

## CAPÍTULO 6. MUESTRAS GRANDES

### Para leer

Bernardo y Smith (1994), Sección 5.3.

Gelman et al (1995), Capítulo 4, Secciones 4.1 – 4.3 y Apéndice B.

Si la muestra es muy grande, está claro que los valores de los parámetros de la distribución a priori suelen ser poco importantes.

**Ejemplo 83**  $X|\mu, \sigma^2 \sim \mathcal{N}(\mu, \sigma^2)$ . Supongamos una distribución inicial conjugada. Entonces, por ejemplo:

$$E[\mu|\mathbf{x}] = \frac{cm + n\bar{x}}{c + n} \rightarrow \bar{x}$$

cuando  $n \rightarrow \infty$ .

## El caso discreta

### Convergencia al verdadero valor de $\theta$

El siguiente teorema demuestra la convergencia de la distribución a posteriori en el caso de que  $\Theta$  sea discreta.

**Teorema 11** *Sea  $X|\theta \sim f(\cdot|\theta)$  donde el espacio  $\Theta = \{\theta_1, \theta_2, \dots\}$  es contable. Supongamos que  $\theta_v \in \Theta$  es el verdadero valor de  $\theta$ .*

*Sea la distribución a priori  $P(\theta)$  donde se tiene  $P(\theta_i) > 0 \forall i$  y supongamos que*

$$\int f(x|\theta_v) \log \frac{f(x|\theta_v)}{f(x|\theta_i)} dx > 0 \quad \forall i \neq v. \quad \text{Entonces}$$

$$\lim_{n \rightarrow \infty} P(\theta_v|\mathbf{x}) = 1 \quad \text{y} \quad \lim_{n \rightarrow \infty} P(\theta_i|\mathbf{x}) = 0 \quad \forall i \neq v.$$

## Demostración

Sea  $\mathbf{x} = (x_1, \dots, x_n)$ .

$$\begin{aligned} P(\boldsymbol{\theta}_i | \mathbf{x}) &= \frac{P(\boldsymbol{\theta}_i) f(\mathbf{x} | \boldsymbol{\theta}_i)}{\sum_i P(\boldsymbol{\theta}_i) f(\mathbf{x} | \boldsymbol{\theta}_i)} \\ &= \frac{P(\boldsymbol{\theta}_i) f(\mathbf{x} | \boldsymbol{\theta}_i) / f(\mathbf{x} | \boldsymbol{\theta}_v)}{\sum_i P(\boldsymbol{\theta}_i) f(\mathbf{x} | \boldsymbol{\theta}_i) / f(\mathbf{x} | \boldsymbol{\theta}_v)} \\ &= \frac{\exp(\log P(\boldsymbol{\theta}_i) + S_i)}{\sum_i \exp(\log P(\boldsymbol{\theta}_i) + S_i)} \end{aligned}$$

donde  $S_i = \sum_{j=1}^n \log \frac{f(x_j | \boldsymbol{\theta}_i)}{f(x_j | \boldsymbol{\theta}_v)}$ .

Condicionada en  $\boldsymbol{\theta}_v$ ,  $S_i$  es la suma de  $n$  cantidades aleatorias independientes y idénticamente distribuidas y entonces, por la ley fuerte de números grandes, se tiene

$$\lim_{n \rightarrow \infty} \frac{1}{n} S_i = \int f(x | \boldsymbol{\theta}_v) \log \frac{f(x | \boldsymbol{\theta}_i)}{f(x | \boldsymbol{\theta}_v)} dx.$$

Esta cantidad es negativa si  $i \neq v$  y cero si  $i = v$ . Entonces, cuando  $n \rightarrow \infty$ ,  $S_v \rightarrow 0$  y  $S_i \rightarrow -\infty$  si  $i \neq v$  y el resultado queda demostrado.

◇

## El caso continuo

Es normal que los estimadores bayesianos se aproximen a los estimadores EMV en muestras grandes. Recordamos que la distribución de la EMV es aproximadamente normal cuando  $n \rightarrow \infty$ . Existen resultados parecidos para la distribución a posteriori.

**Teorema 12** *Sea  $X_i|\theta \sim f(\cdot|\theta)$  con distribución a priori  $f(\theta)$ . Dados los datos  $\mathbf{x}$ , cuando  $n \rightarrow \infty$ ,*

1  $\theta|\mathbf{x} \approx \mathcal{N}(E[\theta|\mathbf{x}], V[\theta|\mathbf{x}])$ , suponiendo que la media y varianza de  $\theta$  existen,

2  $\theta|\mathbf{x} \approx \mathcal{N}(\hat{\theta}, I(\hat{\theta})^{-1})$  donde  $\hat{\theta}$  es la moda de la distribución final y  $I(\theta)$  es la **información observada**

$$I(\theta) = -\frac{d^2}{d\theta^2} \log(f(\theta|\mathbf{x})).$$

3  $\theta|\mathbf{x} \approx \mathcal{N}(\hat{\theta}, I^*(\hat{\theta})^{-1})$  donde  $\hat{\theta}$  es la EMV de  $\theta$ , suponiendo que la exista y

$$I^*(\theta) = -\frac{d^2}{d\theta^2} \log(f(\mathbf{x}|\theta))$$

4  $\theta|\mathbf{x} \approx \mathcal{N}(\hat{\theta}, I^{**}(\hat{\theta})^{-1})$  donde

$$I^{**}(\theta) = -nE_X \left[ \frac{d^2}{d\theta^2} \log(f(X|\theta)) \right]$$

Se demuestran los resultados del teorema mediante una expansión de Taylor de la distribución a posteriori sobre, por ejemplo  $\hat{\theta}$ . Ver Bernardo y Smith (1994), Gelman et al (1995).

Normalmente, la primera aproximación será mejor que la segunda y tercera, y la última será la peor.

**Observación 56** *En muchos casos, la media y varianza a posteriori son difíciles de calcular pero es mucho más fácil evaluar la moda.*

**Ejemplo 84 Aproximación a una distribución beta.** Sea  $X|\theta \sim \mathcal{BI}(n, \theta)$  y  $\theta \sim \mathcal{B}(\alpha, \beta)$ . Entonces,  $\theta|\mathbf{x} \sim \mathcal{B}(\alpha + x, \beta + n - x)$ .

*Si  $n$  es grande, se puede aproximar la distribución a posteriori de  $\theta$ . Comparamos las cuatro aproximaciones.*

1

$$\theta|\mathbf{x} \approx \mathcal{N}\left(\frac{\alpha + x}{\alpha + \beta + n}, \frac{(\alpha + x)(\beta + n - x)}{(\alpha + \beta + n)^2(\alpha + \beta + n + 1)}\right)$$

2 Calculamos la moda de la distribución beta.

$$\begin{aligned} \log f(\theta|\mathbf{x}) &= c + (\alpha + x - 1) \log(\theta) + \\ &\quad (\beta + n - x - 1) \log(1 - \theta) \\ \frac{d}{d\theta} &= \frac{\alpha + x - 1}{\theta} - \frac{\beta + n - x - 1}{1 - \theta} \\ \hat{\theta} &= \frac{\alpha + x - 1}{\alpha + \beta + n - 2} \end{aligned}$$

es la moda.

Para evaluar la información observada, se tiene

$$\begin{aligned} \frac{d^2}{d\theta^2} \log(f(\theta|\mathbf{x})) &= -\frac{\alpha + x - 1}{\theta^2} - \frac{\beta + n - x - 1}{(1 - \theta)^2} \\ I(\hat{\theta}) &= \frac{\alpha + x - 1}{\hat{\theta}^2} + \frac{\beta + n - x - 1}{(1 - \hat{\theta})^2} \\ &= \frac{(\alpha + \beta + n - 2)^3}{(\alpha + x - 1)(\beta + n - x - 1)} \end{aligned}$$

$$\theta|\mathbf{x} \approx N \left( \frac{\alpha + x - 1}{\alpha + \beta + n - 2}, \frac{(\alpha + x - 1)(\beta + n - x - 1)}{(\alpha + \beta + n - 2)^3} \right)$$

3 El EMV es  $\hat{\theta} = \frac{x}{n}$  y  $I^*(\hat{\theta}) = \frac{n^3}{x(n-x)}$ . Luego

$$\theta|\mathbf{x} \approx \mathcal{N}\left(\frac{x}{n}, \frac{x(n-x)}{n^3}\right)$$

4

$$\begin{aligned} -\frac{d^2}{d\theta^2} \log(f(X|\theta)) &= \frac{X}{\theta^2} + \frac{n-X}{(1-\theta)^2} \\ I^{**}(\theta) &= \frac{n\theta}{\theta^2} + \frac{n(1-\theta)}{(1-\theta)^2} \\ &= \frac{n}{\theta} + \frac{n}{(1-\theta)} \\ I^{**}(\hat{\theta}) &= \frac{n^3}{x(n-x)} \end{aligned}$$

y se tiene la misma aproximación.

Cuando  $n \gg \alpha + \beta$  las aproximaciones serán parecidas, pero en muestras pequeñas pueden dar resultados diferentes.

**Ejemplo 85** Supongamos que  $\alpha = \beta = 2$  y  $x = 20$ ,  $n = 30$ . Hallamos las aproximaciones y estimamos  $P(\theta > 0,5|data)$ .

Se tiene  $\theta|x \sim \mathcal{B}(22, 12)$  y mediante las tablas de la función beta incompleta, se calcula que  $P(\theta > 0,5|x) = 0,95993$ .

1. Se aproxima con

$$\theta|x \approx \mathcal{N}\left(\frac{22}{34}, \frac{22 \times 12}{34^2 \times 35}\right) \approx \mathcal{N}(0,64706, 0,006525)$$

$$\text{Ahora } P(\theta > 0,5|x) \approx P(Z > -1,8206) = 0,9660.$$

2.

$$\theta|x \approx \mathcal{N}\left(\frac{21}{32}, \frac{21 \times 11}{32^3}\right) \approx \mathcal{N}(0,65625, 0,00705).$$

$$P(\theta > 0,5|x) \approx P(Z > -1,8610) = 0,9686.$$

3.

$$\theta|x \approx \mathcal{N}\left(\frac{20}{30}, \frac{20 \times 10}{30^3}\right) \approx \mathcal{N}(0,66667, 0,00741).$$

$$P(\theta > 0,5|x) \approx P(Z > -1,9365) = 0,9735.$$

El siguiente ejemplo demuestra la aproximación con una muestra pequeña.

### **Ejemplo 86** (*Berger 1985*)

*Dada una muestra  $\mathbf{x} = (4,0 \ 5,5 \ 7,5 \ 4,5 \ 3,0)$  de una distribución Cauchy:  $\mathcal{C}(\mu, 1)$ , y una distribución inicial (impropia)  $f(\mu) \propto 1$ , queremos aproximar a la distribución a posteriori  $f(\mu|\mathbf{x})$ .*

*Se puede demostrar que  $E[\mu|\mathbf{x}] = 4,45$  y  $V[\mu|\mathbf{x}] = 0,562$  y la siguiente tabla proporciona las  $\alpha$  quantiles de la distribución exacta y de la aproximación normal.*

$\alpha$	2,5	25	50	75	97,5
$F_{exact}$	3,17	4,07	4,52	5,00	6,15
$F_{norm}$	3,08	4,05	4,55	5,06	6,02

*También, la moda a posteriori es 4,55 y la información esperada  $I^{**}(\hat{\theta}) = 5/2$ . Luego el método 4 da la aproximación  $\mathcal{N}(4,55, 0,4)$  que es peor.*

## Cuando no se puede aplicar el teorema

Existen algunas situaciones cuando no se puede aplicar el teorema. Por ejemplo

- Si la densidad a priori del verdadero valor de  $\theta$  es 0,
- Si la distribución a posteriori es impropia,
- Si el modelo no es identificable.

**Ejemplo 87** *Supongamos el modelo*

$$f(x|\theta_1, \dots, \theta_k) = w_1g(x|\theta_1) + \dots + w_kg(x|\theta_k)$$

*una mixtura de  $k$  densidades de la misma familia.*

*Dados los datos, la verosimilitud será multimodal porque el modelo no es identificable. Necesitamos restringir el espacio  $\Theta$ , para que el modelo sea identificable.*

*Por ejemplo, podemos suponer que  $\theta_1 < \dots < \theta_k$ .*

Ver Gelman et al (1995) para mas ejemplos.

## La aproximación de Laplace

Tierney y Kadane (1996) desarrollo esta generalización de la aproximación normal para la estimación de la media a posteriori.

Se quiere estimar

$$E[g(\theta)|\mathbf{x}] = \frac{\int g(\theta)l(\theta|\mathbf{x})f(\theta) d\theta}{\int l(\theta|\mathbf{x})f(\theta) d\theta}$$

Supongamos que  $g(\cdot)$  es no negativa.

Se expresa la esperanza en la forma

$$E[g(\theta)|\mathbf{x}] = \frac{\int \exp(-nh^*(\theta)) d\theta}{\int \exp(-nh(\theta)) d\theta}$$

donde

$$-nh(\theta) = \log f(\theta) + \log l(\theta|\mathbf{x})$$

$$\text{y } -nh^*(\theta) = \log g(\theta) + \log f(\theta) + \log l(\theta|\mathbf{x}).$$

Dada esta expresión, se usa la expansión de Taylor de  $h$  ( $h^*$ ) en torno a la moda  $\hat{\theta}$  ( $\hat{\theta}$ ).

$$\begin{aligned} -h(\hat{\theta}) &= \max_{\theta}(-h(\theta)) \\ -h^*(\hat{\theta}) &= \max_{\theta}(-h^*(\theta)) \end{aligned}$$

y se quedan con los términos cuadráticos. Se estima el integral del denominador con

$$\int \exp(-nh(\theta)) d\theta \approx \sqrt{2\pi\sigma} n^{-1/2} \exp(-nh(\hat{\theta}))$$

$$\text{donde } \sigma = \left( \frac{d^2}{d\theta^2} h(\theta) \Big|_{\theta=\hat{\theta}} \right)^{-1/2}$$

y una aproximación parecida en el numerador.

Nos proporciona la estimación:

$$E[g(\theta|\mathbf{x})] \approx \left( \frac{\sigma^*}{\sigma} \right) \frac{g(\hat{\theta})f(\hat{\theta})l(\hat{\theta}|\mathbf{x})}{f(\hat{\theta})l(\hat{\theta}|\mathbf{x})}$$

donde

$$\sigma^* = \left( \frac{d^2}{d\theta^2} h^*(\theta) \Big|_{\theta=\hat{\theta}} \right)^{-1/2}$$

**Ejemplo 88** *Volvemos al Ejemplo 84. Se tiene  $\theta|\mathbf{x} \sim \mathcal{B}(\alpha + x, \beta + n - x)$ .*

**Observación 57** *Sin pérdida de generalidad, se suponen  $0 \leq \alpha, \beta < 1$ . Si no, se puede transformar  $x \rightarrow x + [\alpha]$  y  $n \rightarrow n + [\alpha] + [\beta]$ .*

*Escribiendo la densidad en una forma conveniente*

$$\begin{aligned} f(\theta|\mathbf{x}) &\propto \theta^{\alpha+x-1} (1-\theta)^{\beta+n-x-1} \\ &\propto \exp(-nh(\theta)) \end{aligned}$$

*donde*

$$h(\theta) = -\frac{1}{n} \left( (\alpha + x - 1) \log \theta + (\beta + n - x - 1) \log(1 - \theta) \right)$$

*Se puede demostrar (Ejercicio) que el estimador de Laplace de la media a posteriori será*

$$\frac{(\alpha + x)^{\alpha+x+1/2} (\alpha + \beta + n - 2)^{\alpha+\beta+n-1/2}}{(\alpha + x - 1)^{\alpha+x-1/2} (\alpha + \beta + n - 1)^{\alpha+\beta+n+1/2}}$$

Por ejemplo, si  $\theta|\mathbf{x} \sim \mathcal{B}(8, 12)$ , poniendo  $\alpha = \beta = 0$  y  $n = 20$  el estimador de Laplace es

$$E[\theta|\mathbf{x}] \approx \frac{8^{8,5} 18^{19,5}}{77,5 19^{20,5}} \approx ,3994$$

El valor exacto de la media es  $8/20 = 0,4$ .

Utilizando la aproximación 2 del teorema de Capítulo 6, se estima la media con la moda  $7/18 = ,3889$ . La aproximación de Laplace es mejor.

## Ejemplo 89 Estimación del Factor Bayes

*Consideramos el caso de dos hipótesis compuestas  $H_0$  y  $H_1$ . El factor Bayes es*

$$B_1^0 = \frac{\int f(\mathbf{x}|\boldsymbol{\theta}_0, H_0)f(\boldsymbol{\theta}_0|H_0) d\boldsymbol{\theta}_0}{\int f(\mathbf{x}|\boldsymbol{\theta}_1, H_1)f(\boldsymbol{\theta}_1|H_1) d\boldsymbol{\theta}_1}$$

*y el numerador y denominador son las dos funciones positivas. Entonces se puede aplicar la aproximación de Laplace. Ver Kass y Raftery (1995).*

## Propiedades y problemas de la aproximación de Laplace

- La aproximación es  $O(1/n^2)$
- Se puede extender el método al caso multidimensional
- Si  $\Theta \neq R$ , se puede reparameterizar el modelo para mejorar la aproximación
- Necesitamos ser capaces de calcular los EMV.