

MAT-269: Sesión 15

Modelo GMANOVA


Felipe Osorio

fosorios.mat.utfsm.cl

Departamento de Matemática, UTFSM



Estudio de Ortodoncia (Potthoff y Roy, 1964)



- ▶ ¿Cómo manipular los distintos grupos e incorporar covariables?
- ▶ Se puede extender el modelo mediante incluir una matriz de diseño adicional:

$$Y = XBZ + E,$$

donde Z es matriz conocida.

- ▶ El modelo anterior se denomina modelo de curvas de crecimiento o GMANOVA.



Definición 1 (Modelo GMANOVA)

Un modelo GMANOVA (curvas de crecimiento) está definido como

$$Y = XBZ + E,$$

donde $X \in \mathbb{R}^{n \times m}$ y $Z \in \mathbb{R}^{q \times p}$ son matrices de diseño con $\text{rg}(X) = m$ y $\text{rg}(Z) = q$, respectivamente. $B \in \mathbb{R}^{q \times r}$ es matriz de coeficientes de regresión y

$$E \sim N_{n,p}(\mathbf{0}, I_n, \Sigma).$$

De ahí que

$$Y \sim N_{n,p}(XBZ, I_n, \Sigma).$$



Considere

$$Q(B) = (Y - XBZ)^T(Y - XBZ).$$

El **estimador LS** en el modelo GMANOVA está definido como la solución del problema:

$$\min_B \operatorname{tr} Q(B) := \min_B \operatorname{tr} (Y - XBZ)^T(Y - XBZ).$$

En efecto, diferenciando con relación a B , obtenemos

$$\begin{aligned} d_B \operatorname{tr} Q(B) &= -\operatorname{tr} Z^T (dB)^T X^T (Y - XBZ) - \operatorname{tr} (Y - XBZ)^T X (dB) Z \\ &= -2 \operatorname{tr} X^T (Y - XBZ) Z^T (dB)^T, \end{aligned}$$

de ahí que la **ecuación de estimación para B** es dada por:

$$X^T (Y - XBZ) Z^T = 0.$$



Desde la ecuación de estimación $\mathbf{X}^\top (\mathbf{Y} - \mathbf{X}\mathbf{B}\mathbf{Z})\mathbf{Z}^\top = \mathbf{0}$, tenemos que

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

es decir el **estimador LS para \mathbf{B}** asume la forma:

$$\hat{\mathbf{B}} = (\mathbf{X}^\top \mathbf{X})^{-1} \mathbf{X}^\top \mathbf{Y} \mathbf{Z}^\top (\mathbf{Z} \mathbf{Z}^\top)^{-1}.$$

Por otro lado,

$$\begin{aligned} d_B^2 \operatorname{tr} \mathbf{Q}(\mathbf{B}) &= 2 \operatorname{tr} \mathbf{X}^\top \mathbf{X} (\mathbf{d}\mathbf{B}) \mathbf{Z} \mathbf{Z}^\top (\mathbf{d}\mathbf{B})^\top \\ &= 2 (\mathbf{d} \operatorname{vec} \mathbf{B})^\top (\mathbf{Z} \mathbf{Z}^\top \otimes \mathbf{X}^\top \mathbf{X}) \mathbf{d} \operatorname{vec} \mathbf{B}, \end{aligned}$$

y como $\mathbf{Z} \mathbf{Z}^\top \otimes \mathbf{X}^\top \mathbf{X}$ es matriz positiva definida, sigue que $\hat{\mathbf{B}}$ es **mínimo (global)**.



Resultado 1 (Distribución del estimador LS de B en GMANOVA)

En el modelo GMANOVA, la **distribución del estimador LS**, \hat{B} puede ser escrita como:

$$\hat{B} \sim N_{q,p}(B, (X^T X)^{-1}, (ZZ^T)^{-1} Z \Sigma Z^T (ZZ^T)^{-1}).$$

Es decir,

$$\text{Cov}(\text{vec } \hat{B}^T) = (X^T X)^{-1} \otimes (ZZ^T)^{-1} Z \Sigma Z^T (ZZ^T)^{-1}.$$

Demostración:

El resultado sigue desde $Y \sim N_{q,p}(X B Z, I_n, \Sigma)$ y de la definición del estimador mínimos cuadrados:

$$\hat{B} = (X^T X)^{-1} X^T Y Z^T (ZZ^T)^{-1}.$$



Para el ejemplo de **datos dentales** tenemos que:

$$\mathbf{X} = \begin{pmatrix} \mathbf{1}_{16} & \mathbf{0} \\ \mathbf{0} & \mathbf{1}_{11} \end{pmatrix}, \quad \mathbf{Z} = \begin{pmatrix} 1 & 1 & 1 & 1 \\ 8 & 10 & 12 & 14 \end{pmatrix},$$

mientras que $\mathbf{Y} \in \mathbb{R}^{27 \times 4}$. De este modo, tenemos que $\mathbf{B} \in \mathbb{R}^{2 \times 2}$ y Σ es matriz definida positiva 4×4 .



Comandos en R

```
library(nlme) # Biblioteca nlme contiene los datos 'dentales'  
data(Orthodont)  
names(Orthodont)  
[1] "distance" "age"          "Subject"  "Sex"  
  
# matriz de respuestas  
y <- Orthodont$distance  
y <- matrix(y, ncol = 4, byrow = TRUE)
```

```
y  
      [,1] [,2] [,3] [,4]  
[1,] 26.0 25.0 29.0 31.0  
[2,] 21.5 22.5 23.0 26.5  
[3,] 23.0 22.5 24.0 27.5  
[4,] 25.5 27.5 26.5 27.0
```

...

```
[24,] 23.0 23.0 23.5 24.0  
[25,] 20.0 21.0 22.0 21.5  
[26,] 16.5 19.0 19.0 19.5  
[27,] 24.5 25.0 28.0 28.0
```



```
# matrices de diseno
x <- cbind(c(rep(1,16), rep(0,11)), c(rep(0,16), rep(1,11)))
z <- rbind(rep(1,4), c(8,10,12,14))

# contruye estimador para B
xx <- crossprod(x)
zz <- crossprod(t(z))
xyz <- crossprod(x, y %*% t(z))
B <- solve(xx, xyz %*% solve(zz))

# Salida
B
      Intercept      age
Male    16.34063 0.7843750
Female  17.37273 0.4795455
```



```
# construye estimador para Sigma
```

```
res <- y - x %*% B %*% z
```

```
n <- nrow(y)
```

```
Sigma <- crossprod(res) / n
```

```
# Salida
```

```
Sigma
```

```
      [,1]      [,2]      [,3]      [,4]  
[1,] 5.054480 2.457757 3.615701 2.531994  
[2,] 2.457757 3.958162 2.717032 3.039186  
[3,] 3.615701 2.717032 5.978775 3.821699  
[4,] 2.531994 3.039186 3.821699 4.629217
```

```
# Calcula covarianza (estimada) del estimador de B
```

```
kronecker(solve(xx), solve(zz, z %*% Sigma %*% t(z)) %*% solve(zz))
```

```
      [,1]      [,2]      [,3]      [,4]  
[1,] 0.96056230 -0.071385371 0.00000000 0.00000000  
[2,] -0.07138537 0.006848071 0.00000000 0.00000000  
[3,] 0.00000000 0.000000000 1.3971815 -0.10383327  
[4,] 0.00000000 0.000000000 -0.1038333 0.00996083
```



- ▶ Primeramente, asumiremos que la matriz Σ es **no estructurada**, es decir corresponde a una **matriz simétrica y definida positiva**.
- ▶ Luego consideraremos **estructuras lineales** del tipo:

$$\Sigma = \mathbf{Z}^\top \mathbf{\Gamma} \mathbf{Z} + \mathbf{G}^\top \mathbf{\Phi} \mathbf{G},$$

donde $\mathbf{G} \in \mathcal{Q}$ tal que

$$\mathcal{Q} = \{\mathbf{G} : \mathbf{G} \in \mathbb{R}^{p \times (p-m)}, \mathbf{G} \mathbf{Z}^\top = \mathbf{0}\}.$$

Clase que es conocida como **estructura de covarianza (simple) de Rao**.



Sea $\Theta = (\mathbf{B}, \Sigma)$, entonces la **función de log-verosimilitud** adopta la forma

$$\begin{aligned}\ell(\Theta) &= \log \left\{ (2\pi)^{-np/2} |\Sigma|^{-n/2} \exp \left\{ -\frac{1}{2} \text{tr} \Sigma^{-1} \mathbf{Q}(\mathbf{B}) \right\} \right\} \\ &= -\frac{np}{2} \log 2\pi - \frac{n}{2} \log |\Sigma| - \frac{1}{2} \text{tr} \Sigma^{-1} \mathbf{Q}(\mathbf{B}),\end{aligned}$$

donde

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

corresponde a la matriz de **suma de productos cruzados** (de errores).



Diferenciando con relación a B , obtenemos:

$$d_B \ell(\Theta) = -\frac{1}{2} \text{tr} \Sigma^{-1} d_B Q(B),$$

por otro lado,

$$d_B Q(\Theta) = -\text{tr} \left\{ (Y - XBZ)^\top X (dB) Z + Z^\top (dB)^\top X^\top (Y - XBZ) \right\},$$

De este modo, recordando que $\text{tr} A = \text{tr} A^\top$, obtenemos

$$d_B \ell(\Theta) = \text{tr} Z \Sigma^{-1} (Y - XBZ)^\top X dB.$$

Por tanto, la **ecuación de estimación para B** (obtenida desde $d_B \ell(\Theta) = 0$) asume la forma:

$$X^\top (Y - XBZ) \Sigma^{-1} Z^\top = 0,$$



Ahora, diferenciando con relación a Σ , obtenemos:

$$\begin{aligned}d_{\Sigma} \ell(\Theta) &= -\frac{n}{2} \operatorname{tr} \Sigma^{-1} d\Sigma + \frac{1}{2} \operatorname{tr} \Sigma^{-1} (d\Sigma) \Sigma^{-1} Q(B) \\ &= -\frac{n}{2} \operatorname{tr} \Sigma^{-1} \left(\Sigma - \frac{1}{n} Q(B) \right) \Sigma^{-1} d\Sigma.\end{aligned}$$

De este modo, la ecuación de estimación para Σ es dada por:

$$n\Sigma - Q(B) = 0.$$



Por tanto, los MLEs de B y Σ deben satisfacer el siguiente sistema de ecuaciones:

$$\begin{aligned} \mathbf{X}^\top (\mathbf{Y} - \mathbf{X}\hat{B}\mathbf{Z})\hat{\Sigma}^{-1}\mathbf{Z}^\top &= \mathbf{0} \\ n\hat{\Sigma} - Q(\hat{B}) &= \mathbf{0}. \end{aligned} \tag{1}$$

El siguiente resultado, presenta la solución $(\hat{B}, \hat{\Sigma})$ para las ecuaciones de verosimilitud anteriores.

Resultado 2 (MLE-UN en GMANOVA)

Para el modelo GMANOVA con matrices de diseño X , Z de rango completo. Se tiene que la **solución de la ecuación de verosimilitud en (1)** es única y es dada por

$$\hat{B} = (\mathbf{X}^\top \mathbf{X})^{-1} \mathbf{X}^\top \mathbf{Y} \mathbf{S}^{-1} \mathbf{Z}^\top (\mathbf{Z} \mathbf{S}^{-1} \mathbf{Z}^\top)^{-1},$$

y

$$\hat{\Sigma} = \frac{1}{n} (\mathbf{Y} - \mathbf{X}\hat{B}\mathbf{Z})^\top (\mathbf{Y} - \mathbf{X}\hat{B}\mathbf{Z})$$

donde $\mathbf{S} = \mathbf{Y}^\top (\mathbf{I} - \mathbf{H}_X) \mathbf{Y}$ y $\mathbf{H}_X = \mathbf{X}(\mathbf{X}^\top \mathbf{X})^{-1} \mathbf{X}$.



Demostración:

Considere

$$\begin{aligned} & (\mathbf{Y} - \mathbf{XBZ})^\top (\mathbf{Y} - \mathbf{XBZ}) \\ &= \{(\mathbf{Y} - \mathbf{H}_X \mathbf{Y}) + (\mathbf{H}_X \mathbf{Y} - \mathbf{XBZ})\}^\top \{(\mathbf{Y} - \mathbf{H}_X \mathbf{Y}) + (\mathbf{H}_X \mathbf{Y} - \mathbf{XBZ})\} \\ &= \mathbf{Y}^\top (\mathbf{I} - \mathbf{H}_X) \mathbf{Y} + \mathbf{Y}^\top (\mathbf{I} - \mathbf{H}_X) (\mathbf{H}_X \mathbf{Y} - \mathbf{XBZ}) \\ &+ (\mathbf{H}_X \mathbf{Y} - \mathbf{XBZ})^\top (\mathbf{I} - \mathbf{H}_X) \mathbf{Y} + (\mathbf{H}_X \mathbf{Y} - \mathbf{XBZ})^\top (\mathbf{H}_X \mathbf{Y} - \mathbf{XBZ}), \end{aligned}$$

donde $\mathbf{H}_X = \mathbf{X}(\mathbf{X}^\top \mathbf{X})^{-1} \mathbf{X}^\top$ como $(\mathbf{I} - \mathbf{H}_X) \mathbf{H}_X = \mathbf{0}^1$, sigue que

$$\mathbf{Q}(\mathbf{B}) = \mathbf{Y}^\top (\mathbf{I} - \mathbf{H}_X) \mathbf{Y} + (\mathbf{H}_X \mathbf{Y} - \mathbf{XBZ})^\top (\mathbf{H}_X \mathbf{Y} - \mathbf{XBZ}).$$

Sea $\mathbf{U} = \mathbf{H}_X \mathbf{Y} - \mathbf{XBZ}$, luego podemos escribir la ecuación de verosimilitud $\mathbf{Q}(\mathbf{B}) - n\Sigma = \mathbf{0}$, como:

$$n\Sigma = \mathbf{S} + \mathbf{U}^\top \mathbf{U}, \quad \mathbf{S} = \mathbf{Y}^\top (\mathbf{I} - \mathbf{H}_X) \mathbf{Y}.$$

¹También, $(\mathbf{I} - \mathbf{H}_X) \mathbf{X} = \mathbf{0}$



Ahora

$$\frac{1}{n}\Sigma^{-1} = (\mathbf{S} + \mathbf{U}^T\mathbf{U})^{-1} = \mathbf{S}^{-1} - \mathbf{S}^{-1}\mathbf{U}^T(\mathbf{I} + \mathbf{U}\mathbf{S}^{-1}\mathbf{U}^T)^{-1}\mathbf{U}\mathbf{S}^{-1}.$$

Notando que

$$\begin{aligned} & [\mathbf{I} - (\mathbf{I} + \mathbf{U}\mathbf{S}^{-1}\mathbf{U}^T)^{-1}\mathbf{U}\mathbf{S}^{-1}\mathbf{U}](\mathbf{I} + \mathbf{U}\mathbf{S}^{-1}\mathbf{U}^T) \\ &= (\mathbf{I} + \mathbf{U}\mathbf{S}^{-1}\mathbf{U}^T)^{-1}[\mathbf{I} - \mathbf{U}\mathbf{S}^{-1}\mathbf{U}^T - \mathbf{U}\mathbf{S}^{-1}\mathbf{U}^T](\mathbf{I} + \mathbf{U}\mathbf{S}^{-1}\mathbf{U}^T) \\ &= \mathbf{I}, \end{aligned}$$

de donde sigue que

$$\begin{aligned} \frac{1}{n}\Sigma^{-1}\mathbf{U}^T &= \mathbf{S}^{-1}\mathbf{U}^T[\mathbf{I} - (\mathbf{I} + \mathbf{U}\mathbf{S}^{-1}\mathbf{U}^T)^{-1}\mathbf{U}\mathbf{S}^{-1}\mathbf{U}] \\ &= \mathbf{S}^{-1}\mathbf{U}^T(\mathbf{I} + \mathbf{U}\mathbf{S}^{-1}\mathbf{U}^T)^{-1} \end{aligned}$$



Desde la ecuación de verosimilitud para B , tenemos

$$\mathbf{X}^\top (\mathbf{Y} - \mathbf{X}\mathbf{B}\mathbf{Z})\boldsymbol{\Sigma}^{-1}\mathbf{Z}^\top = \mathbf{0}$$

$$\mathbf{X}^\top (\mathbf{H}_X\mathbf{Y} - \mathbf{X}\mathbf{B}\mathbf{Z})\boldsymbol{\Sigma}^{-1}\mathbf{Z}^\top = \mathbf{0}$$

$$\mathbf{X}^\top \mathbf{U}\boldsymbol{\Sigma}^{-1}\mathbf{Z}^\top = \mathbf{0}$$

$$n\mathbf{X}^\top (\mathbf{I} + \mathbf{U}\mathbf{S}^{-1}\mathbf{U}^\top)^{-1}\mathbf{U}\mathbf{S}^{-1}\mathbf{Z}^\top = \mathbf{0}$$

Sea $\mathbf{M} = \mathbf{I} + \mathbf{U}\mathbf{S}^{-1}\mathbf{U}^\top$, de ahí que la ecuación de estimación puede ser escrita como:

$$n\mathbf{X}^\top \mathbf{M}^{-1}(\mathbf{H}_X\mathbf{Y} - \mathbf{X}\mathbf{B}\mathbf{Z})\mathbf{S}^{-1}\mathbf{Z}^\top = \mathbf{0},$$

o bien,

$$\mathbf{X}^\top \mathbf{M}^{-1}\mathbf{X}\mathbf{B}\mathbf{Z}\mathbf{S}^{-1}\mathbf{Z}^\top = \mathbf{X}^\top \mathbf{M}^{-1}\mathbf{H}_X\mathbf{Y}\mathbf{S}^{-1}\mathbf{Z}^\top.$$



Tenemos que \mathbf{X} y \mathbf{Z} son de rango (columna y fila) completo,

$$\begin{aligned}\hat{\mathbf{B}} &= (\mathbf{X}^\top \mathbf{M}^{-1} \mathbf{X})^{-1} \mathbf{X}^\top \mathbf{M}^{-1} \mathbf{H}_X \mathbf{Y} \mathbf{S}^{-1} \mathbf{Z}^\top (\mathbf{Z} \mathbf{S}^{-1} \mathbf{Z}^\top)^{-1} \\ &= (\mathbf{X}^\top \mathbf{M}^{-1} \mathbf{X})^{-1} \mathbf{X}^\top \mathbf{M}^{-1} \mathbf{X} (\mathbf{X}^\top \mathbf{X})^{-1} \mathbf{X}^\top \mathbf{Y} \mathbf{S}^{-1} \mathbf{Z}^\top (\mathbf{Z} \mathbf{S}^{-1} \mathbf{Z}^\top)^{-1} \\ &= (\mathbf{X}^\top \mathbf{X})^{-1} \mathbf{X}^\top \mathbf{Y} \mathbf{S}^{-1} \mathbf{Z}^\top (\mathbf{Z} \mathbf{S}^{-1} \mathbf{Z}^\top)^{-1},\end{aligned}$$

donde

$$\mathbf{S} = \mathbf{Y}^\top (\mathbf{I} - \mathbf{H}_X) \mathbf{Y}.$$

De ahí que

$$\hat{\Sigma} = \frac{1}{n} \mathbf{Q}(\hat{\Sigma})$$



```
## Supondremos que los datos 'x', 'y', 'z' estan cargados en  
## nuestro directorio de trabajo.
```

```
# calculos en el modelo de regresion multivariado
```

```
xy <- crossprod(x, y)  
r <- y - x %*% solve(xx, xy)  
S <- crossprod(r)
```

```
# Salida
```

```
S  
      [,1]      [,2]      [,3]      [,4]  
[1,] 135.38636  67.92045  97.75568  67.75568  
[2,]  67.92045 104.61932  73.17898  82.92898  
[3,]  97.75568  73.17898 161.39347 103.26847  
[4,]  67.75568  82.92898 103.26847 124.64347
```



Comandos en R

```
# construye estimador para B
zsz <- z %>% solve(S, t(z))
rhs <- solve(S, t(z) %>% solve(zsz))
B <- solve(xx, xy) %>% rhs

# Salida
B
      Intercept      age
Male    15.84229  0.8268033
Female  17.42537  0.4763647

# construye estimador para Sigma
res <- y - x %>% B %>% z
n <- nrow(y)
Sigma <- crossprod(res) / n

# Salida
Sigma
      [,1]      [,2]      [,3]      [,4]
[1,] 5.119199  2.440902  3.610510  2.522243
[2,] 2.440902  3.927948  2.717514  3.062349
[3,] 3.610510  2.717514  5.979798  3.823461
[4,] 2.522243  3.062349  3.823461  4.617984
```



¿Existe alguna condición en la que el **estimador ML** bajo el modelo GMANOVA

$$\hat{B}_S = (\mathbf{X}^\top \mathbf{X})^{-1} \mathbf{X}^\top \mathbf{Y} \mathbf{S}^{-1} \mathbf{Z}^\top (\mathbf{Z} \mathbf{S}^{-1} \mathbf{Z}^\top)^{-1},$$

coincida con el **estimador LS**?

$$\hat{B} = (\mathbf{X}^\top \mathbf{X})^{-1} \mathbf{X}^\top \mathbf{Y} \mathbf{Z}^\top (\mathbf{Z} \mathbf{Z}^\top)^{-1},$$

Observación:

La respuesta a la pregunta anterior puede ser resuelto mediante **modelar la estructura de covarianza**.



Definición 2 (Estructura de covarianza simple de Rao)

La estructura de **covarianza simple de Rao (SCS)** es dada por

$$\Sigma = \mathbf{Z}^\top \Gamma \mathbf{Z} + \mathbf{G}^\top \Phi \mathbf{G},$$

donde $\mathbf{Z} \in \mathbb{R}^{q \times p}$ ($\text{rg}(\mathbf{Z}) = q$) y $\mathbf{G} \in \mathcal{Q}$, con

$$\mathcal{G} = \{\mathbf{G} : \mathbf{G} \in \mathbb{R}^{p \times (p-q)}, \mathbf{G}\mathbf{Z}^\top = \mathbf{0} = \mathbf{Z}\mathbf{G}^\top\}.$$



Resultado 3 (MLE-SCS en GMANOVA)

Para el modelo GMANOVA con *estructura de covarianza simple de Rao*, los estimadores ML pueden ser expresados como:

$$\hat{B} = (\mathbf{X}^\top \mathbf{X})^{-1} \mathbf{X}^\top \mathbf{Y} \mathbf{Z}^\top (\mathbf{Z} \mathbf{Z}^\top)^{-1}$$

$$\hat{\Gamma} = \frac{1}{n} (\mathbf{Z} \mathbf{Z}^\top)^{-1} \mathbf{Z} \mathbf{S} \mathbf{Z}^\top (\mathbf{Z} \mathbf{Z}^\top)^{-1}$$

$$\hat{\Phi} = \frac{1}{n} (\mathbf{G} \mathbf{G}^\top)^{-1} \mathbf{G} \mathbf{Y}^\top \mathbf{Y} \mathbf{G}^\top (\mathbf{G} \mathbf{G}^\top)^{-1}.$$



Sea

$$\tilde{\mathbf{Z}} = \begin{pmatrix} \mathbf{Z} \\ \mathbf{G} \end{pmatrix}.$$

Note que $\Sigma = |\mathbf{Z}^\top \Gamma \mathbf{Z} + \mathbf{G}^\top \Phi \mathbf{G}|$, puede ser escrito como

$$\begin{aligned} |\Sigma| &= \left| (\mathbf{Z}^\top, \mathbf{G}^\top) \begin{pmatrix} \Gamma & \mathbf{0} \\ \mathbf{0} & \Phi \end{pmatrix} \begin{pmatrix} \mathbf{Z} \\ \mathbf{G} \end{pmatrix} \right| = \left| \begin{pmatrix} \mathbf{Z} \\ \mathbf{G} \end{pmatrix} (\mathbf{Z}^\top, \mathbf{G}^\top) \begin{pmatrix} \Gamma & \mathbf{0} \\ \mathbf{0} & \Phi \end{pmatrix} \right| \\ &= \left| \begin{array}{cc} \mathbf{Z}\mathbf{Z}^\top & \mathbf{0} \\ \mathbf{0} & \mathbf{G}\mathbf{G}^\top \end{array} \right| \left| \begin{array}{cc} \Gamma & \mathbf{0} \\ \mathbf{0} & \Phi \end{array} \right| = |\mathbf{Z}\mathbf{Z}^\top| |\mathbf{G}\mathbf{G}^\top| |\Gamma| |\Phi|. \end{aligned}$$

Por otro lado,

$$\begin{aligned} \Sigma^{-1} &= \begin{pmatrix} \mathbf{Z} \\ \mathbf{G} \end{pmatrix}^{-1} \begin{pmatrix} \Gamma^{-1} & \mathbf{0} \\ \mathbf{0} & \Phi^{-1} \end{pmatrix} (\mathbf{Z}^\top, \mathbf{G}^\top)^{-1} \\ &= (\mathbf{Z}^\top (\mathbf{Z}\mathbf{Z}^\top)^{-1}, \mathbf{G}^\top (\mathbf{G}\mathbf{G}^\top)^{-1}) \begin{pmatrix} \Gamma^{-1} & \mathbf{0} \\ \mathbf{0} & \Phi^{-1} \end{pmatrix} \begin{pmatrix} ((\mathbf{Z}\mathbf{Z}^\top)^{-1} \mathbf{Z}) \\ ((\mathbf{G}\mathbf{G}^\top)^{-1} \mathbf{G}) \end{pmatrix} \\ &= \mathbf{Z}^\top (\mathbf{Z}\mathbf{Z}^\top)^{-1} \Gamma^{-1} (\mathbf{Z}\mathbf{Z}^\top)^{-1} \mathbf{Z} + \mathbf{G}^\top (\mathbf{G}\mathbf{G}^\top)^{-1} \Phi^{-1} (\mathbf{G}\mathbf{G}^\top)^{-1} \mathbf{G} \end{aligned}$$



Considere $\Theta = (\mathbf{B}, \mathbf{\Gamma}, \mathbf{\Phi})$, entonces la **función de log-verosimilitud** es dada por

$$\begin{aligned}\ell(\Theta) &= \log \left\{ (2\pi)^{-np/2} |\mathbf{\Sigma}|^{-n/2} \exp \left\{ -\frac{1}{2} \text{tr} \mathbf{\Sigma}^{-1} \mathbf{Q}(\mathbf{B}) \right\} \right\} \\ &= -\frac{np}{2} \log 2\pi - \frac{n}{2} \log |\mathbf{\Sigma}| - \frac{1}{2} \text{tr} \mathbf{\Sigma}^{-1} \mathbf{Q}(\mathbf{B}),\end{aligned}$$

donde

$$\mathbf{Q}(\mathbf{B}) = (\mathbf{Y} - \mathbf{X}\mathbf{B}\mathbf{Z})^\top (\mathbf{Y} - \mathbf{X}\mathbf{B}\mathbf{Z}).$$



Note que

$$\log |\Sigma| = \log |\mathbf{Z}\mathbf{Z}^\top| + \log |\mathbf{G}\mathbf{G}^\top| + \log |\Gamma| + \log |\Phi|.$$

Por otro lado,

$$\begin{aligned}\text{tr } \Sigma^{-1} \mathbf{Q}(\mathbf{B}) &= \text{tr } \mathbf{Z}^\top (\mathbf{Z}\mathbf{Z}^\top)^{-1} \Gamma^{-1} (\mathbf{Z}\mathbf{Z}^\top)^{-1} \mathbf{Z} \mathbf{Q}(\mathbf{B}) \\ &\quad + \text{tr } \mathbf{G}^\top (\mathbf{G}\mathbf{G}^\top)^{-1} \Phi^{-1} (\mathbf{G}\mathbf{G}^\top)^{-1} \mathbf{G} \mathbf{Q}(\mathbf{B}) \\ &= \text{tr } \Gamma^{-1} (\mathbf{Y}\mathbf{Z}^\top (\mathbf{Z}\mathbf{Z}^\top)^{-1} - \mathbf{X}\mathbf{B})^\top (\mathbf{Y}\mathbf{Z}^\top (\mathbf{Z}\mathbf{Z}^\top)^{-1} - \mathbf{X}\mathbf{B}) \\ &\quad + \text{tr } \Phi^{-1} (\mathbf{G}\mathbf{G}^\top)^{-1} \mathbf{G}\mathbf{Y}^\top \mathbf{Y}\mathbf{G}^\top (\mathbf{G}\mathbf{G}^\top)^{-1}\end{aligned}$$



Finalmente, la **función de log-verosimilitud** para $\Theta = (B, \Gamma, \Phi)$ asume la forma

$$\begin{aligned}\ell(\Theta) &= -\frac{np}{2} \log 2\pi - \frac{n}{2} \log |\mathbf{Z}\mathbf{Z}^\top| - \frac{n}{2} \log |\mathbf{G}\mathbf{G}^\top| \\ &\quad - \frac{n}{2} \log |\Gamma| - \frac{1}{2} \text{tr} \Gamma^{-1} (\mathbf{Y}\mathbf{Z}^\top (\mathbf{Z}\mathbf{Z}^\top)^{-1} - \mathbf{X}\mathbf{B})^\top (\mathbf{Y}\mathbf{Z}^\top (\mathbf{Z}\mathbf{Z}^\top)^{-1} - \mathbf{X}\mathbf{B}) \\ &\quad - \frac{n}{2} \log |\Phi| - \frac{1}{2} \text{tr} \Phi^{-1} (\mathbf{G}\mathbf{G}^\top)^{-1} \mathbf{G}\mathbf{Y}^\top \mathbf{Y}\mathbf{G}^\top (\mathbf{G}\mathbf{G}^\top)^{-1}.\end{aligned}$$



De este modo, **diferenciando con relación a Γ** , obtenemos:

$$\begin{aligned}d_{\Gamma} \ell(\Theta) &= -\frac{n}{2} \operatorname{tr} \Gamma^{-1} d\Gamma \\ &\quad + \frac{1}{2} \operatorname{tr} \Gamma^{-1} (d\Gamma) \Gamma^{-1} (\mathbf{Y}\mathbf{Z}^{\top} (\mathbf{Z}\mathbf{Z}^{\top})^{-1} - \mathbf{X}\mathbf{B})^{\top} (\mathbf{Y}\mathbf{Z}^{\top} (\mathbf{Z}\mathbf{Z}^{\top})^{-1} - \mathbf{X}\mathbf{B}) \\ &= -\frac{n}{2} \operatorname{tr} \Gamma^{-1} \left\{ \Gamma - \frac{1}{n} (\mathbf{Y}\mathbf{Z}^{\top} (\mathbf{Z}\mathbf{Z}^{\top})^{-1} - \mathbf{X}\mathbf{B})^{\top} (\mathbf{Y}\mathbf{Z}^{\top} (\mathbf{Z}\mathbf{Z}^{\top})^{-1} - \mathbf{X}\mathbf{B}) \right\} \Gamma^{-1} d\Gamma.\end{aligned}$$

Por tanto el **estimador ML para Γ** es dado por:

$$\begin{aligned}\hat{\Gamma} &= \frac{1}{n} (\mathbf{Y}\mathbf{Z}^{\top} (\mathbf{Z}\mathbf{Z}^{\top})^{-1} - \mathbf{X}\hat{\mathbf{B}})^{\top} (\mathbf{Y}\mathbf{Z}^{\top} (\mathbf{Z}\mathbf{Z}^{\top})^{-1} - \mathbf{X}\hat{\mathbf{B}}) \\ &= \frac{1}{n} (\mathbf{Z}\mathbf{Z}^{\top})^{-1} \mathbf{Z}\mathbf{S}\mathbf{Z}^{\top} (\mathbf{Z}\mathbf{Z}^{\top})^{-1}\end{aligned}$$



De este modo, **diferenciando con relación a Φ** , obtenemos:

$$\begin{aligned}d_{\Phi} \ell(\Theta) &= -\frac{n}{2} \operatorname{tr} \Phi^{-1} d\Phi + \frac{1}{2} \operatorname{tr} \Phi^{-1} (d\Phi) \Phi^{-1} (GG^{\top})^{-1} GY^{\top} YG^{\top} (GG^{\top})^{-1} \\ &= -\frac{n}{2} \operatorname{tr} \Phi^{-1} \left\{ \Phi - \frac{1}{n} (GG^{\top})^{-1} GY^{\top} YG^{\top} (GG^{\top})^{-1} \right\} \Phi^{-1} d\Phi.\end{aligned}$$

Así, el **estimador ML para Φ** resulta:

$$\hat{\Phi} = \frac{1}{n} (GG^{\top})^{-1} GY^{\top} YG^{\top} (GG^{\top})^{-1}.$$



Finalmente, note que

$$\mathbf{G}^\top (\mathbf{G}\mathbf{G}^\top)^{-1} \mathbf{G} = \mathbf{I}_q - \mathbf{Z}^\top (\mathbf{Z}\mathbf{Z}^\top)^{-1} \mathbf{Z}.$$

Esto permite construir una matriz asociada a \mathbf{G} tal que $\mathbf{G}\mathbf{Z}^\top = \mathbf{0}$ y que además

$$\widehat{\Sigma} = \mathbf{Z}^\top \widehat{\Gamma} \mathbf{Z} + \mathbf{G}^\top \widehat{\Phi} \mathbf{G}.$$

Basta apreciar que

$$\begin{aligned} \mathbf{G}^\top \widehat{\Phi} \mathbf{G} &= \frac{1}{n} \mathbf{G}^\top (\mathbf{G}\mathbf{G}^\top)^{-1} \mathbf{G} \mathbf{Y}^\top \mathbf{Y} \mathbf{G}^\top (\mathbf{G}\mathbf{G}^\top)^{-1} \mathbf{G} \\ &= \frac{1}{n} (\mathbf{I}_q - \mathbf{Z}^\top (\mathbf{Z}\mathbf{Z}^\top)^{-1} \mathbf{Z}) \mathbf{Y}^\top \mathbf{Y} (\mathbf{I}_q - \mathbf{Z}^\top (\mathbf{Z}\mathbf{Z}^\top)^{-1} \mathbf{Z}). \end{aligned}$$




```
## Supondremos que los datos 'x', 'y', 'z' estan cargados en  
## nuestro directorio de trabajo.
```

```
# calculos en el modelo de regresion multivariado
```

```
xy <- crossprod(x, y)  
r <- y - x %*% solve(xx, xy)  
S <- crossprod(r)
```

```
# Salida
```

```
S  
      [,1]      [,2]      [,3]      [,4]  
[1,] 135.38636  67.92045  97.75568  67.75568  
[2,]  67.92045 104.61932  73.17898  82.92898  
[3,]  97.75568  73.17898 161.39347 103.26847  
[4,]  67.75568  82.92898 103.26847 124.64347
```



```
# contruye estimador para B
xx <- crossprod(x)
zz <- crossprod(t(z))
xyz <- crossprod(x, y %*% t(z))
B <- solve(xx, xyz %*% solve(zz))
```

```
# Salida
```

```
B
      Intercept      age
Male    16.34063 0.7843750
Female  17.37273 0.4795455
```

```
# construye estimador para Gamma
```

```
zsz <- z %*% S %*% t(z)
Gamma <- solve(zz, zsz %*% solve(zz)) / n
```

```
# Salida
```

```
Gamma
      [,1]      [,2]
[1,] 15.368997 -1.1421659
[2,] -1.142166  0.1095691
```



Comandos en R

```
p <- ncol(z)
res <- diag(p) - t(z) %*% solve(zz, z)
res
      [,1] [,2] [,3] [,4]
[1,]  0.3 -0.4 -0.1  0.2
[2,] -0.4  0.7 -0.2 -0.1
[3,] -0.1 -0.2  0.7 -0.4
[4,]  0.2 -0.1 -0.4  0.3

yy <- crossprod(y)
gg <- res %*% yy %*% res /n
gg
      [,1]      [,2]      [,3]      [,4]
[1,] 0.4084259 -0.6697222  0.1141667  0.14712963
[2,] -0.6697222  1.4050000 -0.8008333  0.06555556
[3,]  0.1141667 -0.8008333  1.2591667 -0.57250000
[4,]  0.1471296  0.06555556 -0.5725000  0.35981481

# construye estimador para Sigma
Sigma <- crossprod(z, Gamma %*% z) + gg

# Salida
Sigma
      [,1]      [,2]      [,3]      [,4]
[1,] 4.515192  2.905818  3.158481  2.660218
[2,] 2.905818  4.887591  2.588808  3.362248
[3,] 3.158481  2.588808  4.994136  3.507796
[4,] 2.660218  3.362248  3.507796  5.223715
```

