

# TÉCNICAS BAYESIANAS

Juan Carlos Flores López y Marisol Paredes

## Elementos de Teoría Bayesiana

Se asume las observaciones  $x = (x_1, \dots, x_n)$  han sido generados de una distribución de probabilidad  $f(x/\theta)$ , tal que el parámetro  $\theta$  es desconocido y la función  $f$  es conocida. Este modelo es representado por  $x \sim f(x/\theta)$ , donde  $x$  puede ser un vector, lo mismo que  $\theta$ .

## Distribución a priori

Consideremos un problema de inferencia estadística en el que se van a seleccionar observaciones de una distribución cuya función de probabilidad es  $f(x/\theta)$ , donde  $\theta$  es un parámetro de valor desconocido. Se supone que el valor desconocido del parámetro  $\theta$  debe pertenecer a un espacio paramétrico  $\Omega$ . Lo que se pretende es el de intentar determinar donde es probable que se encuentre el verdadero de  $\theta$  en el espacio paramétrico  $\Omega$ , partiendo de las observaciones de la densidad  $f(x/\theta)$ . Esta distribución se denomina *distribución a priori* de  $\theta$ , que se denota por  $\pi(\theta)$

## Distribución posteriori

Supongamos que  $x = (x_1, \dots, x_n)$  constituyen una muestra, donde los  $x_i$  son independientes e idénticamente distribuidas (i.i.d.), de una distribución cuya densidad es  $f(x/\theta)$ . Luego:

$$f(x/\theta) = \prod_{i=1}^n f(x_i/\theta) = L(\theta/x)$$

Cuando la función de densidad conjunta  $f(x/\theta)$  de las observaciones, donde los  $x_i$  son i.i.d, se considera con una función de  $\theta$ , para valores dados de  $x_1, \dots, x_n$ , se llama de verosimilitud y la demostraremos por  $L(\theta/x)$ . Asumimos, en resumen, para la distribución muestral  $f(x/\theta)$ , una distribución inicial en  $\theta$  y que  $\pi(\theta)$  esta disponible. Dado lo anterior, podemos construir diferentes distribuciones, llamadas:

(a) la distribución conjunta de  $(x, \theta)$

$$f(x, \theta) = f(x/\theta)\pi(\theta)$$

(b) la distribución marginal de  $x$ , también llamada la distribución predictiva

$$m(x) = \int f(x, \theta) d\theta$$

$$= \int f(x/\theta)\pi(\theta) d\theta$$

(c) la distribución posterior de  $\theta$ , obtenida por la formula de Bayes

$$\pi(\theta/x) = \frac{f(x/\theta)\pi(\theta)}{\int f(x/\theta)\pi(\theta) d\theta} = \frac{f(x/\theta)\pi(\theta)}{m(x)}$$

notemos que  $\pi(\theta/x)$  es proporcional a la distribución de  $x$  condicional en  $\theta$ , es decir la función de verosimilitud, multiplicada por la distribución a priori de  $\theta$ , ya que el denominador de  $m(x)$  no depende de  $\theta$ , puede ser considerado como una constante, así tenemos:

$$\pi(\theta/x) \propto f(x/\theta)\pi(\theta)$$

esta simple expresión encierra el núcleo de la inferencia Bayesiana.

## Principio de invarianza de Jeffreys

Esta introducción introducida por Jeffreys, esta basada en considerar transformaciones uno a uno del parámetro  $\theta$ , es decir una función del parámetro  $\theta$  llamada  $\phi: \phi = h(\theta)$ . Si realizamos transformaciones de variables, la densidad a priori  $\pi(\theta)$  es equivalente, en términos de expresar la misma confianza, a la siguiente densidad a priori en  $\phi$ :

$$\pi(\phi) = \pi(\theta) \left| \frac{d\theta}{d\phi} \right| = \pi(\theta) |h'(\theta)|^{-1}$$

**Definición.-** Una familia  $F$  de distribuciones de probabilidad en  $\Theta$  se dice que es conjugada (o cerrada bajo muestreo) si, para cada  $\pi \in F$ , la distribución posteriori  $\pi(\theta/x)$  también pertenece a  $F$ .

Modelo normal con varianza conocida

Dada la importancia de la distribución normal en el desarrollo de la inferencia, es necesario mostrar desde el punto de vista bayesiano. Dado  $x = (x_1, \dots, x_n)$  una muestra, (i.i.d.) de una distribución normal con media  $\theta$  desconocida, pero con varianza  $\sigma^2$  conocida, la distribución conjugada de  $\theta$  es la distribución normal. Luego sea  $\pi(\theta) \sim N(\mu_0, \tau_0^2)$  donde  $\mu_0$  y  $\tau_0^2$  están dados. Luego la distribución posterior también es normal, y tiene como media y varianza

$$\mu_n = \frac{\frac{1}{\tau_0^2} \mu_0 + \frac{n}{\sigma^2} \bar{x}}{\frac{1}{\tau_0^2} + \frac{n}{\sigma^2}} \quad \text{y} \quad \frac{1}{\tau_n^2} = \frac{1}{\tau_0^2} + \frac{n}{\sigma^2}$$

por otro lado la distribución normal multivariante esta dado por

$$f(x) = (2\pi)^{-k/2} |\Sigma|^{-1/2} \exp\left(-\frac{1}{2} (x - \theta)' \Sigma^{-1} (x - \theta)\right)$$

y la función de verosimilitud para una muestra de  $n$  observaciones i.i.d. de  $x_i, x_1, \dots, x_n, i = 1, 2, \dots, k$ , es:

$$\begin{aligned} f(x/\theta, \Sigma) &= \prod_{r=1}^n (2\pi)^{-k/2} |\Sigma|^{-1/2} \exp\left(-\frac{1}{2} (x_r - \theta)' \Sigma^{-1} (x_r - \theta)\right) \\ &= (2\pi)^{-nk/2} |\Sigma|^{-n/2} \exp\left(-\frac{1}{2} \sum_{r=1}^n (x_r - \theta)' \Sigma^{-1} (x_r - \theta)\right) \end{aligned}$$

como  $\sum_{r=1}^n (x_r - \theta)' \Sigma^{-1} (x_r - \theta)$  es un escalar, tomando la traza y por propiedad de esta ultima, lo anterior se convierte en:

$$= |\Sigma|^{-n/2} \exp\left(-\frac{1}{2} \text{tr}(\Sigma^{-1} S)\right)$$

donde  $S_{k \times k}$  es la matriz de "suma de cuadrados" relativo a  $\theta$ .

$$S_{k \times k} = \sum_{r=1}^n (x_r - \theta)(x_r - \theta)'$$

**Definición.-** un modelo jerárquico de Bayes es un modelo estocástico Bayesiano  $(f(x/\theta), \pi(\theta))$ , donde la distribución a priori  $\pi(\theta)$  esta descompuesta en distribuciones condicionales:

$$\pi_1(\theta_1/\theta_0), \pi_2(\theta_2/\theta_1), \dots, \pi_n(\theta_n/\theta_{n-1})$$

y una distribución marginal  $\pi_{n+1}(\theta_n)$  tal que:

$$\pi(\theta) = \int_{\Theta_1 \times \dots \times \Theta_n} \pi_1(\theta_1/\theta_0) \pi_2(\theta_2/\theta_1) \dots \pi_n(\theta_n/\theta_{n-1}) d\theta_1 \dots d\theta_n$$

los parámetros  $\theta_i$  son llamados hiperparámetros de nivel  $i$ .