

MAT-269: Sesión 13

Regresión Multivariada I

Felipe Osorio

fosorios.mat.utfsm.cl

Departamento de Matemática, UTFSM



Modelo de regresión multivariado

En esta sección extendemos el modelo de regresión lineal considerando que ahora se dispone de k variables de respuesta. El **modelo lineal multivariado** asume la forma

$$\mathbf{Y} = \mathbf{X}\mathbf{B} + \mathbf{U},$$

donde \mathbf{Y} y \mathbf{U} son matrices aleatorias $n \times k$, \mathbf{X} es matriz de diseño $n \times p$ y \mathbf{B} es matriz de **coeficientes de regresión** $p \times k$. Asumiremos que $\text{rg}(\mathbf{X}) = p$ y $n \geq p + k$.

Además supondremos que las filas de la matriz de **disturbios aleatorios** son **independientes** $N_p(\mathbf{0}, \Sigma)$. Es decir,

$$\mathbf{U} \sim N_{n,k}(\mathbf{0}, \mathbf{I}_n \otimes \Sigma),$$

o análogamente

$$\mathbf{Y} \sim N_{n,k}(\mathbf{X}\mathbf{B}, \mathbf{I}_n \otimes \Sigma).$$



Resultado 1

Si $Y \sim N_{n,k}(XB, I_n \otimes \Sigma)$ y $n \geq k + p$ los estimadores máximo verosímiles de B y Σ son

$$\hat{B} = (X^T X)^{-1} X^T Y,$$
$$\hat{\Sigma} = \frac{1}{n} (Y - X\hat{B})^T (Y - X\hat{B})$$

Además $(\hat{B}, \hat{\Sigma})$ es suficiente para (B, Σ) .



Demostración:

En efecto, como $\mathbf{Y} \sim N_{n,k}(\mathbf{XB}, \mathbf{I}_n \otimes \Sigma)$, la función de densidad conjunta de \mathbf{Y} es

$$f(\mathbf{Y}) = (2\pi)^{-np/2} |\Sigma|^{-n/2} \exp \left\{ -\frac{1}{2} \text{tr}(\mathbf{Y} - \mathbf{XB})\Sigma^{-1}(\mathbf{Y} - \mathbf{XB})^\top \right\},$$

ignorando términos que no involucran $\theta = (\mathbf{B}, \Sigma)$, tenemos

$$\ell_n(\mathbf{B}, \Sigma) = -\frac{n}{2} \log |\Sigma| - \frac{1}{2} \text{tr} \Sigma^{-1}(\mathbf{Y} - \mathbf{XB})^\top (\mathbf{Y} - \mathbf{XB}).$$

Diferenciando con relación a \mathbf{B} y Σ obtenemos

$$d_{\mathbf{B}} \ell_n(\mathbf{B}, \Sigma) = -\frac{1}{2} \text{tr} \Sigma^{-1} d_{\mathbf{B}} Q(\mathbf{B})$$

$$d_{\Sigma} \ell_n(\mathbf{B}, \Sigma) = -\frac{n}{2} \text{tr} \Sigma^{-1} d\Sigma + \frac{1}{2} \text{tr} \Sigma^{-1} (d\Sigma)\Sigma^{-1} Q(\mathbf{B})$$

donde $Q(\mathbf{B}) = (\mathbf{Y} - \mathbf{XB})^\top (\mathbf{Y} - \mathbf{XB})$.



Modelo de regresión multivariado

En efecto,

$$d_B Q(\mathbf{B}) = -(d\mathbf{B})^\top \mathbf{X}^\top (\mathbf{Y} - \mathbf{X}\mathbf{B}) - (\mathbf{Y} - \mathbf{X}\mathbf{B})^\top \mathbf{X} d\mathbf{B},$$

de este modo

$$d_B \ell_n(\mathbf{B}, \boldsymbol{\Sigma}) = \frac{1}{2} \operatorname{tr} \boldsymbol{\Sigma}^{-1} \{ (d\mathbf{B})^\top \mathbf{X}^\top (\mathbf{Y} - \mathbf{X}\mathbf{B}) + (\mathbf{Y} - \mathbf{X}\mathbf{B})^\top \mathbf{X} d\mathbf{B} \},$$

recordando que $\operatorname{tr} \mathbf{A} = \operatorname{tr} \mathbf{A}^\top$ y como $\boldsymbol{\Sigma}$ es simétrica

$$d_B \ell_n(\mathbf{B}, \boldsymbol{\Sigma}) = \operatorname{tr} \boldsymbol{\Sigma}^{-1} (\mathbf{Y} - \mathbf{X}\mathbf{B})^\top \mathbf{X} d\mathbf{B},$$

el diferencial es cero si y sólo si

$$\mathbf{X}^\top (\mathbf{Y} - \mathbf{X}\mathbf{B}) = \mathbf{0},$$

es decir $\hat{\mathbf{B}}$ es solución del sistema de ecuaciones

$$\mathbf{X}^\top \mathbf{X} \hat{\mathbf{B}} = \mathbf{X}^\top \mathbf{Y},$$

como $\operatorname{rg}(\mathbf{X}) = p$, tenemos $\hat{\mathbf{B}} = (\mathbf{X}^\top \mathbf{X})^{-1} \mathbf{X}^\top \mathbf{Y}$.



Modelo de regresión multivariado

Por otro lado,

$$d_{\Sigma} Q(\mathbf{B}) = -\frac{1}{2} \operatorname{tr} \Sigma^{-1} (n\Sigma - Q(\mathbf{B})) \Sigma^{-1} d\Sigma,$$

y por tanto,

$$\widehat{\Sigma} = \frac{1}{n} Q(\widehat{\mathbf{B}}).$$

Note además que

$$\begin{aligned} (\mathbf{Y} - \mathbf{X}\mathbf{B})^{\top} (\mathbf{Y} - \mathbf{X}\mathbf{B}) &= (\mathbf{Y} - \mathbf{X}\widehat{\mathbf{B}} + \mathbf{X}\widehat{\mathbf{B}} - \mathbf{X}\mathbf{B})^{\top} (\mathbf{Y} - \mathbf{X}\widehat{\mathbf{B}} + \mathbf{X}\widehat{\mathbf{B}} - \mathbf{X}\mathbf{B}) \\ &= Q(\widehat{\mathbf{B}}) + (\widehat{\mathbf{B}} - \mathbf{B})^{\top} \mathbf{X}^{\top} \mathbf{X} (\widehat{\mathbf{B}} - \mathbf{B}) \end{aligned}$$

(pues $\mathbf{X}^{\top} (\mathbf{Y} - \mathbf{X}\widehat{\mathbf{B}}) = 0$), de ahí que

$$\begin{aligned} L(\mathbf{B}, \Sigma) &= |\Sigma|^{-n/2} \exp \left\{ -\frac{1}{2} \operatorname{tr} \Sigma^{-1} (\mathbf{Y} - \mathbf{X}\mathbf{B})^{\top} (\mathbf{Y} - \mathbf{X}\mathbf{B}) \right\} \\ &= |\Sigma|^{-n/2} \exp \left\{ -\frac{1}{2} \operatorname{tr} \Sigma^{-1} (Q(\widehat{\mathbf{B}}) + (\widehat{\mathbf{B}} - \mathbf{B})^{\top} \mathbf{X}^{\top} \mathbf{X} (\widehat{\mathbf{B}} - \mathbf{B})) \right\} \\ &= |\Sigma|^{-n/2} \exp \left\{ -\frac{n}{2} \operatorname{tr} \widehat{\Sigma} \Sigma^{-1} + \frac{1}{2} \operatorname{tr} \Sigma^{-1} (\widehat{\mathbf{B}} - \mathbf{B})^{\top} \mathbf{X}^{\top} \mathbf{X} (\widehat{\mathbf{B}} - \mathbf{B}) \right\}, \end{aligned}$$

es decir $(\widehat{\mathbf{B}}, \widehat{\Sigma})$ es suficiente para (\mathbf{B}, Σ) .



Resultado 2

Si $\mathbf{Y} \sim N_{n,k}(\mathbf{X}\mathbf{B}, \mathbf{I}_n \otimes \mathbf{\Sigma})$ los estimadores máximo verosímiles $\widehat{\mathbf{B}}$ y $\widehat{\mathbf{\Sigma}}$ son independientemente distribuidos como:

$$\begin{aligned}\widehat{\mathbf{B}} &\sim N_{q,k}(\mathbf{B}, (\mathbf{X}^\top \mathbf{X})^{-1} \otimes \mathbf{\Sigma}), \\ n\widehat{\mathbf{\Sigma}} &\sim W_k(n-p, \mathbf{\Sigma}).\end{aligned}$$

Demostración:

Sea $\mathbf{E} = \mathbf{Y} - \mathbf{X}\widehat{\mathbf{B}} = \mathbf{Y} - \mathbf{H}\mathbf{Y} = (\mathbf{I} - \mathbf{H})\mathbf{Y}$, con

$$\mathbf{H} = \mathbf{X}(\mathbf{X}^\top \mathbf{X})^{-1} \mathbf{X}^\top.$$

Sea $\mathbf{M} = \mathbf{I} - \mathbf{H}$, entonces

$$\mathbf{M}\mathbf{X} = (\mathbf{I} - \mathbf{H})\mathbf{X} = \mathbf{0}, \quad \mathbf{M}^2 = \mathbf{M}.$$

De este modo,

$$\mathbf{E}^\top \mathbf{E} = \mathbf{Y}^\top (\mathbf{I} - \mathbf{H})\mathbf{Y} = \mathbf{Y}^\top \mathbf{M}\mathbf{Y} = n\widehat{\mathbf{\Sigma}}.$$



Modelo de regresión multivariado

Considere la matriz

$$\begin{pmatrix} \hat{\mathbf{B}} \\ \mathbf{E} \end{pmatrix} = \begin{pmatrix} (\mathbf{X}^\top \mathbf{X})^{-1} \mathbf{X}^\top \\ \mathbf{M} \end{pmatrix} \mathbf{Y}$$

luego $(\hat{\mathbf{B}}^\top, \mathbf{E}^\top)^\top$ es normal con media

$$\mathbb{E} \begin{pmatrix} \hat{\mathbf{B}} \\ \mathbf{E} \end{pmatrix} = \begin{pmatrix} (\mathbf{X}^\top \mathbf{X})^{-1} \mathbf{X}^\top \\ \mathbf{M} \end{pmatrix} \mathbb{E}(\mathbf{Y}) = \begin{pmatrix} \hat{\mathbf{B}} \\ \mathbf{E} \end{pmatrix} = \begin{pmatrix} (\mathbf{X}^\top \mathbf{X})^{-1} \mathbf{X}^\top \\ \mathbf{M} \end{pmatrix} \mathbf{X} \mathbf{B} = \begin{pmatrix} \mathbf{B} \\ \mathbf{0} \end{pmatrix}$$

mientras que la covarianza es:

$$\begin{aligned} & \left(\begin{pmatrix} (\mathbf{X}^\top \mathbf{X})^{-1} \mathbf{X}^\top \\ \mathbf{M} \end{pmatrix} \otimes \mathbf{I}_p \right) (\mathbf{I}_n \otimes \boldsymbol{\Sigma}) \left((\mathbf{X} (\mathbf{X}^\top \mathbf{X})^{-1}, \mathbf{M}^\top) \otimes \mathbf{I}_p \right) \\ &= \begin{pmatrix} (\mathbf{X}^\top \mathbf{X})^{-1} \mathbf{X}^\top \\ \mathbf{M} \end{pmatrix} (\mathbf{X} (\mathbf{X}^\top \mathbf{X})^{-1}, \mathbf{M}^\top) \otimes \boldsymbol{\Sigma} \\ &= \begin{pmatrix} (\mathbf{X}^\top \mathbf{X})^{-1} & (\mathbf{X}^\top \mathbf{X})^{-1} \mathbf{X}^\top \mathbf{M}^\top \\ \mathbf{M} \mathbf{X} (\mathbf{X}^\top \mathbf{X})^{-1} & \mathbf{M} \mathbf{M}^\top \end{pmatrix} \otimes \boldsymbol{\Sigma} \end{aligned}$$



En efecto,

$$\text{Cov} \left(\text{vec} \begin{pmatrix} \hat{\mathbf{B}} \\ \mathbf{E} \end{pmatrix} \right) = \begin{pmatrix} (\mathbf{X}^\top \mathbf{X})^{-1} & \mathbf{0} \\ \mathbf{0} & \mathbf{M} \end{pmatrix} \otimes \boldsymbol{\Sigma}.$$

De ahí que

$$\hat{\mathbf{B}} \sim \text{N}(\mathbf{B}, (\mathbf{X}^\top \mathbf{X})^{-1} \otimes \boldsymbol{\Sigma}), \quad \mathbf{E} \sim \text{N}(\mathbf{0}, \mathbf{M} \otimes \boldsymbol{\Sigma}),$$

luego $\hat{\mathbf{B}}$ y \mathbf{E} son independientes. La parte final del resultado sigue de notar que $n\hat{\boldsymbol{\Sigma}}$ puede ser escrito como $\mathbf{E}^\top \mathbf{E}$.



Ejemplo: Datos de dializadores (Vonesh y Carter, 1987)¹

Datos de un estudio para evaluar las características de **ultrafiltración** in vivo de un **grupo de dializadores**.

Los dializadores se evaluaron en **tres centros** y cada uno de ellos utilizó un tipo **diferente** de sistema de administración de dializado.

Los datos corresponden a la **tasa de ultrafiltración de los 4 dializadores** Y_1, Y_2, Y_3, Y_4 .

Este conjunto de datos ha sido usado en varios artículos científicos y bajo el **supuesto de normalidad**. Además, este supuesto no es rechazado por el test de Mardia (1974), basado en las medidas de sesgo y kurtosis multivariadas.

¹Biometrics 43, 617-628.



Ejemplo: Datos de dializadores

```
# Carga biblioteca 'heavy' y datos de ejemplo
> library(heavy)
> data(dialyzer)

> dialyzer
   y1   y2   y3   y4 centre
1  600 1026 1470 1890      1
2  516  930 1380 1770      1
3  480  900 1380 1860      1
4  528  930 1410 1872      1
5  540  978 1410 1920      1
6  564  996 1422 1920      1
7  564 1062 1500 1980      1
8  492  900 1392 1860      1
9  516  960 1380 1800      1
10 528  930 1356 1860      1
11 564 1020 1380 1884      1

...

38 480  780 1140 1710      3
39 540  840 1200 1650      3
40 780  780 1290 1680      3
```



Ejemplo: Datos de dializadores

Vamos a considerar un modelo de regresión multivariada con matriz de respuestas

$$\mathbf{Y} = (\mathbf{Y}_1, \mathbf{Y}_2, \mathbf{Y}_3, \mathbf{Y}_4),$$

y matriz de diseño

$$\mathbf{X} = \begin{pmatrix} \mathbf{1}_{17} & \mathbf{0} & \mathbf{0} \\ \mathbf{0} & \mathbf{1}_{12} & \mathbf{0} \\ \mathbf{0} & \mathbf{0} & \mathbf{1}_{11} \end{pmatrix}.$$

Por tanto tenemos que $\mathbf{B} \in \mathbb{R}^{3 \times 4}$ y Σ es matriz simétrica y definida positiva 4×4 .



Ejemplo: Datos de dializadores

```
# Ajuste de un modelo de regresión lineal multivariado
# (bajo errores normales)
> fm <- heavyLm(cbind(y1,y2,y3,y4) ~ -1 + centre, data = dialyzer,
+             family = normal())

# Salida con estimación de los coeficientes de regresión
> fm
Call:
heavyLm(formula = cbind(y1, y2, y3, y4) ~ -1 + centre, data = dialyzer,
        family = normal())
Converged in 1 iterations

Coefficients:
           y1           y2           y3           y4
centre1  541.0588  973.4118 1404.3529 1873.4118
centre2  472.5000  830.5000 1230.5000 1653.0000
centre3  591.8182  850.9091 1276.3636 1655.4545

Degrees of freedom: 40 total; 37 residual
```



Ejemplo: Datos de dializadores

```
# Salida de función 'summary'
> summary(fm)
Multivariate regression under heavy-tailed distributions
Data: dialyzer; Family: normal()

Coefficients:
          y1          y2          y3          y4
centre1 541.0588  973.4118 1404.3529 1873.4118
centre2 472.5000  830.5000 1230.5000 1653.0000
centre3 591.8182  850.9091 1276.3636 1655.4545

Scatter matrix estimate:
  y1      y2      y3      y4
y1 4402.5848
y2 380.6878 2337.0659
y3 867.8210 2712.4908 6160.8440
y4 506.2871 1987.2839 4808.4436 7134.5452

Degrees of freedom: 40 total; 37 residual
Log-likelihood: -761.7318 on 22 degrees of freedom
```



Ejemplo: Datos de dializadores

Es decir, tenemos que

$$\hat{\mathbf{B}} = \begin{pmatrix} 541.059 & 973.412 & 1404.353 & 1873.412 \\ 472.500 & 830.500 & 1230.500 & 1653.000 \\ 591.818 & 850.909 & 1276.364 & 1655.455 \end{pmatrix}.$$

y

$$\hat{\mathbf{\Sigma}} = \begin{pmatrix} 4402.585 & 380.688 & 867.821 & 506.287 \\ 380.688 & 2337.066 & 2712.491 & 1987.284 \\ 867.821 & 2712.491 & 6160.844 & 4808.444 \\ 506.287 & 1987.284 & 4808.444 & 7134.545 \end{pmatrix}.$$

Además, $\ell_n(\hat{\mathbf{B}}, \hat{\mathbf{\Sigma}}) = -761.732$.



Ejemplo: Datos de dializadores

```
# Alternativamente, podemos usar la función 'lm' de R
> f0 <- lm(cbind(y1,y2,y3,y4) ~ -1 + centre, data = dialyzer)

# Salida:
> f0

Call:
lm(formula = cbind(y1, y2, y3, y4) ~ -1 + centre, data = dialyzer)

Coefficients:
          y1          y2          y3          y4
centre1  541.1   973.4  1404.4  1873.4
centre2  472.5   830.5  1230.5  1653.0
centre3  591.8   850.9  1276.4  1655.5
```

