

CAPÍTULO 8. MODELOS LINEALES Y REGRESIÓN

Para leer

Gelman et al, Capítulo 8

Se supone que \mathbf{Y} es un vector de n observaciones. Se define un modelo lineal para y

$$E[\mathbf{y}|\boldsymbol{\theta}] = \mathbf{A}\boldsymbol{\theta}$$

donde $\boldsymbol{\theta}$ es un vector de p parámetros, \mathbf{A} es una matriz conocida de diseño y la matriz de varianzas de \mathbf{y} es \mathbf{C} . Se define \mathbf{C}^{-1} la matriz de precisión.

Observación 27 *A menudo se supone que la distribución de \mathbf{y} es normal.*

También en muchos problemas, la matriz de varianzas tiene una forma simple, por ejemplo $\mathbf{C} = \sigma^2\mathbf{I}$.

Ejemplo 59 *Observaciones univariables*

$$\mathbf{A}^T = (1, \dots, 1), \quad \theta \text{ escalar} \quad \mathbf{C} = \frac{1}{\phi} \mathbf{I} \quad p = 1$$

Ejemplo 60 *Regresión lineal simple.*

El modelo es

$$y_i = \alpha + \beta x_i + \epsilon_i \quad i = 1, \dots, n$$

donde $\epsilon_i \sim \mathcal{N}(0, 1/\phi)$. *Entonces*

$$\mathbf{A}^T = \begin{pmatrix} 1 & 1 & \cdots & 1 \\ x_1 & x_2 & \cdots & x_n \end{pmatrix} \quad \boldsymbol{\theta} = \begin{pmatrix} \alpha \\ \beta \end{pmatrix}$$

$$\text{y } \mathbf{C} = \frac{1}{\phi} \mathbf{I}.$$

Es habitual escribir el modelo de otra forma:

$$y_i = \alpha' + \beta(x_i - \bar{x}) + \epsilon_i$$

donde $\alpha' = \alpha + \beta\bar{x}$.

En este caso se tiene

$$\mathbf{A}^T = \begin{pmatrix} 1 & 1 & \cdots & 1 \\ x_1 - \bar{x} & x_2 - \bar{x} & \cdots & x_n - \bar{x} \end{pmatrix} \quad \boldsymbol{\theta} = \begin{pmatrix} \alpha' \\ \beta \end{pmatrix}$$

Ejemplo 61 *El modelo de dos factores (sin réplicas) Las observaciones son y_{ij} donde $i = 1, \dots, t$ y $j = 1, \dots, b$. Entonces hay $n = tb$ observaciones. El modelo es*

$$E[y_{ij}|\boldsymbol{\theta}] = \mu + \alpha_i + \beta_j.$$

Suponiendo la restricción “GLIM” $\alpha_1 = \beta_1 = 0$ (para hacer el modelo identificable), en el caso de $t = 2, b = 3$ se tiene

$$E \begin{bmatrix} y_{11} \\ y_{12} \\ y_{13} \\ y_{21} \\ y_{22} \\ y_{23} \end{bmatrix} = \begin{pmatrix} 1 & 0 & 0 & 0 \\ 1 & 0 & 1 & 0 \\ 1 & 0 & 0 & 1 \\ 1 & 1 & 0 & 0 \\ 1 & 1 & 1 & 0 \\ 1 & 1 & 0 & 1 \end{pmatrix} \begin{pmatrix} \mu \\ \alpha_2 \\ \beta_2 \\ \beta_3 \end{pmatrix}$$

La distribución normal multivariante

Para hacer la inferencia se necesita conocer las propiedades de la distribución normal multivariante.

Definición 13 *Un vector \mathbf{y} de dimensión k tiene una distribución normal multivariante con media $\boldsymbol{\mu}$ y varianza $E[(\mathbf{y} - \boldsymbol{\mu})(\mathbf{y} - \boldsymbol{\mu})^T] = \mathbf{V}$ si*

$$f(\mathbf{y}|\boldsymbol{\mu}, \mathbf{V}) = (2\pi)^{-\frac{k}{2}}|\mathbf{V}|^{-\frac{1}{2}} \exp\left(-\frac{1}{2}(\mathbf{y} - \boldsymbol{\mu})^T \mathbf{V}^{-1}(\mathbf{y} - \boldsymbol{\mu})\right)$$

Propiedades importantes de la distribución son las siguientes.

- Cualquier subconjunto de \mathbf{y} también se distribuye como normal. Si

$$\mathbf{y} = \begin{pmatrix} \mathbf{y}_1 \\ \mathbf{y}_2 \end{pmatrix} \sim \mathcal{N}\left(\begin{pmatrix} \boldsymbol{\mu}_1 \\ \boldsymbol{\mu}_2 \end{pmatrix}, \begin{pmatrix} \mathbf{V}_1 & \mathbf{V}_{12} \\ \mathbf{V}_{21} & \mathbf{V}_2 \end{pmatrix}\right)$$

entonces $\mathbf{y}_1 \sim \mathcal{N}(\boldsymbol{\mu}_1, \mathbf{V}_1)$ y $\mathbf{y}_2 \sim \mathcal{N}(\boldsymbol{\mu}_2, \mathbf{V}_2)$.

- Si $y_1 \sim \mathcal{N}(\boldsymbol{\mu}_1, \mathbf{V}_1)$ y $y_2 \sim \mathcal{N}(\boldsymbol{\mu}_2, \mathbf{V}_2)$ son variables independientes con la misma dimensión entonces

$$y_1 \pm y_2 \sim \mathcal{N}(\boldsymbol{\mu}_1 \pm \boldsymbol{\mu}_2, \mathbf{V}_1 + \mathbf{V}_2)$$

- Si $\mathbf{z} = \mathbf{D}\mathbf{y}$ para una matriz \mathbf{D} entonces

$$\mathbf{z} \sim \mathcal{N}(\mathbf{D}\boldsymbol{\mu}, \mathbf{D}\mathbf{V}\mathbf{D}^T).$$

Ejemplo 62 *El modelo lineal normal es*

$$\mathbf{y} = \mathbf{A}\boldsymbol{\theta} + \boldsymbol{\epsilon}$$

donde $\boldsymbol{\epsilon} \sim \mathcal{N}(\mathbf{0}, \mathbf{C})$. Entonces $\mathbf{y}|\boldsymbol{\theta} \sim \mathcal{N}(\mathbf{A}\boldsymbol{\theta}, \mathbf{C})$.

Matrices, vectores y formas cuadráticas

Es necesario entender cómo se manipulan matrices y vectores para hacer los cálculos necesarios para la inferencia.

Unos resultados útiles son

- Para matrices o vectores \mathbf{A} y \mathbf{B} ,

$$(\mathbf{AB})^T = \mathbf{B}^T \mathbf{A}^T.$$

- Si \mathbf{x}_i , ($i = 1, \dots, n$) y $\boldsymbol{\mu}$ son vectores de dimensión $k \times 1$ y \mathbf{V} es una matriz simétrica de dimensión $k \times k$,

$$\sum_{i=1}^n \mathbf{x}_i \mathbf{V} \boldsymbol{\mu} = n \bar{\mathbf{x}} \mathbf{V} \boldsymbol{\mu}$$

donde $\bar{\mathbf{x}} = \frac{1}{n} \sum_{i=1}^n \mathbf{x}_i$

- Para vectores \mathbf{x} , $\boldsymbol{\mu}$ ($k \times 1$) y matriz simétrica \mathbf{V} una forma cuadrática es

$$(\mathbf{x} - \boldsymbol{\mu})^T \mathbf{V} (\mathbf{x} - \boldsymbol{\mu}).$$

Se tiene la expansión

$$\begin{aligned} (\mathbf{x} - \boldsymbol{\mu})^T \mathbf{V} (\mathbf{x} - \boldsymbol{\mu}) &= \mathbf{x}^T \mathbf{V} \mathbf{x} - \boldsymbol{\mu}^T \mathbf{V} \mathbf{x} - \mathbf{x}^T \mathbf{V} \boldsymbol{\mu} \\ &\quad + \boldsymbol{\mu}^T \mathbf{V} \boldsymbol{\mu} \\ &= \mathbf{x}^T \mathbf{V} \mathbf{x} - 2\mathbf{x}^T \mathbf{V} \boldsymbol{\mu} + \boldsymbol{\mu}^T \mathbf{V} \boldsymbol{\mu} \end{aligned}$$

Se observa que el resultado es escalar.

- Se puede expresar una forma cuadrática de otra manera:

$$(\mathbf{x} - \boldsymbol{\mu})^T \mathbf{V} (\mathbf{x} - \boldsymbol{\mu}) = \text{tr}(\mathbf{V}\mathbf{W})$$

donde $\mathbf{W} = (\mathbf{x} - \boldsymbol{\mu})(\mathbf{x} - \boldsymbol{\mu})^T$ y $\text{tr}(\cdot)$ es la traza de la matriz.

Ejemplo 63 La verosimilitud para una muestra de una distribución normal multivariante.

Sea y_1, \dots, y_n una muestra de una distribución normal multivariante $\mathcal{N}(\boldsymbol{\mu}, \mathbf{V})$. La verosimilitud es

$$\begin{aligned}
 l(\boldsymbol{\mu}, \mathbf{V} | \text{datos}) &\propto |\mathbf{V}|^{-\frac{n}{2}} \exp \left(-\frac{1}{2} \sum_{i=1}^n (\mathbf{y}_i - \boldsymbol{\mu})^T \mathbf{V}^{-1} (\mathbf{y}_i - \boldsymbol{\mu}) \right) \\
 &\propto |\mathbf{V}|^{-\frac{n}{2}} \exp \left(-\frac{1}{2} \sum_{i=1}^n (\mathbf{y}_i - \bar{\mathbf{y}} + \bar{\mathbf{y}} - \boldsymbol{\mu})^T \mathbf{V}^{-1} \right. \\
 &\quad \left. (\mathbf{y}_i - \bar{\mathbf{y}} + \bar{\mathbf{y}} - \boldsymbol{\mu}) \right) \\
 &\propto |\mathbf{V}|^{-\frac{n}{2}} \exp \left(-\frac{1}{2} \left[\sum_{i=1}^n (\mathbf{y}_i - \bar{\mathbf{y}})^T \mathbf{V}^{-1} (\mathbf{y}_i - \bar{\mathbf{y}}) \right. \right. \\
 &\quad \left. \left. - 2 \sum_{i=1}^n (\mathbf{y}_i - \bar{\mathbf{y}})^T \mathbf{V}^{-1} (\bar{\mathbf{y}} - \boldsymbol{\mu}) + \right. \right. \\
 &\quad \left. \left. n(\bar{\mathbf{y}} - \boldsymbol{\mu})^T \mathbf{V}^{-1} (\bar{\mathbf{y}} - \boldsymbol{\mu}) \right] \right)
 \end{aligned}$$

$$\begin{aligned}
&= |\mathbf{V}|^{-\frac{n}{2}} \exp \left(-\frac{1}{2} \left[\sum_{i=1}^n (\mathbf{y}_i - \bar{\mathbf{y}})^T \mathbf{V}^{-1} (\mathbf{y}_i - \bar{\mathbf{y}}) \right. \right. \\
&\quad \left. \left. + n(\bar{\mathbf{y}} - \boldsymbol{\mu})^T \mathbf{V}^{-1} (\bar{\mathbf{y}} - \boldsymbol{\mu}) \right] \right) \\
&\propto |\mathbf{V}|^{-\frac{n}{2}} \exp \left(-\frac{1}{2} \left[\text{tr}(\mathbf{V}^{-1} \mathbf{S}) \right. \right. \\
&\quad \left. \left. + n(\bar{\mathbf{y}} - \boldsymbol{\mu})^T \mathbf{V}^{-1} (\bar{\mathbf{y}} - \boldsymbol{\mu}) \right] \right)
\end{aligned}$$

donde $\mathbf{S} = \sum_{i=1}^n (\mathbf{y}_i - \bar{\mathbf{y}})(\mathbf{y}_i - \bar{\mathbf{y}})^T$.

La fórmula para la verosimilitud es parecida a la fórmula en el caso univariable.

Ejemplo 64 Inferencia bayesiana para la distribución normal multivariante

Se puede hacer inferencia conjugada para la distribución normal multivariable. Suponiendo V conocida y con la distribución a priori

$$\boldsymbol{\mu} \sim \mathcal{N}\left(\mathbf{m}, \frac{1}{\alpha} \mathbf{V}\right)$$

entonces, la distribución a posteriori es también normal

$$\begin{aligned} \boldsymbol{\mu} | \mathbf{y} &\sim \mathcal{N}\left(\mathbf{m}^*, \frac{1}{\alpha^*} \mathbf{V}\right) \quad \text{donde} \\ \alpha^* &= \alpha + n \\ \mathbf{m}^* &= \frac{\alpha \mathbf{m} + n \bar{\mathbf{y}}}{\alpha + n} \end{aligned}$$

Demostración

$$\begin{aligned}
 f(\boldsymbol{\mu}|\mathbf{y}) &\propto l(\boldsymbol{\mu}|\mathbf{y})f(\boldsymbol{\mu}) \\
 &\propto \exp\left(-\frac{1}{2}\left[n(\boldsymbol{\mu}-\bar{\mathbf{y}})^T\mathbf{V}^{-1}(\boldsymbol{\mu}-\bar{\mathbf{y}})+\right. \right. \\
 &\quad \left. \left.\alpha(\boldsymbol{\mu}-\mathbf{m})^T\mathbf{V}^{-1}(\boldsymbol{\mu}-\mathbf{m})\right]\right) \\
 &\propto \exp\left(-\frac{1}{2}\left[n\boldsymbol{\mu}^T\mathbf{V}^{-1}\boldsymbol{\mu}-2n\boldsymbol{\mu}^T\mathbf{V}^{-1}\bar{\mathbf{y}}+\right. \right. \\
 &\quad \left. \left.\alpha\boldsymbol{\mu}^T\mathbf{V}^{-1}\boldsymbol{\mu}-2\alpha\boldsymbol{\mu}^T\mathbf{V}^{-1}\mathbf{m}\right]\right) \\
 &\propto \exp\left(-\frac{1}{2}\left[(\alpha+n)\boldsymbol{\mu}^T\mathbf{V}^{-1}\boldsymbol{\mu}-\right. \right. \\
 &\quad \left. \left.2(\alpha+n)\boldsymbol{\mu}^T\mathbf{V}^{-1}\frac{\alpha\mathbf{m}+n\bar{\mathbf{y}}}{\alpha+n}\right]\right) \\
 &\propto \exp\left(-\frac{1}{2}\left[\alpha^*\boldsymbol{\mu}^T\mathbf{V}^{-1}\boldsymbol{\mu}-2\alpha^*\boldsymbol{\mu}^T\mathbf{V}^{-1}\mathbf{m}^*\right]\right) \\
 &\propto \exp\left(-\frac{\alpha^*}{2}\left[(\boldsymbol{\mu}-\mathbf{m}^*)^T\mathbf{V}^{-1}(\boldsymbol{\mu}-\mathbf{m}^*)\right]\right) \\
 &\propto \exp\left(-\frac{1}{2}(\boldsymbol{\mu}-\mathbf{m}^*)^T\left(\frac{1}{\alpha^*}\mathbf{V}\right)^{-1}(\boldsymbol{\mu}-\mathbf{m}^*)\right)
 \end{aligned}$$

que es el núcleo de una distribución normal. \diamond

Con una distribución a priori uniforme se tiene

$$\boldsymbol{\mu}|\mathbf{y} \sim \mathcal{N}\left(\bar{\mathbf{y}}, \frac{1}{n}\mathbf{V}\right)$$

y la media a posteriori de $\boldsymbol{\mu}$ coincide con el EMV.

El caso de \mathbf{V} desconocida.

En este caso, la distribución a priori conjugada para \mathbf{V} es una distribución Wishart invertida, $\mathbf{V} \sim \mathcal{WI}(\nu, \mathbf{W})$, es decir

$$f(\mathbf{V}) \propto |\mathbf{V}|^{\frac{\nu+p+1}{2}} \exp\left(-\frac{1}{2}\text{tr}(\mathbf{V}^{-1}\mathbf{W})\right)$$

donde $p = \dim(\mathbf{V})$.

Teorema 10 Si $Y|\mu, \mathbf{V} \sim \mathcal{N}(\mu, \mathbf{V})$ con distribución a priori $\mu|\mathbf{V} \sim \mathcal{N}(\mathbf{m}, \frac{1}{\alpha}\mathbf{V})$ y $\mathbf{V} \sim \mathcal{WI}(\nu, \mathbf{W})$, luego $\mu|y, \mathbf{V} \sim \mathcal{N}(\mathbf{m}^*, \frac{1}{\alpha^*}\mathbf{V})$ y $\mathbf{V}|y \sim \mathcal{WI}(\nu^*, \mathbf{W}^*)$ donde

$$\begin{aligned}\alpha^* &= \alpha + n \\ \mathbf{m}^* &= \frac{\alpha\mathbf{m} + n\bar{y}}{\alpha + n} \\ \nu^* &= \nu + n \\ \mathbf{W}^* &= \mathbf{W} + \mathbf{S} + \frac{\alpha n}{\alpha + n}(\bar{y} - \mathbf{m})(\bar{y} - \mathbf{m})^T\end{aligned}$$

El resultado es similar al resultado univariable.

Inferencia para el modelo lineal con varianza conocida.

Supongamos el modelo básico $y|\theta \sim \mathcal{N}(\mathbf{A}\theta, \mathbf{C})$ y una distribución a priori normal $\theta \sim \mathcal{N}(\boldsymbol{\mu}, \mathbf{V})$ donde \mathbf{A} , \mathbf{C} , $\boldsymbol{\mu}$ y \mathbf{V} son conocidos.

Este modelo se llama **el modelo lineal de 2 etapas**.

Tenemos el siguiente teorema

Teorema 11 *La distribución marginal de y es*

$$y \sim \mathcal{N}(\mathbf{A}\boldsymbol{\mu}, \mathbf{C} + \mathbf{A}\mathbf{V}\mathbf{A}^T)$$

y la distribución a posteriori de θ es $\theta|y \sim \mathcal{N}(\mathbf{B}b, \mathbf{B})$ donde

$$\begin{aligned}\mathbf{B}^{-1} &= \mathbf{V}^{-1} + \mathbf{A}^T\mathbf{C}^{-1}\mathbf{A} \\ \mathbf{b} &= \mathbf{A}^T\mathbf{C}^{-1}y + \mathbf{V}^{-1}\boldsymbol{\mu}\end{aligned}$$

Demostración

En primer lugar se calcula la distribución marginal de y .

Es suficiente calcular la media y la varianza.

$$\begin{aligned} E[y] &= E[E[y|\boldsymbol{\theta}]] \\ &= E[\mathbf{A}\boldsymbol{\theta}] \\ &= \mathbf{A}E[\boldsymbol{\theta}] = \mathbf{A}\boldsymbol{\mu} \\ V[y] &= E[V[y|\boldsymbol{\theta}]] + V[E[y|\boldsymbol{\theta}]] \\ &= E[\mathbf{C}] + V[\mathbf{A}\boldsymbol{\theta}] \\ &= \mathbf{C} + \mathbf{A}V[\boldsymbol{\theta}]\mathbf{A}^T \\ &= \mathbf{C} + \mathbf{A}\mathbf{V}\mathbf{A}^T \end{aligned}$$

La normalidad sigue inmediatamente recordando que $y = \mathbf{A}\boldsymbol{\theta} + \epsilon$ donde $\boldsymbol{\theta}$ y ϵ son normales.

Ahora se calcula la distribución a posteriori

$$\begin{aligned} f(\boldsymbol{\theta}|\mathbf{y}) &\propto f(\boldsymbol{\theta})f(\mathbf{y}|\boldsymbol{\theta}) \\ &\propto \exp\left(-\frac{1}{2}(\boldsymbol{\theta} - \boldsymbol{\mu})^T \mathbf{V}^{-1}(\boldsymbol{\theta} - \boldsymbol{\mu})\right) \\ &\quad \exp\left(-\frac{1}{2}(\mathbf{y} - \mathbf{A}\boldsymbol{\theta})^T \mathbf{C}^{-1}(\mathbf{y} - \mathbf{A}\boldsymbol{\theta})\right) \\ &\propto \exp\left(-\frac{1}{2}\left[\boldsymbol{\theta}^T (\mathbf{V}^{-1} + \mathbf{A}^T \mathbf{C}^{-1} \mathbf{A})\boldsymbol{\theta} - \right.\right. \\ &\quad \left.\left. 2\boldsymbol{\theta}^T (\mathbf{V}^{-1} \boldsymbol{\mu} + \mathbf{A}^T \mathbf{C}^{-1} \mathbf{y})\right]\right) \\ &\propto \exp\left(-\frac{1}{2}\left[\boldsymbol{\theta}^T \mathbf{B}^{-1} \boldsymbol{\theta} - 2\boldsymbol{\theta}^T \mathbf{b}\right]\right) \\ &\propto \exp\left(-\frac{1}{2}\left[\boldsymbol{\theta}^T \mathbf{B}^{-1} \boldsymbol{\theta} - 2\boldsymbol{\theta}^T \mathbf{B}^{-1} \mathbf{Bb}\right]\right) \\ &\propto \exp\left(-\frac{1}{2}(\boldsymbol{\theta} - \mathbf{Bb})^T \mathbf{B}^{-1}(\boldsymbol{\theta} - \mathbf{Bb})\right) \end{aligned}$$

que es el núcleo de una distribución normal $\mathcal{N}(\mathbf{Bb}, \mathbf{B})$. ◇

Relación con el EMV

El estimador de mínimos cuadrados para este problema es

$$\hat{\boldsymbol{\theta}} = (\mathbf{A}^T \mathbf{C}^{-1} \mathbf{A})^{-1} \mathbf{A}^T \mathbf{C}^{-1} \mathbf{y}$$

y entonces

$$\begin{aligned} \mathbf{Bb} &= (\mathbf{V}^{-1} + \mathbf{A}^T \mathbf{C}^{-1} \mathbf{A})^{-1} (\mathbf{A}^T \mathbf{C}^{-1} \mathbf{y} + \mathbf{V}^{-1} \boldsymbol{\mu}) \\ &= (\mathbf{V}^{-1} + \mathbf{A}^T \mathbf{C}^{-1} \mathbf{A})^{-1} [(\mathbf{A}^T \mathbf{C}^{-1} \mathbf{A}) \hat{\boldsymbol{\theta}} + \mathbf{V}^{-1} \boldsymbol{\mu}] \end{aligned}$$

La media a posteriori es una media ponderada de la media a priori $\boldsymbol{\mu}$ y el EMV $\hat{\boldsymbol{\theta}}$ con ponderaciones proporcionales a las matrices de precisión.

Se puede expresar la media a posteriori de otra manera.

$$\begin{aligned}\mathbf{Bb} &= \mathbf{B} \left[\mathbf{A}^T \mathbf{C}^{-1} (\mathbf{y} - \mathbf{A}\boldsymbol{\mu}) + (\mathbf{A}^T \mathbf{C}^{-1} \mathbf{A} + \mathbf{V}^{-1}) \boldsymbol{\mu} \right] \\ &= \boldsymbol{\mu} + \mathbf{B} \mathbf{A}^T \mathbf{C}^{-1} (\mathbf{y} - \mathbf{A}\boldsymbol{\mu})\end{aligned}$$

Se ha expresado la media a posteriori como la media a priori más una corrección.

La cantidad $\mathbf{y} - \mathbf{A}\boldsymbol{\mu}$ es la diferencia entre la observación \mathbf{y} y su esperanza a priori $\mathbf{A}\boldsymbol{\mu}$. La cantidad $\mathbf{B} \mathbf{A}^T \mathbf{C}^{-1}$ se llama **un filtro**

Ejemplo 65 Retomando el Ejemplo 59 con observaciones univariables y $\mathbf{A} = (1, \dots, 1)^T$, $\mathbf{C} = \frac{1}{\phi} \mathbf{I}$ y la distribución a priori $\theta \sim \mathcal{N}\left(\mu, \frac{1}{\alpha\phi}\right)$ tenemos

$$\mathbf{A}^T \mathbf{C}^{-1} \mathbf{A} = n\phi$$

$$\mathbf{A}^T \mathbf{C}^{-1} \mathbf{y} = \phi \sum_{i=1}^n y_i = n\phi\bar{y}$$

$$\mathbf{A}^T \mathbf{C}^{-1} \mathbf{A} + \mathbf{V}^{-1} = n\phi + \alpha\phi = (n + \alpha)\phi$$

$$\mathbf{A}^T \mathbf{C}^{-1} \mathbf{y} + \mathbf{V}^{-1} \boldsymbol{\mu} = n\phi\bar{y} + \alpha\phi\mu$$

$$\mathbf{B}\mathbf{b} = \frac{n\bar{y} + \alpha\mu}{n + \alpha}$$

que es el resultado que hemos visto para la media a posteriori en el Ejemplo 38.

Ejemplo 66 *Escribir el siguiente problema en términos del modelo lineal de 2 etapas y entonces calcular las distribuciones a posteriori de θ y α .*

$$y_1 \sim \mathcal{N}\left(\theta + \delta, \frac{1}{\phi}\right) \quad y_2 \sim \mathcal{N}\left(\theta - \delta, \frac{1}{\phi}\right)$$

donde y_1 y y_2 independientes dados θ y δ .

$$\theta \sim \mathcal{N}(m, v) \quad \delta \sim \mathcal{N}(0, w)$$

θ δ independientes.

¿Qué forma tiene la distribución a posteriori cuando $v \rightarrow \infty$?

Definimos $\mathbf{y} = (y_1, y_2)^T$ y $\boldsymbol{\theta} = (\theta, \delta)^T$ y entonces

$$E[\mathbf{y}|\boldsymbol{\theta}] = \mathbf{A}\boldsymbol{\theta} \quad \text{donde} \quad \mathbf{A} = \begin{pmatrix} 1 & 1 \\ 1 & -1 \end{pmatrix}$$

También $\mathbf{C} = V[\mathbf{y}|\boldsymbol{\theta}] = \frac{1}{\phi}\mathbf{I}$ y la distribución a priori de $\boldsymbol{\theta}$ es

$$\begin{aligned} \boldsymbol{\theta} &\sim \mathcal{N}(\boldsymbol{\mu}, \mathbf{V}) \quad \text{donde} \\ \boldsymbol{\mu} &= (m, 0)^T \\ \mathbf{V} &= \begin{pmatrix} v & 0 \\ 0 & w \end{pmatrix} \end{aligned}$$

Calculamos la distribución a posteriori utilizando el resultado del teorema.

$$\begin{aligned}
\mathbf{V}^{-1} &= \begin{pmatrix} 1/v & 0 \\ 0 & 1/w \end{pmatrix} \\
\mathbf{A}^T \mathbf{C}^{-1} \mathbf{A} &= \phi \begin{pmatrix} 1 & 1 \\ 1 & -1 \end{pmatrix} \begin{pmatrix} 1 & 1 \\ 1 & -1 \end{pmatrix} \\
&= \phi \begin{pmatrix} 2 & 0 \\ 0 & 2 \end{pmatrix} \\
\mathbf{B}^{-1} &= \begin{pmatrix} \frac{1}{v} + 2\phi & 0 \\ 0 & \frac{1}{w} + 2\phi \end{pmatrix} \\
\mathbf{B} &= \begin{pmatrix} \frac{1}{\frac{1}{v} + 2\phi} & 0 \\ 0 & \frac{1}{\frac{1}{w} + 2\phi} \end{pmatrix} \\
\mathbf{V}^{-1} \boldsymbol{\mu} &= (m/v, 0)^T \\
\mathbf{A}^T \mathbf{C}^{-1} \mathbf{y} &= \phi(y_1 + y_2, y_1 - y_2)^T \\
\mathbf{b} &= \left(\frac{m}{v} + \phi(y_1 + y_2), \phi(y_1 - y_2) \right)^T \\
\mathbf{Bb} &= \left(\frac{\frac{m}{v} + \phi(y_1 + y_2)}{\frac{1}{v} + 2\phi}, \frac{\phi(y_1 - y_2)}{\frac{1}{w} + 2\phi} \right)^T
\end{aligned}$$

Entonces θ y δ son independientes a posteriori con distribuciones

$$\theta|y \sim \mathcal{N}\left(\frac{\frac{m}{v} + \phi(y_1 + y_2)}{\frac{1}{v} + 2\phi}, \frac{1}{\frac{1}{v} + 2\phi}\right)$$

$$\delta|y \sim \mathcal{N}\left(\frac{\phi(y_1 - y_2)}{\frac{1}{w} + 2\phi}, \frac{1}{\frac{1}{w} + 2\phi}\right)$$

La media a posteriori de θ es una media ponderada de la media a priori y el EMV con pesos proporcionales a la precisión a priori ($1/v$) y la precisión del EMV (2ϕ).

Si $v \rightarrow \infty$, tenemos

$$E[\theta|y] = \frac{\frac{m}{v} + \phi(y_1 + y_2)}{\frac{1}{v} + 2\phi} \rightarrow \frac{\phi(y_1 + y_2)}{2\phi} = \bar{y}$$

$$V[\theta|y] = \frac{1}{\frac{1}{v} + 2\phi} \rightarrow \frac{1}{2\phi}$$

y la distribución a posteriori de θ es $\mathcal{N}\left(\bar{y}, \frac{1}{2\phi}\right)$.
No cambia la distribución a posteriori de δ .

Resultados para el modelo de 2 etapas con distribución a priori uniforme

Sea la distribución a priori no informativa; $f(\boldsymbol{\theta}) \propto 1$. Esta distribución a priori equivale a poner $\mathbf{V}^{-1} = \mathbf{0}$ en el Teorema. Entonces:

$$\begin{aligned}\mathbf{B}^{-1} &= \mathbf{A}^T \mathbf{C}^{-1} \mathbf{A} \\ \Rightarrow \mathbf{B} &= \left(\mathbf{A}^T \mathbf{C}^{-1} \mathbf{A} \right)^{-1} \\ \mathbf{b} &= \mathbf{A}^T \mathbf{C}^{-1} \mathbf{y}\end{aligned}$$

y la distribución a posteriori será

$$\boldsymbol{\theta} | \mathbf{y} \sim \mathcal{N} \left(\left(\mathbf{A}^T \mathbf{C}^{-1} \mathbf{A} \right)^{-1} \mathbf{A}^T \mathbf{C}^{-1} \mathbf{y}, \left(\mathbf{A}^T \mathbf{C}^{-1} \mathbf{A} \right)^{-1} \right).$$

La media a posteriori es igual al EMV de $\boldsymbol{\theta}$.

Ejemplo 67 Siendo $\mathbf{C} = \frac{1}{\phi} \mathbf{I}$, se tiene el modelo lineal con errores independientes y dada una distribución a priori uniforme, la distribución a posteriori es

$$\boldsymbol{\theta} | \mathbf{y} \sim \mathcal{N} \left(\left(\mathbf{A}^T \mathbf{A} \right)^{-1} \mathbf{A}^T \mathbf{y}, \frac{1}{\phi} \left(\mathbf{A}^T \mathbf{A} \right)^{-1} \right)$$

y la media a posteriori de $\boldsymbol{\theta}$ coincide con el EMV.

Ejemplo 68 Retomando el modelo de regresión simple del Ejemplo 60 se tiene

$$\begin{aligned}
 \mathbf{A}^T \mathbf{A} &= \begin{pmatrix} n & 0 \\ 0 & \sum (x_i - \bar{x})^2 \end{pmatrix} \\
 \mathbf{A}^T \mathbf{A}^{-1} &= \begin{pmatrix} 1/n & 0 \\ 0 & 1/\sum (x_i - \bar{x})^2 \end{pmatrix} \\
 \mathbf{A}^T \mathbf{y} &= \begin{pmatrix} \sum y_i \\ \sum y_i (x_i - \bar{x}) \end{pmatrix} \\
 \mathbf{A}^T \mathbf{A}^{-1} \mathbf{A}^T \mathbf{y} &= \begin{pmatrix} \frac{1}{n} \sum y_i \\ \frac{\sum y_i (x_i - \bar{x})}{\sum (x_i - \bar{x})^2} \end{pmatrix} \\
 &= \begin{pmatrix} \bar{y} \\ SC(xy)/SC(xx) \end{pmatrix}
 \end{aligned}$$

donde $SC(xy) = \sum_i (x_i - \bar{x})(y_i - \bar{y})$ y $SC(xx) = \sum_i (x_i - \bar{x})^2$.

Las distribuciones a posteriori de α y β son independientes con medias iguales a los estimadores mínimos cuadrados:

$$\alpha|y \sim \mathcal{N}\left(\bar{y}, \frac{1}{n\phi}\right)$$
$$\beta|y \sim \mathcal{N}\left(\frac{SC(xy)}{SC(xx)}, \frac{1}{\phi SC(xx)}\right)$$

Ejemplo 69 *Volviendo al Ejemplo 61 supongamos una distribución a priori uniforme para $\theta = (\mu, \alpha_2, \beta_2, \beta_3)^T$.*

Tenemos

$$\mathbf{A}^T \mathbf{A} = \begin{pmatrix} 6 & 3 & 2 & 2 \\ 3 & 3 & 1 & 1 \\ 2 & 1 & 2 & 0 \\ 2 & 1 & 0 & 2 \end{pmatrix}$$
$$(\mathbf{A}^T \mathbf{A})^{-1} = \begin{pmatrix} 2/3 & -1/3 & -1/2 & -1/2 \\ -1/3 & 2/3 & 0 & 0 \\ -1/2 & 0 & 1 & 1/2 \\ -1/2 & 0 & 1/2 & 1 \end{pmatrix}$$
$$\mathbf{A}^T \mathbf{y} = \begin{pmatrix} 6\bar{y}_{..} \\ 3\bar{y}_{2.} \\ 2\bar{y}_{.2} \\ 2\bar{y}_{.3} \end{pmatrix}$$

donde $\bar{y}_{..} = \frac{1}{6} \sum_i \sum_j y_{ij}$, $\bar{y}_{2.} = \frac{1}{3} \sum_j y_{2j}$, etc.

Entonces por ejemplo, la distribución a posteriori de α_2 es normal con media $2\bar{y}_{2.} - 2\bar{y}_{..}$ y varianza $2/(3\phi)$.

Cuando la varianza \mathbf{C} es desconocida

Consideramos sólo el caso: $\mathbf{C} = \frac{1}{\phi}\mathbf{D}$ con \mathbf{D} conocida (por ejemplo $\mathbf{D} = \mathbf{I}$).

Supongamos la distribución a priori no informativa

$$f(\boldsymbol{\theta}, \phi) \propto \frac{1}{\phi}.$$

Entonces, se tiene

Teorema 12 *La distribución a posteriori es*

$$\boldsymbol{\theta}|\phi, \mathbf{y} \sim \mathcal{N}\left(\mathbf{B}\mathbf{b}, \frac{1}{\phi}\mathbf{B}\right) \quad \text{donde}$$

$$\mathbf{B}^{-1} = \mathbf{A}^T \mathbf{D}^{-1} \mathbf{A}$$

$$\mathbf{b} = \mathbf{A}^T \mathbf{D}^{-1} \mathbf{y}$$

$$\phi|\mathbf{y} \sim \mathcal{G}\left(\frac{n-p}{2}, \frac{\mathbf{y}^T \mathbf{D}^{-1} \mathbf{y} - \mathbf{b}^T \mathbf{B} \mathbf{b}}{2}\right)$$

Demostración

La demostración es similar a la del teorema 11.
Se tiene

$$\begin{aligned} f(\boldsymbol{\theta}, \phi | \mathbf{y}) &\propto \phi^{-1} \phi^{\frac{n}{2}} \exp\left(-\frac{\phi}{2}(\mathbf{y} - \mathbf{A}\boldsymbol{\theta})^T \mathbf{D}^{-1}(\mathbf{y} - \mathbf{A}\boldsymbol{\theta})\right) \\ &\propto \phi^{\frac{n}{2}-1} \exp\left(-\frac{\phi}{2}\left[(\boldsymbol{\theta} - \mathbf{B}\mathbf{b})^T \mathbf{B}^{-1}(\boldsymbol{\theta} - \mathbf{B}\mathbf{b})\right.\right. \\ &\quad \left.\left.+ \mathbf{y}^T \mathbf{D}^{-1} \mathbf{y} - (\mathbf{B}\mathbf{b})^T \mathbf{B}^{-1}(\mathbf{B}\mathbf{b})\right]\right) \\ f(\phi | \mathbf{y}) &\propto \phi^{\frac{n-p}{2}-1} \exp\left(-\frac{\phi}{2}\left[\mathbf{y}^T \mathbf{D}^{-1} \mathbf{y} - \mathbf{b}^T \mathbf{B}\mathbf{b}\right]\right) \end{aligned}$$

que es el núcleo de una distribución gamma. \diamond

El resultado implica que la distribución a posteriori marginal de $\boldsymbol{\theta}$ será una distribución t, no centrada y multivariante. Es muy difícil tratar con esta distribución excepto en algunos casos especiales.

Ejemplo 70 *Volviendo al Ejemplo 68, tenemos*

$$\begin{aligned}
 \mathbf{y}^T \mathbf{D}^{-1} \mathbf{y} &= \sum_{i=1}^n y_i^2 \\
 \mathbf{b}^T \mathbf{B} \mathbf{b} &= \left(n\bar{y}, \sum_{i=1}^n (x_i - \bar{x})y_i \right) \begin{pmatrix} \bar{y} \\ SC(xy)/SC(xx) \end{pmatrix} \\
 &= n\bar{y}^2 + SC(xy)^2/SC(xx) \\
 \mathbf{y}^T \mathbf{D}^{-1} \mathbf{y} - \mathbf{b}^T \mathbf{B} \mathbf{b} &= SC(yy) - SC(xy)^2/SC(xx) \\
 \phi | \mathbf{y} &\sim \mathcal{G} \left(\frac{n-2}{2}, \frac{SC(yy) - SC(xy)^2/SC(xx)}{2} \right)
 \end{aligned}$$

Observamos que el estimador clásico de la varianza residual es

$$s^2 = \frac{1}{n-2} \left(SC(yy) - \frac{SC(xy)^2}{SC(xx)} \right).$$

Entonces, se puede demostrar que las distribuciones marginales de α y β son independientes t no centradas y (por ejemplo) un intervalo de credibilidad para β es

$$\frac{SC(xy)}{SC(xx)} \pm \frac{s}{\sqrt{SC(xx)}} t_{n-2}(,025).$$

Este intervalo es igual al intervalo clásico de confianza.

En el caso de que la varianza es completamente desconocida se necesitan métodos numéricos para calcular las distribuciones a posteriori.