

Resumen Estadística

Sea \mathbb{X} el espacio muestral, un elemento $x = (x_1, \dots, x_n) \in \mathbb{X}$ es una realización de un vector aleatorio $X = (X_1, \dots, X_n)$ con valores en \mathbb{X} . X tiene una ley (distribución) desconocida que pertenece a una familia $\mathcal{P} = \{P_\theta | \theta \in \Theta\}$ de probabilidad sobre \mathbb{X} , con θ los parámetros del modelo y Θ su espacio.

1. Estimación puntual

El problema de estimación puntual es aproximar una función $g(\theta)$ del parámetro θ , es decir

$$g : \Theta \longrightarrow \mathbb{R}^k$$

$$\theta \longrightarrow g(\theta).$$

Def 1. (Estimador) Se define el estimador puntual de $g(\theta)$ como

$$\hat{g} : \mathbb{X} \longrightarrow g(\Theta)$$

$$x \longrightarrow \hat{g}(x).$$

Def 2. (Estimador perfecto) Diremos que un estimador $\hat{g}(X)$ de $g(\theta)$ es perfecto si:

$$P_\theta[\hat{g}(X) = g(\theta)] = 1, \quad \forall \theta \in \Theta.$$

Def 3. (Error cuadrático medio) Sea g una función a valores reales y \hat{g} tal que $E_\theta(\hat{g}(X)^2) < +\infty$, $\forall \theta \in \Theta$. Se define el error cuadrático medio como:

$$\text{ecm}_\theta(\hat{g}) = E_\theta[(\hat{g}(X) - g(\theta))^2]$$

$$= \text{Var}_\theta(\hat{g}(X)) + (E_\theta(\hat{g}(X)) - g(\theta))^2.$$

Entonces, decimos que \hat{g} es mejor que \tilde{g} en el sentido del error cuadrático medio ssi $\text{ecm}_\theta(\hat{g}) \leq \text{ecm}_\theta(\tilde{g})$.

Def 4. (Insesgado) Se dice que \tilde{g} es un estimador insesgado para $g(\theta)$ si:

$$E_\theta(\tilde{g}(X)) = g(\theta), \quad \forall \theta \in \Theta.$$

En este caso $\text{ecm}_\theta(\hat{g}) = \text{Var}_\theta(\hat{g}(X))$.

Prop 0. Sea $\mathcal{P} = \{P_\theta | \theta \in \Theta\}$ una familia paramétrica y $X = (X_1, X_2, \dots, X_n)$ un vector aleatorio tal que $E_\theta(X_i) = \mu(\theta)$, $\text{Var}_\theta(X_i) = \sigma^2(\theta) < \infty$. Entonces $\bar{X} = \hat{\mu}(x) = \frac{1}{n} \sum_{i=1}^n x_i$ es estimador insesgado de $\mu(\theta)$ y $\widehat{\sigma^2}(x) = \frac{1}{n-1} \sum_{i=1}^n (x_i - \hat{\mu}(x))^2$ es estimador insesgado de $\sigma^2(\theta)$.

Def 5. (EIVUM) Diremos que g^* es un EIVUM (estimador insesgado de varianza uniformemente mínima) para $g(\theta)$ si

$$\text{Var}_\theta(g^*(X)) \leq \text{Var}_\theta(\hat{g}(X)), \quad \forall \theta \in \Theta, \forall \hat{g}$$

con \hat{g} estimador insesgado de $g(\theta)$.

Def 6. (Estadístico) Una función $T(X)$ del vector aleatorio $X = (X_1, \dots, X_n)$ es un estadístico, es decir, T es una función de \mathbb{X} a \mathbb{R}^k .

Def 7. (Estadístico suficiente) Diremos que $T(X)$ es un estadístico suficiente para la familia $\mathcal{P} = \{P_\theta | \theta \in \Theta\}$ si la ley de X condicional a $T(X)$ no depende de θ . Es decir, si existe una función H tal que

$$P_\theta[X \in A | T(X) = t] = H(A, t),$$

donde $A \in \mathbb{X}$ y H no depende de θ .

Teo 1. (Factorización) Consideremos el modelo $\mathcal{P} = \{P_\theta | \theta \in \Theta\}$ y $T(X)$ un estadístico. Entonces $T(X)$ es suficiente para \mathcal{P} ssi

$$f_\theta(X) = g_\theta(T(X)) h(X)$$

donde $f_\theta(X)$ representa la densidad del vector X , $g_\theta(\cdot)$ es una función que depende de θ y $h(\cdot)$ es una función que no depende de θ .

Teo 2. (Rao-Blackwell) Sea $\mathcal{P} = \{P_\theta | \theta \in \Theta\}$ una familia paramétrica, $g(\theta)$ una función del parámetro θ , $\tilde{g}(X)$ un estimador insesgado de $g(\theta)$. Sea $T(X)$ un estadístico suficiente para \mathcal{P} . Definimos

$$\hat{g}(t) = E_\theta[\tilde{g}(X) | T(X) = t].$$

Entonces $\hat{g}(T(X))$ es un estimador insesgado para $g(\theta)$ y

$$\text{Var}_\theta(\hat{g}(T(X))) \leq \text{Var}_\theta(\tilde{g}(X)), \quad \forall \theta \in \Theta.$$

Def 8. (Estadístico completo) Diremos que $T(X)$ es completo para la familia $\{P_\theta | \theta \in \Theta\}$ si no existen estimadores insesgados de 0 no triviales que sean función de $T(X)$, es decir,

$$E_\theta[f(T(X))] = 0 \quad \forall \theta \in \Theta \implies f = 0 \quad \text{ctp.}$$

Prop 1. Sea $T(X)$ estadístico suficiente y completo para $\{P_\theta | \theta \in \Theta\}$. Sea $\tilde{g}(X)$ un estimador insesgado para $g(\theta)$, definimos

$$\hat{g}(t) = E_\theta(\tilde{g}(X) | T(X) = t).$$

Entonces $\hat{g}(T(X))$ es el EIVUM de $g(\theta)$.

Def 9. (Familia exponencial) Consideremos una familia $\{P_\theta | \theta \in \Theta\}$ sobre \mathbb{X} y supongamos que P_θ tienen densidad f_θ . Si f_θ se puede escribir como

$$f_\theta(X) = C(\theta) e^{\sum_{i=1}^k Q_i(\theta) t_i(X)} h(X)$$

donde los $t_i(X)$ son funciones de X , no de θ , y $Q_i(\theta)$ son funciones solo de θ . Entonces diremos que esta familia es de tipo exponencial.

Prop 2. Si f_θ se descompone como

$$f_\theta(X) = C(\theta) e^{\sum_{i=1}^k \theta_i t_i(X)} h(X)$$

donde $\theta = (\theta_1, \dots, \theta_k)$. Entonces $t(X) = (t_1(X), \dots, t_k(X))$ es un estadístico suficiente completo si Θ contiene un rectángulo k -dimensional.

Teo 3. (Cota de Cramer-Rao) Supongamos que la familia $\{P_\theta | \theta \in \Theta\}$ posee densidades $f_\theta(X)$ derivables. Consideremos una función $g(\theta)$ del parámetro $\theta \in \Theta \subseteq \mathbb{R}$ (g derivable). Si $\hat{g}(X)$ es un estimador insesgado de $g(\theta)$, entonces

$$\text{Var}_\theta(\hat{g}(X)) \geq \frac{(g'(\theta))^2}{I_\theta}$$

con I_θ la información de Fisher: $I_\theta = E_\theta \left(\left(\frac{\partial \log f_\theta(X)}{\partial \theta} \right)^2 \right)$. Bajo regularidad se tiene $I_\theta = -E_\theta \left(\frac{\partial^2 \log f_\theta(X)}{\partial \theta^2} \right)$. Todo estimador de Cramer-Rao es EIVUM, pero no todo EIVUM alcanza la cota de Cramer-Rao.

Def 10. (Función de verosimilitud) Consideremos la familia $\{P_\theta | \theta \in \Theta\}$ con densidades $f_\theta(X)$. La función de verosimilitud se define como

$$L : \Theta \longrightarrow \mathbb{R}^+$$

$$\theta \longrightarrow f_\theta(x) \quad \text{con } x \in \mathbb{X} \text{ fijo.}$$

Def 11. (EMV) Un estimador de máxima verosimilitud $\hat{\theta}$ es un elemento de Θ tal que

$$f_{\hat{\theta}(x)}(x) = \sup_{\theta \in \Theta} f_\theta(x) \quad \forall x.$$

Obs. Para maximizar es útil aplicar logaritmo y luego derivar, en caso que se pueda.

Algunas propiedades del EMV son:

- (1) Los EMV no son insesgados en general, pero en algunos casos se puede corregir el sesgo.
- (2) El EMV no es único.
- (3) Bajo regularidad, el EMV es asintóticamente insesgado, es decir, si $\hat{\theta}_n$ es el EMV de θ , entonces $E_\theta(\hat{\theta}_n) \longrightarrow \theta$.
- (4) Bajo regularidad, la convergencia fuerte (débil) significa que la sucesión de v.a. $\hat{\theta}_n$ converge c.s. (y en probabilidad) a θ .
- (5) Bajo regularidad, en algunos casos es posible mostrar que $\hat{\theta}_n$ (EMV) es asintóticamente normal, es decir,

$$\frac{\hat{\theta}_n - \theta}{\sqrt{I_\theta^{-1}}} \longrightarrow \mathcal{N}(0, 1).$$

- (6) El EMV suele ser asintóticamente eficiente. La eficiencia se define como

$$ef_\theta(\hat{\theta}_n) = \frac{I_\theta^{-1}}{\text{Var}_\theta(\hat{\theta}_n)} \leq 1.$$

Se dice que $\hat{\theta}_n$ es asintóticamente eficiente si $ef_\theta(\hat{\theta}_n) \longrightarrow 1$.

- (7) El EMV es función de cualquier estadístico suficiente, pues cumple el teorema de factorización: $f_\theta(X) = g_\theta(T(X))h(X)$.

2. Intervalos de confianza

Se desea estimar una función del parámetro mediante un conjunto de valores plausibles (conjunto de confianza).

Def 12. (Intervalo de confianza) Sea $\{P_\theta | \theta \in \Theta\}$ una familia paramétrica y $g(\theta)$ función del parámetro. Buscamos un conjunto $S(X)$ tal que $g(\theta) \in S(X)$ con cierta confianza, es decir

$$P_\theta[g(\theta) \in S(X)] \geq 1 - \alpha, \quad \forall \theta \in \Theta.$$

Diremos que $S(X)$ es una región de confianza con nivel $1 - \alpha$ para $g(\theta)$, con $\alpha \in [0, 1]$. En el caso en que $g(\theta) \in \mathbb{R}$, $S(X)$ son intervalos acotados $S(X) = [L(X), R(X)]$ tales que

$$P_\theta[L(X) \leq g(\theta) \leq R(X)] \geq 1 - \alpha, \quad \forall \theta \in \Theta.$$

Def 13. (Pivote) Un pivote es una función $T : \mathbb{X} \times \Theta \longrightarrow \mathbb{R}$ medible tal que

- (1) La ley de $T(X, \theta)$ no depende de θ .
- (2) $T(X, \theta)$ es función monótona de $g(\theta)$.

Pivotes importantes para intervalos de confianza

Si (X_1, \dots, X_n) son i.i.d. $\mathcal{N}(\mu, \sigma^2)$, entonces

- σ conocido: $T(X, \mu) = \frac{\bar{X}_n - \mu}{\sigma/\sqrt{n}} \sim \mathcal{N}(0, 1)$, pivote para $g(\mu) = \mu$.
- σ desconocido: $T(X, \theta) = \frac{\bar{X}_n - \mu}{\hat{\sigma}/\sqrt{n}} \sim t(n - 1)$, pivote para $g(\theta) = \mu$.
- μ conocido: $T(X, \sigma) = \sum_{i=1}^n \frac{(X_i - \mu)^2}{\sigma^2} \sim \chi^2(n)$, pivote para $g(\sigma) = \sigma^2$.
- μ desconocido: $T(X, \theta) = \sum_{i=1}^n \frac{(X_i - \bar{X}_n)^2}{\sigma^2} \sim \chi^2(n - 1)$, pivote para $g(\theta) = \sigma^2$.

Si (X_1, \dots, X_n) i.i.d. uniforme en $[0, \theta]$, entonces

$$T(X, \theta) = \frac{\max\{X_1, \dots, X_n\}}{\theta}$$

es pivote para θ , pues $\frac{X_i}{\theta} \sim U[0, 1]$.

3. Estadística Bayesiana

Tenemos un parámetro θ que vive en el espacio Θ y observamos un vector X con valores en \mathbb{X} . La familia de probabilidades está caracterizada por una familia de densidades condicionales $\{f(X|\theta) : \theta \in \Theta\}$.

Def 21. (Densidad a priori y posteriori) Definimos la densidad $\pi(\theta)$ como la densidad a priori, que corresponde a la opinión que se tiene del parámetro antes de observar X . Entonces se define una probabilidad en $\mathbb{X} \times \Theta$ a través de

$$f(X, \theta) = f(X|\theta)\pi(\theta).$$

Definimos la densidad a posteriori como

$$f(\theta|X) = \frac{f(X|\theta)\pi(\theta)}{f(X)} = \frac{f(X|\theta)\pi(\theta)}{\int_{\Theta} f(X|\theta)\pi(\theta)d\theta}$$

que corresponde a la opinión que se tiene sobre el parámetro después de observar X . Los parámetros de la ley a priori se llaman hiperparámetros.

Def 22. (Estimador MAP) En la estimación Bayesiana, se busca el estimador de $g(\theta)$ con mayor densidad a posteriori. Entonces, se define el estimador máximo a posteriori de θ como

$$\hat{\theta}_{MAP}(X) \in \operatorname{argmax}_{\theta \in \Theta} f(\theta|X).$$

También definimos la esperanza a posteriori como

$$\hat{\theta}_B(X) = \int \theta f(\theta|X) d\theta = E(\theta|X).$$

Def 23. (Conjugadas) Sea $\{f(X|\theta) : \theta \in \Theta\}$ familia paramétrica y P familia de densidades a priori. Se dice que ambas familias están conjugadas si para todo $\pi \in P$ se tiene que $f(\theta|X) \in P$.

Def 24. (Densidad impropia) Sea $\pi(\theta)$ densidad a priori, decimos que es impropia si $\int_{\Theta} \pi(\theta) d\theta \neq 1$. Solo se puede suponer que $\pi(\theta) \geq 0$.

Def 25. (Densidad no informativa) Sea $\pi(\theta)$ densidad a priori, decimos que no es informativa si es igual para todo $\theta \in \Theta$.

Def 26. (Error cuadrático medio) Sea g una función a valores reales y \tilde{g} . Se redefine el error cuadrático medio como

$$\text{ecm}_\theta(\tilde{g}) = \int_{\mathbb{X}} (\tilde{g}(x) - g(\theta))^2 f(x|\theta) dx.$$

Si \hat{g} es óptimo, entonces tiene menor ecm_θ .

Cuadro 1: Resumen distribuciones

nombre	parámetros	notación	tipo	soporte	distribución	esperanza	varianza	f.g.m.
Bernoulli	$p \in (0, 1)$	$X \sim \text{Bernoulli}(p)$	discreta	$\{0, 1\}$	$p_X(0) = 1 - p$ $p_X(1) = p$	p	$p(1 - p)$	$1 - p + pe^t$
binomial	$n \in \mathbb{N}^*$, $p \in (0, 1)$	$X \sim \text{bin}(n, p)$	discreta	$\{0, 1, \dots, n\}$	$p_X(k) = \binom{n}{k} p^k (1 - p)^{n-k}$	np	$np(1 - p)$	$(1 - p + pe^t)^n$
geométrica	$p \in (0, 1)$	$X \sim \text{geom}(p)$	discreta	$\{1, 2, 3, \dots\}$	$p_X(k) = (1 - p)^{k-1} p$	$\frac{1}{p}$	$\frac{1 - p}{p^2}$	$\frac{pe^t}{1 - (1 - p)e^t}$
binomial negativa	$r \in \mathbb{N}^*$, $p \in (0, 1)$	$X \sim \text{BN}(r, p)$	discreta	$\{r, r + 1, \dots\}$	$p_X(k) = \binom{k-1}{r-1} (1 - p)^{k-r} p^r$	$\frac{r}{p}$	$\frac{r(1 - p)}{p^2}$	$\left(\frac{pe^t}{1 - (1 - p)e^t} \right)^r$
Poisson	$\lambda > 0$	$X \sim \text{Poisson}(\lambda)$	discreta	$\{0, 1, 2, \dots\}$	$p_X(k) = e^{-\lambda} \frac{\lambda^k}{k!}$	λ	λ	$e^{\lambda(e^t - 1)}$
uniforme	$a, b \in \mathbb{R}$, $a < b$	$X \sim \text{unif}(a, b)$	continua	$[a, b]$	$f_X(x) = \frac{1}{b - a} \mathbb{1}_{[a, b]}(x)$	$\frac{a + b}{2}$	$\frac{(b - a)^2}{12}$	$\frac{e^{tb} - e^{ta}}{t(b - a)}$
exponencial	$\lambda > 0$	$X \sim \text{exp}(\lambda)$	continua	$[0, \infty)$	$f_X(x) = \lambda e^{-\lambda x} \mathbb{1}_{[0, \infty)}(x)$	$\frac{1}{\lambda}$	$\frac{1}{\lambda^2}$	$\frac{\lambda}{\lambda - t} \forall t < \lambda$
normal	$\mu \in \mathbb{R}$, $\sigma > 0$	$X \sim \mathcal{N}(\mu, \sigma^2)$	continua	\mathbb{R}	$f_X(x) = \frac{1}{\sqrt{2\pi}\sigma} e^{-\frac{(x-\mu)^2}{2\sigma^2}}$	μ	σ^2	$e^{\mu t + \frac{1}{2}\sigma^2 t^2}$
gamma	$\theta > 0$, $\lambda > 0$	$X \sim \text{gamma}(\theta, \lambda)$	continua	$[0, \infty)$	$f_X(x) = \frac{\lambda e^{-\lambda x} (\lambda x)^{\theta-1}}{\Gamma(\theta)} \mathbb{1}_{[0, \infty)}(x)$	$\frac{\theta}{\lambda}$	$\frac{\theta}{\lambda^2}$	$\left(\frac{\lambda}{\lambda - t} \right)^\theta \forall t < \lambda$