(1-p)}{n}$

$$V\left(\frac{\sum x_i}{n}\right) = \frac{1}{n^2} n V(x_1) = \frac{p(1-p)}{n}$$

$$\Rightarrow V(Y) = np(1-p)$$

Es de ver que se minimiza el ECR cuando

$$\alpha = \beta = \frac{\sqrt{np}}{2}$$

Se obtiene $\hat{p}_B = \frac{Y + \sqrt{np}/2}{n + \sqrt{np}}$


$$\hat{p}_B = \frac{Y + \alpha}{\alpha + \beta + n} = \frac{Y + \sqrt{np}/2}{n + \sqrt{np}} = \frac{Y + \sqrt{np}/2}{n + \sqrt{np}}$$

$$\hat{p}_0 = \frac{7 + \alpha}{\alpha + p + n} = \frac{7 + \sqrt{n}/2}{\sqrt{n}/2 + \sqrt{n}/2 + n} = \frac{7 + \sqrt{n}/2}{\frac{2\sqrt{n} + n}{2}} = \frac{7 + \sqrt{n}/2}{\sqrt{n} + n}$$

Tenemos $\hat{p} = \bar{X}$ y $\hat{p}_0 = \frac{7 + \sqrt{n}/2}{n + \sqrt{n}}$

Si uno grafica las funciones de riesgo se ve que cuando tomamos \hat{p}_0 de ECR es cte o sea el riesgo es cte. En todo el riesgo cuadrático es una parábola.

Si tomamos $n=4$ y $n=400$ y graficamos el riesgo obtenemos graficas del estilo



Se ve que si tengo muestra chica es mejor elegir como estimador \hat{p}_0 y si la muestra es grande elegir \hat{p} .

Example $X_1, \dots, X_n \sim N(\mu, \sigma^2)$
 Este problema es estimar σ^2 . De usy

restringir a estimadores del tipo $\hat{\sigma}_b^2 = b S^2$
 Sabemos $E(S^2) = \sigma^2$ $Var(S^2) = \frac{2\sigma^4}{n-1}$

$$R(\sigma^2, \hat{\sigma}_b) = ECM(\hat{\sigma}_b) = Var(\hat{\sigma}_b) + (E(\hat{\sigma}_b) - \sigma^2)^2$$

↓
uso propiedad combinatoria

$$= Var(b S^2) + (E(b S^2) - \sigma^2)^2 =$$

$$= b^2 Var(S^2) + (b E(S^2) - \sigma^2)^2 =$$

$$= b^2 \frac{2\sigma^4}{n-1} + ((b-1)\sigma^2)^2 =$$

$$\underbrace{\left[\frac{2b^2}{n-1} + (b-1)^2 \right]}_{c_b} \sigma^4$$

El estimador $\hat{\sigma}_b$ será mejor que el $\hat{\sigma}_{b'}$

si $c_b < c_{b'}$ o sea voy a minimizar

$\left[\frac{2b^2}{n-1} + (b-1)^2 \right]$ para hallar el mejor c_b

$$\left(\frac{2b^2}{n-1} + (b-1)^2 \right)' = \frac{4b}{n-1} + 2(b-1) = 0$$

$$4b + 2b(n-1) = 2(n-1)$$

$$2b + 2bn = 2(n-1)$$

$$b = \frac{n-1}{n+1}$$

Por lo tanto el estimador varianza $\hat{\sigma}_b^2 = \frac{n-1}{n+1} S^2$

$$\hat{\sigma}_b^2 = \frac{(n-1)}{n+1} \frac{\sum (x_i - \bar{x})^2}{(n-1)} = \frac{\sum (x_i - \bar{x})^2}{n+1}$$

Ej Función de pérdida de Stein

Si X_1, \dots, X_n i.i.d con varianza finita

se define

$$L(\sigma^2, a) = \frac{a}{\sigma^2} - 1 - \log \frac{a}{\sigma^2}$$

$$\text{Si } a = \sigma^2 \Rightarrow L(\sigma^2, a) = 0$$

$$\text{Si } \sigma^2 \text{ es fijo si } a \rightarrow 0 \Rightarrow L(\sigma^2, a) = +\infty$$

$$a \rightarrow +\infty \Rightarrow L(\sigma^2, a) = +\infty$$

Si consideramos estimadores $\hat{\sigma}_b^2 = b S^2$; cuál es el estimador óptimo?

$$R(\sigma^2, \hat{\sigma}_b^2) = E\left(\frac{b S^2}{\sigma^2} - 1 - \log \frac{b S^2}{\sigma^2}\right) =$$

$$= b E\left(\frac{S^2}{\sigma^2}\right) - 1 - \log b - E\left(\log \frac{S^2}{\sigma^2}\right) =$$

1 pues S^2 es insesgado

$$= b - 1 - \log b - E\left(\log \frac{S^2}{\sigma^2}\right)$$

→ No depende

$$0 - 1 - \gamma = \frac{\sigma^2}{s^2} \rightarrow \text{No depende de } b$$

Numero $b-1-\gamma b$

$$(b-1-\gamma b)' = 1 - \frac{1}{b} = 0 \Rightarrow b=1$$

luego $\boxed{s_b = s^2}$

Enfoque Bayesiano

Def 58: Riesgo Bayesiano
 Definimos el riesgo bayesiano como

$$\int R(\theta, \delta) \pi(\theta) d\theta$$

⊕

$\pi(\theta)$ distribución a priori de θ

Regla de Bayes con una a priori π

$$X \sim f(x|\theta) \quad \theta \sim \pi(\theta)$$

$$\int R(\theta, \delta) \pi(\theta) d\theta = \int \left[\int L(\theta, \delta(x)) f(x|\theta) dx \right] \pi(\theta) d\theta$$

⊕ X

$$\int_{\Theta} L(\theta, \delta(x)) \pi(\theta/x) m(x) dx = \int_{\Theta} L(\theta, \delta(x)) \pi(\theta/x) d\theta \int_{\mathcal{X}} m(x) dx$$

$\int_{\Theta} L(\theta, \delta(x)) \pi(\theta/x) d\theta$ ← a posteriori
 la esperanza de la función de pérdida
 $m(x)$ → marginal de x

$$= \int_{\mathcal{X}} \left[\int_{\Theta} L(\theta, \delta(x)) \pi(\theta/x) m(x) dx \right] d\theta = \text{Riesgo}$$

$$m(x) = \int_{\Theta} f(x/\theta) \pi(\theta) d\theta$$

$$\text{Riesgo} = \int_{\mathcal{X}} \left[\int_{\Theta} L(\theta, \delta(x)) \pi(\theta/x) d\theta \right] m(x) dx$$

depende solo de x

Valor esperado de la pérdida a posteriori

luego minimizar la pérdida esperada a posteriori minimiza el riesgo de Bayes

Ejemplos: pérdida cuadrática \Rightarrow el valor esperado de la pérdida a posteriori es

$$\int_{\Theta} (\theta - a)^2 \pi(\theta/x) d\theta = E((\theta - a)^2 / x = x)$$

⊕

se minimiza cuando $a = E(\theta/x)$

Si usamos la pérdida con el valor absoluto

⇒

$$\int |\theta - a| \pi(\theta/x) dx = E(|\theta - a|/x = x)$$

⊕

se minimiza en la Med (θ/x)