

CAPÍTULO 7. ESTIMACIÓN Y CONTRASTES

Para leer

Lee, Capítulo 4

Estimación puntual

Para los bayesianos, el problema de estimación es un problema de decisión. Asociada con cada estimador T hay una pérdida $L(T, \theta)$ que refleja la diferencia entre θ y T . Por ejemplo:

- $L(T, \theta) = (T - \theta)^2$, la pérdida cuadrática
- $L(T, \theta) = |T - \theta|$, la pérdida lineal absoluta
- $L(T, \theta) = \begin{cases} 0 & \text{si } T = \theta \\ 1 & \text{si } T \neq \theta \end{cases}$, la pérdida “todo o nada”.

Definición 9 El estimador Bayes T^B es una solución de

$$T^B = \underset{T}{\text{mín}} E[L(T, \theta)]$$

Ejemplo 48 Dada la pérdida cuadrática, ¿cuál es el estimador Bayes?

$$\begin{aligned} E[L(T, \theta)] &= \int (T - \theta)^2 f(\theta) d\theta \\ &= \int (T - E[\theta] + E[\theta] - \theta)^2 f(\theta) d\theta \\ &= \int \{(T - E[\theta])^2 + (E[\theta] - \theta)^2\} f(\theta) d\theta \\ &= V[\theta] + (T - E[\theta])^2 \end{aligned}$$

y entonces $T^B = E[\theta]$ es el estimador Bayes.

Ejemplo 49 Con la pérdida lineal absoluta, tenemos

$$\begin{aligned}
 E[L(T, \theta)] &= \int |T - \theta| f(\theta) d\theta \\
 &= \int_{-\infty}^T (T - \theta) f(\theta) d\theta + \\
 &\quad + \int_T^{\infty} (\theta - T) f(\theta) d\theta \\
 \frac{d}{dT} E[L(T|\theta)] &= (T - T) f(T) + \int_{-\infty}^T f(\theta) d\theta - \\
 &\quad - (T - T) f(T) - \int_T^{\infty} f(\theta) d\theta \\
 &= F(T) - (1 - F(T)) \\
 &= 2F(T) - 1
 \end{aligned}$$

Entonces, recordando que en el mínimo la derivada es igual a cero, tenemos $F(T^B) = 1/2$ y el estimador Bayes es la mediana de la distribución de θ .

Ejemplo 50 Suponiendo que θ es discreta, con la pérdida “todo o nada” se tiene

$$\begin{aligned} E[L(T, \theta)] &= \sum_{\theta \neq T} P(\theta) \\ &= P(\theta \neq T) \end{aligned}$$

y se minimiza la pérdida esperada eligiendo el estimador Bayes T^B como la moda de la distribución de θ .

Observación 21 Esta pérdida no se puede utilizar con variables continuas porque $P(\theta = T) = 0$ si θ es continua y entonces, la pérdida esperada será 1 para cualquier elección de T .

Intervalos

Se han visto intervalos de credibilidad anteriormente. Sigue la definición formal.

Definición 10 Si $f(\theta|\mathbf{x})$ es una densidad a posteriori, se dice que (a, b) es **un intervalo de credibilidad** de $100 \times (1 - \alpha) \%$ si

$$P(a \leq \theta \leq b|\mathbf{x}) = 1 - \alpha$$

Ejemplo 51 $X|\mu \sim \mathcal{N}(\mu, 1)$. Supongamos que $f(\mu) \propto 1$, entonces, $\mu|\mathbf{x} \sim \mathcal{N}(\bar{x}, 1/n)$ y algunos intervalos de credibilidad de 95 % son

$$(-\infty, \bar{x} + 1,64/\sqrt{n}) \quad \text{o} \quad (\bar{x} - 1,64/\sqrt{n}, \infty) \quad \text{o} \\ (\bar{x} \pm 1,96/\sqrt{n})$$

Hay muchos intervalos de credibilidad. El más corto se llama **un intervalo de máxima densidad a posteriori (MDP)**

Definición 11 *El intervalo MDP de $100 \times (1 - \alpha)$ % es el intervalo de forma*

$$C = \{\theta : f(\theta) \geq c(\alpha)\}$$

donde $c(\cdot)$ es la constante más grande cumpliendo

$$P(C) \geq 1 - \alpha$$

Ejemplo 52 *Volviendo al ejemplo 51, el intervalo MDP de 95 % es*

$$\bar{x} \pm 1,96/\sqrt{n}$$

Se puede aplicar la definición de un intervalo de credibilidad a densidades multivariantes $f(\boldsymbol{\theta}|\mathbf{x})$. En estas situaciones, se puede definir una región de credibilidad \mathbf{C} :

$$P(\boldsymbol{\theta} \in \mathbf{C}|\mathbf{x}) = 1 - \alpha.$$

Contrastes

Consideramos las hipótesis $H_0 : \theta \in \Theta_0$, donde $H_1 : \theta \in \Theta_1$, donde $\Theta_0 \cup \Theta_1 = \Theta$ y $\Theta_0 \cap \Theta_1 = \phi$.

Teóricamente es fácil distinguir entre las dos hipótesis; dados los datos, sólo se deben usar las probabilidades a posteriori. Dada una función de pérdida, se elige aceptar o rechazar H_0 .

Ejemplo 53 *Dada la pérdida “todo o nada” ,*

$$L(H_0, \theta) = \begin{cases} 0 & \text{si } H_0 \text{ es verdadero} \\ 1 & \text{si } H_1 \text{ es verdadero} \end{cases}$$

elegimos H_0 si $P(H_0|\mathbf{x}) > P(H_1|\mathbf{x})$.

Ejemplo 54 Supongamos que $X|\theta \sim N(\theta, 1)$. Queremos hacer el contraste: $H_0 : \theta \leq 0$ frente $H_1 : \theta > 0$. Si usamos una distribución inicial no informativa para θ ,

$$f(\theta) \propto 1,$$

tenemos $\theta|\mathbf{x} \sim \mathcal{N}\left(\bar{x}, \frac{1}{n}\right)$. Entonces,

$$\begin{aligned} P(H_0|\mathbf{x}) &= P(\theta \leq 0|\mathbf{x}) \\ &= P\left(\sqrt{n}(\theta - \bar{x}) \leq -\sqrt{n}\bar{x}|\mathbf{x}\right) \\ &= \Phi\left(-\sqrt{n}\bar{x}\right) \end{aligned}$$

donde $\Phi(\cdot)$ es la función de distribución normal.

Observación 22 Esta probabilidad es igual al p valor clásico para el contraste $H_0^c : \theta = 0$ frente $H_1 : \theta > 0$.

$$\begin{aligned} P(\bar{X} \geq \bar{x}|H_0) &= P\left(\sqrt{n}\bar{X} \geq \sqrt{n}\bar{x}|H_0\right) \\ &= 1 - \Phi\left(\sqrt{n}\bar{x}\right) \\ &= \Phi\left(-\sqrt{n}\bar{x}\right) \end{aligned}$$

La paradoja de Lindley/Jeffreys

Consideramos el contraste $H_0 : \theta = \theta_0$ frente la alternativa $H_1 : \theta \neq \theta_0$. En situaciones así, los resultados bayesianos pueden ser muy diferentes de los resultados clásicos.

Ejemplo 55 $X|\theta \sim \mathcal{N}(\theta, 1)$. Hacemos el contraste $H_0 : \theta = 0$ frente $H_1 : \theta \neq 0$.

Se definen las probabilidades a priori

$$f_0 = P(H_0) = 0,5 = P(H_1) = f_1$$

y se supone que $\theta|H_1 \sim \mathcal{N}(0, 1)$.

Suponiendo que se observa la media de una muestra de tamaño n , se quiere calcular las probabilidades a posteriori.

En primer lugar

$$\begin{aligned}\alpha_0 &= P(H_0|\bar{x}) \\ &\propto f_0 f(\bar{x}|\theta = 0) \\ &\propto \frac{1}{2} \left(\frac{n}{2\pi}\right)^{\frac{1}{2}} \exp\left(-\frac{n\bar{x}^2}{2}\right) \\ &= \frac{K}{2} \left(\frac{n}{2\pi}\right)^{\frac{1}{2}} \exp\left(-\frac{n\bar{x}^2}{2}\right)\end{aligned}$$

para una constante $K = f(\bar{x})$. También

$$\begin{aligned}f(\theta, H_1|\mathbf{x}) &\propto f_1 f(\bar{x}|\theta, H_1) f(\theta|H_1) \\ &\propto \frac{1}{2} \left(\frac{n}{2\pi}\right)^{\frac{1}{2}} \exp\left(-\frac{n(\bar{x} - \theta)^2}{2}\right) \times \\ &\quad \times \left(\frac{1}{2\pi}\right)^{\frac{1}{2}} \exp\left(-\frac{\theta^2}{2}\right) \\ &= \frac{K}{2} \left(\frac{n}{2\pi}\right)^{\frac{1}{2}} \left(\frac{1}{2\pi}\right)^{\frac{1}{2}} \times \\ &\quad \times \exp\left(-\frac{1}{2} [n(\bar{x} - \theta)^2 + \theta^2]\right)\end{aligned}$$

donde K es la misma constante.

Entonces, se tiene

$$\begin{aligned}
 \alpha_1 &= P(H_1|\mathbf{x}) \\
 &= \int f(\theta, H_1|\mathbf{x}) d\theta \\
 &= \int \frac{K}{2} \left(\frac{n}{2\pi}\right)^{\frac{1}{2}} \left(\frac{1}{2\pi}\right)^{\frac{1}{2}} \exp\left(-\frac{1}{2} [n(\bar{x} - \theta)^2 + \theta^2]\right) d\theta \\
 &= \frac{K}{2} \left(\frac{n}{2\pi}\right)^{\frac{1}{2}} \left(\frac{1}{2\pi}\right)^{\frac{1}{2}} \times \\
 &\quad \int \exp\left(-\frac{1}{2} \left[(n+1) \left(\theta - \frac{n\bar{x}}{n+1}\right)^2 - \frac{n\bar{x}^2}{n+1} \right]\right) d\theta \\
 &= \frac{K}{2} \left(\frac{n}{2\pi}\right)^{\frac{1}{2}} \frac{1}{\sqrt{n+1}} \exp\left(-\frac{n\bar{x}^2}{2(n+1)}\right)
 \end{aligned}$$

Recordando que $\alpha_0 + \alpha_1 = 1$, se tiene

$$K = \left(\frac{1}{2} \left(\frac{n}{2\pi}\right)^{\frac{1}{2}} \exp\left(-\frac{n\bar{x}^2}{2}\right) + \frac{1}{2} \left(\frac{n}{2\pi}\right)^{\frac{1}{2}} \frac{1}{\sqrt{n+1}} \exp\left(-\frac{n\bar{x}^2}{2(n+1)}\right) \right)^{-1}.$$

Entonces

$$\begin{aligned}
 \alpha_0 &= \frac{\frac{1}{2} \left(\frac{n}{2\pi}\right)^{\frac{1}{2}} \exp\left(-\frac{n\bar{x}^2}{2}\right)}{\frac{1}{2} \left(\frac{n}{2\pi}\right)^{\frac{1}{2}} \exp\left(-\frac{n\bar{x}^2}{2}\right) + \frac{1}{2} \left(\frac{n}{2\pi}\right)^{\frac{1}{2}} \frac{1}{\sqrt{n+1}} \exp\left(-\frac{n\bar{x}^2}{2(n+1)}\right)} \\
 &= \frac{\exp\left(-\frac{n\bar{x}^2}{2}\right)}{\exp\left(-\frac{n\bar{x}^2}{2}\right) + \frac{1}{\sqrt{n+1}} \exp\left(-\frac{n\bar{x}^2}{2(n+1)}\right)} \\
 &= \frac{\exp\left(-\frac{n(n+1)\bar{x}^2}{2(n+1)}\right)}{\exp\left(-\frac{n(n+1)\bar{x}^2}{2(n+1)}\right) + \frac{1}{\sqrt{n+1}} \exp\left(-\frac{n\bar{x}^2}{2(n+1)}\right)} \\
 &= \left\{ 1 + \frac{1}{\sqrt{n+1}} \exp\left(\frac{n^2\bar{x}^2}{2(n+1)}\right) \right\}^{-1}
 \end{aligned}$$

Consideramos el caso $\bar{x} = 2/\sqrt{n} > 1,96/\sqrt{n}$. Sabemos que si hubiéramos hecho un contraste clásico con un nivel de significación de 95 %, el resultado habría sido significativo, y habríamos rechazado la hipótesis H_0 .

$$\begin{aligned}
 \text{Pero } \alpha_0 &= \left\{ 1 + \frac{1}{\sqrt{n+1}} \exp\left(\frac{n}{n+1}\right) \right\}^{-1} \\
 &\rightarrow 1 \quad \text{cuando } n \rightarrow \infty.
 \end{aligned}$$

Una muestra que nos llega a rechazar H_0 con un contraste clásico nos proporciona una probabilidad a posteriori de H_0 que se acerca a 1 cuando el tamaño de la muestra es grande.

Esta paradoja se llama la paradoja de Lindley y Jeffreys.

Observación 23 *La elección de la varianza de θ en la distribución inicial es bastante importante pero el ejemplo demuestra que no tiene sentido usar niveles fijos de significación según crece n .*

Hipótesis nulos puntuales son poco razonables.

Factores Bayes

También es útil introducir otro concepto.

Supongamos que $f_0 = P(H_0)$ y $f_1 = P(H_1)$ y que $\alpha_0 = P(H_0|\mathbf{x})$ y $\alpha_1 = P(H_1|\mathbf{x})$.

Definición 12 *Se define*

$$B = \frac{\alpha_0/\alpha_1}{f_0/f_1} = \frac{\alpha_0 f_1}{\alpha_1 f_0}$$

el factor Bayes a favor de H_0 .

Observación 24 *El factor Bayes representa las posibilidades (odds) a posteriori divididos por las posibilidades a priori. Nos informe de los cambios en nuestras creencias causados por los datos.*

Observación 25 *Es casi objetiva y parcialmente elimina la influencia de la distribución a priori.*

Ejemplo 56 *Supongamos el contraste simple $H_0 : \theta = \theta_0$ frente $H_1 : \theta = \theta_1$. Tenemos*

$$\alpha_0 = P(H_0|\mathbf{x}) = \frac{f_0 l(\theta_0|\mathbf{x})}{f_0 l(\theta_0|\mathbf{x}) + f_1 l(\theta_1|\mathbf{x})}$$

$$\alpha_1 = P(H_1|\mathbf{x}) = \frac{f_1 l(\theta_1|\mathbf{x})}{f_0 l(\theta_0|\mathbf{x}) + f_1 l(\theta_1|\mathbf{x})}$$

Entonces el factor Bayes es

$$\begin{aligned} B &= \frac{\alpha_0 f_1}{\alpha_1 f_0} \\ &= \frac{f_0 l(\mathbf{x}|\theta_0) f_1}{f_1 l(\mathbf{x}|\theta_1) f_0} \\ &= \frac{l(\theta_0|\mathbf{x})}{l(\theta_1|\mathbf{x})} \end{aligned}$$

que coincide con la razón de verosimilitudes. Entonces, la distribución a priori no influye en el factor Bayes.

Ejemplo 57 *Se observa un dato de una distribución exponencial con densidad*

$$f(x|\lambda) = \lambda e^{-\lambda x}.$$

Se quiere contrastar $H_0 : \lambda = 6$ frente $H_1 : \lambda = 3$. ¿Cuál es el factor Bayes?

$$\begin{aligned} B &= \frac{l(\lambda = 6|x)}{l(\lambda = 3|x)} \\ &= \frac{6e^{-6x}}{3e^{-3x}} \\ &= 2e^{-3x} \end{aligned}$$

Suponiendo que la probabilidad a priori de H_0 es 0,25, se puede demostrar que $P(H_0|x) < 0,5$ para cualquier valor de x .

En primer lugar, hallamos el factor Bayes.

$$\begin{aligned}
 B &= \frac{P(H_0|x) P(H_1)}{P(H_1|x) P(H_0)} \\
 &= 3 \frac{P(H_0|x)}{P(H_1|x)}
 \end{aligned}$$

$$\frac{P(H_0|x)}{P(H_1|x)} = \frac{2}{3} e^{-3x}$$

y $P(H_0|x) \geq 1/2 \Rightarrow \frac{2}{3} e^{-3x} > 1$ y entonces

$$x < -\frac{1}{3} \log \frac{3}{2} < 0$$

que es imposible.

Observación 26 *El factor Bayes es consistente.*

Si H_0 es verdadero, entonces $B \rightarrow \infty$ cuando $n \rightarrow \infty$ y si H_1 es verdadero, $B \rightarrow 0$ cuando $n \rightarrow \infty$.

El factor Bayes no elimina totalmente la influencia de la distribución a priori. Supongamos que H_0 y H_1 son compuestos y entonces

$$\begin{aligned} B &= \frac{P(H_0|\mathbf{x})P(H_1)}{P(H_1|\mathbf{x})P(H_0)} \\ &= \frac{f(\mathbf{x}|H_0)}{f(\mathbf{x}|H_1)} \\ &= \frac{\int f(\mathbf{x}|H_0, \theta_0)f(\theta_0|H_0) d\theta_0}{\int f(\mathbf{x}|H_1, \theta_1)f(\theta_1|H_1) d\theta_1} \end{aligned}$$

donde $f(\theta_0|H_0)$ es la distribución a priori bajo la hipótesis H_0 y $f(\theta_1|H_1)$ es la distribución a priori bajo H_1 .

Ejemplo 58 Supongamos que $X|\lambda \sim \mathcal{E}(\lambda)$ como en el Ejemplo 57. Ahora se quiere contrastar $H_0 : \lambda = 6$ frente a $H_1 : \lambda \neq 6$. Sea la distribución a priori $\lambda|H_1 \sim \mathcal{E}(1/6)$.

Suponiendo que se observa un dato x como anteriormente, se tiene

$$f(x|H_0) = 6e^{-6x}$$

y

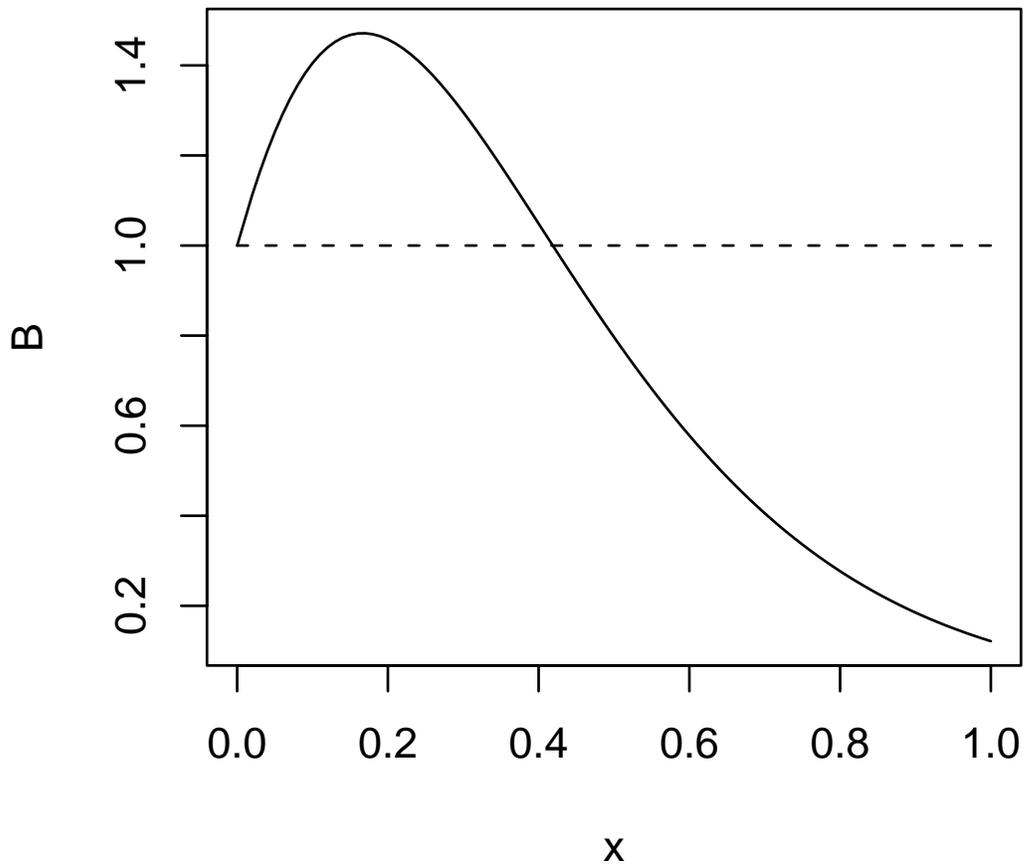
$$\begin{aligned} f(x|H_1) &= \int f(x|H_1, \lambda) f(\lambda|H_1) d\lambda \\ &= \int \lambda e^{-\lambda x} \frac{1}{6} e^{-\frac{1}{6}\lambda} d\lambda \\ &= \frac{1}{6} \int \lambda e^{-\left(x + \frac{1}{6}\right)\lambda} d\lambda \\ &= \frac{1}{6} \int \lambda^{2-1} e^{-\left(x + \frac{1}{6}\right)\lambda} d\lambda \\ &= \frac{1}{6} \frac{\Gamma(2)}{\left(x + \frac{1}{6}\right)^2} \\ &= \frac{6}{(6x + 1)^2} \end{aligned}$$

Entonces el factor Bayes es

$$B = (6x + 1)^2 e^{-6x}.$$

Supongamos ahora que las probabilidades a priori son $P(H_0) = P(H_1) = 0,5$. ¿Para cuáles valores de x es más probable H_0 a posteriori?

La probabilidad a posteriori de H_0 es mayor que 0,5 si $B > 1$. Construimos un gráfico del valor de B frente a x .



El modelo H_0 es más probable a posteriori si $x < 0,4188$ a 4 plazas decimales.

¿Cuál es el máximo valor posible de $P(H_0|x)$?

La probabilidad de H_0 es máxima cuando el factor Bayes es lo más grande posible. Calculamos el máximo del factor Bayes como función de x .

$$\begin{aligned} B &= (6x + 1)^2 e^{-6x} \\ \log B &= 2 \log(6x + 1) - 6x \\ \frac{d}{dx} \log B &= \frac{2}{6x + 1} - 6 \\ 0 &= \frac{2}{6\hat{x} + 1} - 6 \\ 36\hat{x} &= \frac{8}{2} \\ \hat{x} &= \frac{2}{9} \end{aligned}$$

y en este caso, el valor de B es

$$\hat{B} = \left(6 \times \frac{2}{9} + 1\right)^2 e^{-6 \times \frac{2}{9}} = 1,43514$$

Recordamos que

$$\begin{aligned}\hat{B} &= \frac{P(H_0|\hat{x}) P(H_1)}{P(H_1|\hat{x}) P(H_0)} \\ 1,43514 &= \frac{P(H_0|\hat{x})}{1 - P(H_0|\hat{x})} \\ P(H_0|x) &= \frac{1,43514}{1 + 1,43514} \\ &\approx 0,5893\end{aligned}$$

es el máximo valor posible de la probabilidad a posteriori.

Problemas y Generalizaciones

Si usamos distribuciones a priori impropias para los parámetros, puede que el factor Bayes no exista.

Volviendo a la situación de la transparencia , supongamos que $f(\theta_0|H_0)$ y $f(\theta_1|H_1)$ son impropias, por ejemplo

$$f(\theta_i|H_i) = c_i g_i(\theta_i)$$

para algunas constantes c_i indefinidas.

Luego

$$\begin{aligned} B &= \frac{\int f(\mathbf{x}|H_0, \theta_0) f(\theta_0|H_0) d\theta_0}{\int f(\mathbf{x}|H_1, \theta_1) f(\theta_1|H_1) d\theta_1} \\ &= \frac{c_1 \int f(\mathbf{x}|H_0, \theta_0) g_0(\theta_0) d\theta_0}{c_2 \int f(\mathbf{x}|H_1, \theta_1) g_1(\theta_1) d\theta_1} \end{aligned}$$

que depende de la razón de las constantes indefinidas.

Hay algunas alternativas

- factores Bayes fraccionales (O'Hagan, A. Bayesian Inference, Edward Arnold, 1995)
- factores Bayes intrínsecos (Berger J. y Pericchi L. The Intrinsic Bayes Factor for linear models. En Bayesian Statistics V, eds Bernardo et al, O.U.P., 23 – 42.)

Los dos métodos utilizan partes de los datos para crear una distribución inicial propia.