

# MAT-269: Sesión 16, Modelo de Análisis Factorial

**Felipe Osorio**

[fosorios.mat.utfsm.cl](mailto:fosorios.mat.utfsm.cl)

Departamento de Matemática, UTFSM



## Idea:

El objetivo es intentar explicar la correlación entre un conjunto grande de variables en términos de un número pequeño de factores.

Este modelo supone que aquellos factores no son observables y son considerados variables aleatorias. Este modelo es muy apropiado en áreas como Psicología.

## Definición 1 (Modelo de análisis factorial)

Sea  $\mathbf{x} = (x_1, \dots, x_p)^\top$  vector aleatorio con  $E(\mathbf{x}) = \boldsymbol{\mu}$  y  $\text{Cov}(\mathbf{x}) = \boldsymbol{\Sigma}$ . Suponga que los elementos de  $\mathbf{x}$  satisfacen:

$$\mathbf{x} = \boldsymbol{\mu} + \boldsymbol{\Gamma}\mathbf{z} + \boldsymbol{\epsilon},$$

donde  $\mathbf{z} = (z_1, \dots, z_m)^\top$  es llamado **factores comunes** ( $m < p$ ) y  $\boldsymbol{\Gamma} = (\gamma_{jk}) \in \mathbb{R}^{p \times m}$ , con  $\gamma_{jk}$  llamado la **carga factorial** (loadings) de la variable  $j$  ( $x_j$ ) sobre el factor  $z_k$ .



El modelo está basado en los siguientes supuestos:

$$E(\epsilon) = \mathbf{0}, \quad \text{Cov}(\epsilon) = \Psi = \text{diag}(\psi_1^2, \dots, \psi_p^2),$$

independientes de  $\mathbf{z}$  con

$$E(\mathbf{z}) = \mathbf{0}, \quad \text{Cov}(\mathbf{z}) = \mathbf{I}.$$

De este modo,

$$E(\mathbf{x}) = \boldsymbol{\mu} + \Gamma E(\mathbf{z}) + E(\epsilon) = \boldsymbol{\mu},$$

y

$$\begin{aligned} \text{Cov}(\mathbf{x}) &= \text{Cov}(\Gamma \mathbf{z} + \epsilon) = \Gamma \text{Cov}(\mathbf{z}) \Gamma^\top + \text{Cov}(\epsilon) \\ &= \Gamma \Gamma^\top + \Psi = \Sigma. \end{aligned}$$



*Ejemplo: (Spearman, 1904)*

Se desea examinar el desempeño de un grupo de niños en **Classics** ( $x_1$ ), **French** ( $x_2$ ) y **English** ( $x_3$ ). Se calculó la matriz

$$\Sigma = \begin{pmatrix} 1.00 & 0.83 & 0.78 \\ 0.83 & 1.00 & 0.67 \\ 0.78 & 0.67 & 1.00 \end{pmatrix},$$

se puede verificar que  $\Sigma = \Gamma\Gamma^\top + \Psi$  con

$$\Gamma = \begin{pmatrix} 0.983 \\ 0.844 \\ 0.744 \end{pmatrix}, \quad \Psi = \begin{pmatrix} 0.34 & 0.00 & 0.00 \\ 0.00 & 0.29 & 0.00 \\ 0.00 & 0.00 & 0.37 \end{pmatrix},$$

luego el modelo asume la forma

$$\mathbf{x} = \boldsymbol{\mu} + \Gamma\mathbf{z} + \boldsymbol{\epsilon},$$

es decir

$$x_1 = \mu_1 + \gamma_1 z + \epsilon_1, \quad x_2 = \mu_2 + \gamma_2 z + \epsilon_2, \quad x_3 = \mu_3 + \gamma_3 z + \epsilon_3,$$

con  $z$  el factor “**inteligencia**”.



## Observación:

Sea  $P$  matriz ortogonal  $m \times m$ , entonces,

$$\begin{aligned}x &= \mu + \Gamma z + \epsilon = \mu + (\Gamma P)(P^\top z) + \epsilon \\ &= \mu + \Gamma_* z_* + \epsilon,\end{aligned}$$

donde

$$\text{Cov}(z_*) = P^\top \text{Cov}(z) P = P^\top P = I,$$

de este modo el modelo **no es único**, es decir, existe un problema de **identificabilidad**.

El problema de no unicidad puede ser resuelto mediante rotar las cargas factoriales de tal manera que se satisfaga

$$\Gamma^\top \Psi^{-1} \Gamma \quad \text{sea diagonal,}$$

esto incorpora  $m(m - 1)/2$  restricciones.



Note que los elementos diagonales de  $\Sigma (= \Gamma\Gamma^T + \Psi)$  asumen la forma

$$\sigma_{ii} = \sum_{k=1}^m \gamma_{ik}^2 + \psi_i^2 = h_i^2 + \psi_i^2,$$

es decir, podemos descomponer la varianza de  $x_i$  en dos partes  $h_i^2$  llamada **comunalidad** o varianza común y  $\psi_i^2$  es llamada varianza residual.



Suponga una muestra  $\mathbf{x}_1, \dots, \mathbf{x}_n$  muestra aleatoria desde  $N_p(\boldsymbol{\mu}, \boldsymbol{\Sigma})$ , entonces

$$\ell(\boldsymbol{\theta}) = -\frac{np}{2} \log 2\pi - \frac{n}{2} \log |\boldsymbol{\Sigma}| - \frac{1}{2} \sum_{i=1}^n (\mathbf{x}_i - \boldsymbol{\mu})^\top \boldsymbol{\Sigma}^{-1} (\mathbf{x}_i - \boldsymbol{\mu}),$$

es conveniente perfilar la verosimilitud en  $\hat{\boldsymbol{\mu}} = \bar{\mathbf{x}}$ , obteniendo

$$\ell(\boldsymbol{\Gamma}, \boldsymbol{\Psi}) = -\frac{np}{2} \log 2\pi - \frac{n}{2} \log |\boldsymbol{\Gamma}\boldsymbol{\Gamma}^\top + \boldsymbol{\Psi}| - \frac{1}{2} \text{tr}(\boldsymbol{\Gamma}^\top \boldsymbol{\Gamma} + \boldsymbol{\Psi})^{-1} \mathbf{Q},$$

donde  $\mathbf{Q} = \sum_{i=1}^n (\mathbf{x}_i - \bar{\mathbf{x}})(\mathbf{x}_i - \bar{\mathbf{x}})^\top$ .



Se debe optimizar  $\ell(\mathbf{\Gamma}, \mathbf{\Psi})$  sujeto a la condición que  $\mathbf{\Gamma}^\top \mathbf{\Psi}^{-1} \mathbf{\Gamma} = \mathbf{\Delta}$ ,  $\mathbf{\Delta}$  diagonal. Tomando derivadas con respecto a  $\mathbf{\Gamma}$  y  $\mathbf{\Psi}$  lleva a las siguientes ecuaciones:

$$\mathbf{S} \hat{\mathbf{\Psi}}^{-1} \hat{\mathbf{\Gamma}} = \hat{\mathbf{\Gamma}} (\mathbf{I} + \hat{\mathbf{\Gamma}}^\top \hat{\mathbf{\Psi}}^{-1} \hat{\mathbf{\Gamma}})$$

$$\hat{\mathbf{\Psi}} = \text{diag}(\mathbf{S} - \hat{\mathbf{\Gamma}} \hat{\mathbf{\Gamma}}^\top)$$

$$\hat{\mathbf{\Delta}} = \hat{\mathbf{\Gamma}}^\top \hat{\mathbf{\Psi}}^{-1} \hat{\mathbf{\Gamma}}.$$

Estas ecuaciones deben ser resueltas de forma iterativa y es bien conocido que sufre de problemas de convergencia.

### *Observación:*

La función de log-verosimilitud puede no tener máximo, sujeto a  $\mathbf{\Psi} > \mathbf{0}$ , frecuentemente esto se debe a que uno o más elementos de  $\mathbf{\Psi}$  tienden a cero.

Hasta que surgiera el algoritmo propuesto por Jöreskog (1967) y Lawley (1967) existía mucha dificultad en la estimación para el modelo factorial.<sup>1</sup>

---

<sup>1</sup>Estas rutinas se encuentran implementadas en el software LISREL.





## Estimación ML: Método de componentes principales

Note que  $\Sigma - \Psi = \Gamma\Gamma^\top$  es semidefinida positiva de rango  $m$ . De ahí que existe una matriz ortogonal  $M$  tal que

$$M^\top(\Sigma - \Psi)M = \text{diag}(\phi_1, \dots, \phi_m, 0, \dots, 0) = \Phi,$$

donde  $\phi_j$  son los valores propios positivos. Sea  $M_1$  la matriz que contiene los primeros  $m$  vectores propios y  $\Phi_1 = \text{diag}(\phi_1, \dots, \phi_m)$ . Entonces

$$\begin{aligned}\Sigma - \Psi &= M\Phi M^\top = (M_1, M_2) \begin{pmatrix} \Phi_1 & \mathbf{0} \\ \mathbf{0} & \mathbf{0} \end{pmatrix} \begin{pmatrix} M_1^\top \\ M_2^\top \end{pmatrix} \\ &= M_1\Phi_1M_1^\top = (\Gamma_1\Phi_1^{1/2})(\Gamma_1\Phi_1^{1/2})^\top,\end{aligned}$$

y  $\Gamma = \Gamma_1\Phi_1^{1/2}$  es una solución. De este modo, para un estimador dado  $\hat{\Psi}_1$  de  $\Psi$  se obtiene las primeras  $m$  **componentes principales** de  $\hat{\Sigma} - \hat{\Psi}_1$  lo que permite estimar  $\Gamma$  como  $\hat{\Gamma}_1\hat{\Phi}_1^{1/2}$ .



Considere el modelo de análisis factorial,

$$\mathbf{x}_i = \boldsymbol{\mu} + \boldsymbol{\Gamma} \mathbf{z}_i + \boldsymbol{\epsilon}_i, \quad i = 1, \dots, n,$$

asumiremos que  $\mathbf{z}_1, \dots, \mathbf{z}_n$  son vectores **no observables (missing)** IID  $N_m(\mathbf{0}, \mathbf{I})$ , independiente de los errores  $\boldsymbol{\epsilon}_i \stackrel{\text{IID}}{\sim} N_p(\mathbf{0}, \boldsymbol{\Psi})$ , con  $\boldsymbol{\Psi} = \text{diag}(\psi_1^2, \dots, \psi_p^2)$ .

De este modo, condicional a los  $\mathbf{z}_i$ , tenemos:

$$\mathbf{x}_i | \mathbf{z}_i \stackrel{\text{IND}}{\sim} N_p(\boldsymbol{\mu} + \boldsymbol{\Gamma} \mathbf{z}_i, \boldsymbol{\Psi}), \quad \mathbf{z}_i \stackrel{\text{IND}}{\sim} N_m(\mathbf{0}, \mathbf{I}).$$

Integrando con relación a  $\mathbf{z}_i$  obtenemos la distribución marginal

$$\mathbf{x}_i \sim N_p(\boldsymbol{\mu}, \boldsymbol{\Gamma} \boldsymbol{\Gamma}^\top + \boldsymbol{\Psi}), \quad i = 1, \dots, n.$$



De este modo, el vector de **datos completos**  $(\mathbf{x}, \mathbf{z})$  con  $\mathbf{z} = (z_1^\top, \dots, z_n^\top)^\top$  el **vector de datos perdidos**, podemos notar que

$$\mathbf{z}_i | \mathbf{x}_i \sim \mathcal{N}(\mathbf{\Gamma}^\top \mathbf{\Sigma}^{-1} (\mathbf{x}_i - \boldsymbol{\mu}), (\mathbf{\Gamma}^\top \mathbf{\Sigma}^{-1} \mathbf{\Gamma} + \mathbf{I})^{-1}).$$

En este caso tenemos que la **log-verosimilitud de datos completos** asume la forma

$$\begin{aligned} \ell_c(\boldsymbol{\theta}; \mathbf{x}, \mathbf{z}) &= -\frac{n}{2} \log |2\pi \mathbf{\Psi}| \\ &\quad - \frac{1}{2} \sum_{i=1}^n \{ (\mathbf{x}_i - \boldsymbol{\mu} - \mathbf{\Gamma} \mathbf{z}_i)^\top \mathbf{\Psi}^{-1} (\mathbf{x}_i - \boldsymbol{\mu} - \mathbf{\Gamma} \mathbf{z}_i) + \mathbf{z}_i^\top \mathbf{z}_i \}. \end{aligned}$$

Note que,

$$\mathbb{E}(\mathbf{z}_i | \mathbf{x}_i) = (\mathbf{\Gamma}^\top \mathbf{\Sigma}^{-1} \mathbf{\Gamma} + \mathbf{I})^{-1} \mathbf{\Gamma}^\top \mathbf{\Psi}^{-1} (\mathbf{x}_i - \boldsymbol{\mu}).$$



Substituyendo  $\boldsymbol{\mu}$  por  $\bar{\boldsymbol{x}}$  y como:

$$\begin{aligned}(\boldsymbol{x}_i - \bar{\boldsymbol{x}} - \boldsymbol{\Gamma} \boldsymbol{z}_i)^\top \boldsymbol{\Psi}^{-1} (\boldsymbol{x}_i - \bar{\boldsymbol{x}} - \boldsymbol{\Gamma} \boldsymbol{z}_i) &= (\boldsymbol{x}_i - \bar{\boldsymbol{x}})^\top \boldsymbol{\Psi}^{-1} (\boldsymbol{x}_i - \bar{\boldsymbol{x}}) \\ &+ \boldsymbol{z}_i^\top \boldsymbol{\Gamma}^\top \boldsymbol{\Psi}^{-1} \boldsymbol{\Gamma} \boldsymbol{z}_i - 2(\boldsymbol{x}_i - \bar{\boldsymbol{x}})^\top \boldsymbol{\Psi}^{-1} \boldsymbol{\Gamma} \boldsymbol{z}_i,\end{aligned}$$

usando resultados básicos de esperanzas de formas cuadráticas, tenemos

$$\begin{aligned}\mathbb{E}\{(\boldsymbol{x}_i - \bar{\boldsymbol{x}} - \boldsymbol{\Gamma} \boldsymbol{z}_i)^\top \boldsymbol{\Psi}^{-1} (\boldsymbol{x}_i - \bar{\boldsymbol{x}} - \boldsymbol{\Gamma} \boldsymbol{z}_i) | \boldsymbol{x}_i, \boldsymbol{\theta}^{(k)}\} &= (\boldsymbol{x}_i - \bar{\boldsymbol{x}})^\top \boldsymbol{\Psi}^{-1} (\boldsymbol{x}_i - \bar{\boldsymbol{x}}) \\ &- 2(\boldsymbol{x}_i - \bar{\boldsymbol{x}})^\top \boldsymbol{\Psi}^{-1} \boldsymbol{\Gamma} \hat{\boldsymbol{z}}_i + \text{tr} \boldsymbol{\Gamma}^\top \boldsymbol{\Psi}^{-1} \boldsymbol{\Gamma} \text{Cov}(\boldsymbol{z}_i | \boldsymbol{x}_i, \boldsymbol{\theta}^{(k)}) + \hat{\boldsymbol{z}}_i^\top \boldsymbol{\Gamma}^\top \boldsymbol{\Psi}^{-1} \boldsymbol{\Gamma} \hat{\boldsymbol{z}}_i \\ &= (\boldsymbol{x}_i - \bar{\boldsymbol{x}} - \boldsymbol{\Gamma} \hat{\boldsymbol{z}}_i)^\top \boldsymbol{\Psi}^{-1} (\boldsymbol{x}_i - \bar{\boldsymbol{x}} - \boldsymbol{\Gamma} \hat{\boldsymbol{z}}_i) + \text{tr} \boldsymbol{\Gamma}^\top \boldsymbol{\Psi}^{-1} \boldsymbol{\Gamma} \hat{\boldsymbol{\Omega}},\end{aligned}$$

donde

$$\begin{aligned}\hat{\boldsymbol{z}}_i &= \mathbb{E}(\boldsymbol{z}_i | \boldsymbol{x}_i, \boldsymbol{\theta}^{(k)}) = (\hat{\boldsymbol{\Gamma}}^\top \hat{\boldsymbol{\Psi}}^{-1} \hat{\boldsymbol{\Gamma}} + \boldsymbol{I})^{-1} \hat{\boldsymbol{\Gamma}}^\top \hat{\boldsymbol{\Psi}}^{-1} (\boldsymbol{x}_i - \bar{\boldsymbol{x}}), \\ \hat{\boldsymbol{\Omega}} &= \text{Cov}(\boldsymbol{z}_i | \boldsymbol{x}_i, \boldsymbol{\theta}^{(k)}) = (\hat{\boldsymbol{\Gamma}}^\top \hat{\boldsymbol{\Psi}}^{-1} \hat{\boldsymbol{\Gamma}} + \boldsymbol{I})^{-1},\end{aligned}$$

con  $\hat{\boldsymbol{\Gamma}}$  y  $\hat{\boldsymbol{\Psi}}$  siendo evaluadas en  $\boldsymbol{\theta}^{(k)}$ , y análogamente

$$\mathbb{E}(\boldsymbol{z}_i^\top \boldsymbol{z}_i | \boldsymbol{x}_i, \boldsymbol{\theta}^{(k)}) = \hat{\boldsymbol{z}}_i^\top \hat{\boldsymbol{z}}_i + \text{tr} \hat{\boldsymbol{\Omega}}.$$



De este modo,

$$Q(\boldsymbol{\theta}; \boldsymbol{\theta}^{(k)}) = -\frac{n}{2} \log |\boldsymbol{\Psi}| \\ - \frac{1}{2} \sum_{i=1}^n \{(\mathbf{x}_i - \bar{\mathbf{x}} - \boldsymbol{\Gamma} \hat{\mathbf{z}}_i)^\top \boldsymbol{\Psi}^{-1} (\mathbf{x}_i - \bar{\mathbf{x}} - \boldsymbol{\Gamma} \hat{\mathbf{z}}_i) + \text{tr} \hat{\boldsymbol{\Omega}} \boldsymbol{\Gamma}^\top \boldsymbol{\Psi}^{-1} \boldsymbol{\Gamma}\}.$$

Tenemos que

$$d_{\boldsymbol{\Psi}} Q(\boldsymbol{\theta}; \boldsymbol{\theta}^{(k)}) = -\frac{n}{2} \text{tr} \boldsymbol{\Psi}^{-1} + \frac{n}{2} \text{tr} \boldsymbol{\Psi}^{-1} \boldsymbol{\Gamma} \hat{\boldsymbol{\Omega}} \boldsymbol{\Gamma}^\top \boldsymbol{\Psi}^{-1} d \boldsymbol{\Psi} \\ + \frac{1}{2} \text{tr} \boldsymbol{\Psi}^{-1} \sum_{i=1}^n (\mathbf{x}_i - \bar{\mathbf{x}} - \boldsymbol{\Gamma} \hat{\mathbf{z}}_i)(\mathbf{x}_i - \bar{\mathbf{x}} - \boldsymbol{\Gamma} \hat{\mathbf{z}}_i)^\top \boldsymbol{\Psi}^{-1} d \boldsymbol{\Psi} \\ = \frac{1}{2} \text{tr} \boldsymbol{\Psi}^{-1} \{ \mathbf{S} + n \boldsymbol{\Gamma} \hat{\boldsymbol{\Omega}} \boldsymbol{\Gamma}^\top - n \boldsymbol{\Psi} \} \boldsymbol{\Psi}^{-1} d \boldsymbol{\Psi}.$$

De ahí que

$$\boldsymbol{\Psi}^{(k+1)} = \text{diag} \left( \frac{1}{n} \mathbf{S} + \boldsymbol{\Gamma}^{(k)} \hat{\boldsymbol{\Omega}} \boldsymbol{\Gamma}^{(k)\top} \right)$$



Por otro lado,

$$\begin{aligned}d_{\Gamma} Q(\boldsymbol{\theta}; \boldsymbol{\theta}^{(k)}) &= \sum_{i=1}^n (\mathbf{x}_i - \bar{\mathbf{x}} - \Gamma \hat{\mathbf{z}}_i)^{\top} \Psi^{-1} (d\Gamma) \hat{\mathbf{z}}_i \\ &\quad - \frac{n}{2} \text{tr} \hat{\Omega} (d\Gamma)^{\top} \Psi^{-1} \Gamma - \frac{n}{2} \text{tr} \hat{\Omega} \Gamma^{\top} \Psi^{-1} d\Gamma \\ &= \sum_{i=1}^n (\mathbf{x}_i - \bar{\mathbf{x}} - \Gamma \hat{\mathbf{z}}_i)^{\top} \Psi^{-1} (d\Gamma) \hat{\mathbf{z}}_i - n \text{tr} \hat{\Omega} \Gamma^{\top} \Psi^{-1} d\Gamma,\end{aligned}$$

es decir,

$$d_{\Gamma} Q(\boldsymbol{\theta}; \boldsymbol{\theta}^{(k)}) = \text{tr} \sum_{i=1}^n \hat{\mathbf{z}}_i (\mathbf{x}_i - \bar{\mathbf{x}} - \Gamma \hat{\mathbf{z}}_i)^{\top} \Psi^{-1} d\Gamma - n \text{tr} \hat{\Omega} \Gamma^{\top} \Psi^{-1} d\Gamma.$$

Desde la condición de primer orden, sigue que

$$\begin{aligned}\sum_{i=1}^n \hat{\mathbf{z}}_i (\mathbf{x}_i - \bar{\mathbf{x}} - \Gamma \hat{\mathbf{z}}_i)^{\top} - n \hat{\Omega} \Gamma^{\top} &= \mathbf{0} \\ \sum_{i=1}^n \hat{\mathbf{z}}_i (\mathbf{x}_i - \bar{\mathbf{x}})^{\top} - \sum_{i=1}^n \hat{\mathbf{z}}_i \hat{\mathbf{z}}_i^{\top} \Gamma^{\top} - n \hat{\Omega} \Gamma^{\top} &= \mathbf{0}\end{aligned}$$



Es decir,

$$n \left( \frac{1}{n} \sum_{i=1}^n \hat{\mathbf{z}}_i \hat{\mathbf{z}}_i^\top + \hat{\mathbf{\Omega}} \right) \mathbf{\Gamma}^\top = \sum_{i=1}^n \hat{\mathbf{z}}_i (\mathbf{x}_i - \bar{\mathbf{x}})^\top.$$

Finalmente,

$$\mathbf{\Gamma}^{(k+1)\top} = \left( \frac{1}{n} \sum_{i=1}^n \hat{\mathbf{z}}_i \hat{\mathbf{z}}_i^\top + \hat{\mathbf{\Omega}} \right)^{-1} \sum_{i=1}^n \hat{\mathbf{z}}_i (\mathbf{x}_i - \bar{\mathbf{x}})^\top.$$

### Observaciones:

- ▶ Este algoritmo EM es simple y numéricamente estable.
- ▶ Posibilidad de soluciones múltiples (que no necesariamente son rotaciones unas de otras).
- ▶ Lenta razón de convergencia, lentitud que se atribuye a la proporción de datos perdidos.
- ▶ Errores estándar no son obtenidos como un subproducto del procedimiento de estimación (diferente a algoritmo Newton-Raphson).

