

MAT-269: Sesión 6

Estimación para la normal multivariada

Felipe Osorio

fosorios.mat.utfsm.cl

Departamento de Matemática, UTFSM



Resultado 1

Suponga $\mathbf{x}_1, \dots, \mathbf{x}_n$ vectores aleatorios independientes siguiendo una distribución $N_p(\mu, \Sigma)$. Entonces $(\bar{\mathbf{x}}, \mathbf{Q})$ es **estadística suficiente** para (μ, Σ) , con

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

Demostración:

La función de densidad conjunta para $\mathbf{x}_1, \dots, \mathbf{x}_n$ adopta la forma:

$$\begin{aligned} f(\mathbf{X}) &= (2\pi)^{-np/2} |\Sigma|^{-n/2} \exp \left\{ -\frac{1}{2} \sum_{i=1}^n (\mathbf{x}_i - \mu)^\top \Sigma^{-1} (\mathbf{x}_i - \mu) \right\} \\ &= (2\pi)^{-np/2} |\Sigma|^{-n/2} \exp \left\{ -\frac{1}{2} \text{tr} \Sigma^{-1} (\mathbf{Q} + n(\bar{\mathbf{x}} - \mu)(\bar{\mathbf{x}} - \mu)^\top) \right\}, \end{aligned}$$

pertenece a la FE $\{p + p(p + 1)/2\}$ -paramétrica. Es decir, $(\bar{\mathbf{x}}, \mathbf{Q})$ o bien $(\bar{\mathbf{x}}, \mathbf{S})$ son estadísticas suficientes para (μ, Σ) .



Resultado 2

Suponga $\mathbf{x}_1, \dots, \mathbf{x}_n$ vectores aleatorios independientes cada uno $N_p(\boldsymbol{\mu}, \boldsymbol{\Sigma})$ y $n > p$.
Entonces los **estimadores máximo verosímiles** de $\boldsymbol{\mu}$ y $\boldsymbol{\Sigma}$ son

$$\hat{\boldsymbol{\mu}} = \bar{\mathbf{x}}, \quad \hat{\boldsymbol{\Sigma}} = \frac{1}{n} \mathbf{Q}.$$



Estimación máximo verosímil (ML) de μ y Σ

Demostración:

Ignorando términos que no dependen de $\theta = (\mu, \Sigma)$, tenemos que la función de log-verosimilitud es:

$$\ell(\theta) = -\frac{n}{2} \log |\Sigma| - \frac{1}{2} \text{tr} \Sigma^{-1} Q(\mu),$$

donde

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

Note que

$$dQ(\mu) = - \sum_{i=1}^n \{ (d\mu)(\mathbf{x}_i - \mu)^\top + (\mathbf{x}_i - \mu)(d\mu)^\top \}$$

De este modo,

$$\begin{aligned} d_\mu \ell(\theta) &= -\frac{1}{2} \text{tr} \Sigma^{-1} dQ(\mu) \\ &= \frac{1}{2} \text{tr} \Sigma^{-1} \sum_{i=1}^n \{ (d\mu)(\mathbf{x}_i - \mu)^\top + (\mathbf{x}_i - \mu)(d\mu)^\top \} \\ &= \frac{n}{2} \text{tr} \Sigma^{-1} \{ (d\mu)(\bar{\mathbf{x}} - \mu)^\top + (\bar{\mathbf{x}} - \mu)(d\mu)^\top \} \\ &= \frac{n}{2} \{ (\bar{\mathbf{x}} - \mu)^\top \Sigma^{-1} (d\mu) + (d\mu)^\top \Sigma^{-1} (\bar{\mathbf{x}} - \mu) \} \\ &= n(d\mu)^\top \Sigma^{-1} (\bar{\mathbf{x}} - \mu), \end{aligned}$$

y el diferencial es cero si, $\hat{\mu} = \bar{\mathbf{x}}$.



Estimación máximo verosímil (ML) de μ y Σ

Recuerde que (ver Magnus y Neudecker, 2007)

$$d\mathbf{F}^{-1} = -\mathbf{F}^{-1}(d\mathbf{F})\mathbf{F}^{-1}, \quad d \log |\mathbf{F}| = \text{tr } \mathbf{F}^{-1} d\mathbf{F}.$$

De este modo,

$$\begin{aligned} d_{\Sigma} \ell(\boldsymbol{\theta}) &= -\frac{n}{2} \text{tr } \Sigma^{-1} d\Sigma - \frac{1}{2} \text{tr } d\Sigma^{-1} \mathbf{Q}(\boldsymbol{\mu}) \\ &= -\frac{n}{2} \text{tr } \Sigma^{-1} d\Sigma + \frac{1}{2} \text{tr } \Sigma^{-1} (d\Sigma) \Sigma^{-1} \mathbf{Q}(\boldsymbol{\mu}) \\ &= \frac{1}{2} \text{tr } \{ \Sigma^{-1} \mathbf{Q}(\boldsymbol{\mu}) \Sigma^{-1} d\Sigma - n \Sigma^{-1} d\Sigma \} \\ &= \frac{1}{2} \text{tr } \Sigma^{-1} \{ \mathbf{Q}(\boldsymbol{\mu}) - n \Sigma \} \Sigma^{-1} d\Sigma, \end{aligned}$$

y por tanto el primer diferencial es cero, si:¹

$$\mathbf{Q}(\hat{\boldsymbol{\mu}}) - n\hat{\Sigma} = \mathbf{0}, \quad \text{es decir} \quad \hat{\Sigma} = \frac{1}{n} \mathbf{Q}.$$

¹Note que $\mathbf{Q}(\hat{\boldsymbol{\mu}}) = \mathbf{Q}(\bar{\mathbf{x}}) \equiv \mathbf{Q}$.



Estimación máximo verosímil (ML) de μ y Σ

Para apreciar que $\hat{\mu}$ y $\hat{\Sigma}$ son máximos, note que:

$$\begin{aligned}\sum_{i=1}^n (\mathbf{x}_i - \boldsymbol{\mu})^\top \boldsymbol{\Sigma}^{-1} (\mathbf{x}_i - \boldsymbol{\mu}) &= \text{tr} \sum_{i=1}^n \boldsymbol{\Sigma}^{-1} (\mathbf{x}_i - \boldsymbol{\mu})(\mathbf{x}_i - \boldsymbol{\mu})^\top \\ &= \text{tr} \boldsymbol{\Sigma}^{-1} \mathbf{Q} + n \text{tr} \boldsymbol{\Sigma}^{-1} (\bar{\mathbf{x}} - \boldsymbol{\mu})(\bar{\mathbf{x}} - \boldsymbol{\mu})^\top \\ &= \text{tr} \boldsymbol{\Sigma}^{-1} \mathbf{Q} + n(\bar{\mathbf{x}} - \boldsymbol{\mu})^\top \boldsymbol{\Sigma}^{-1} (\bar{\mathbf{x}} - \boldsymbol{\mu}).\end{aligned}$$

De este modo, la parte relevante de la log-verosimilitud asume la forma:

$$\ell(\boldsymbol{\theta}) = -\frac{n}{2} \log |\boldsymbol{\Sigma}| - \frac{1}{2} \text{tr} \boldsymbol{\Sigma}^{-1} \mathbf{Q} - \frac{n}{2} (\bar{\mathbf{x}} - \boldsymbol{\mu})^\top \boldsymbol{\Sigma}^{-1} (\bar{\mathbf{x}} - \boldsymbol{\mu}),$$

como $\boldsymbol{\Sigma} > 0$ (y de ahí que $\boldsymbol{\Sigma}^{-1} > 0$), sigue que:

$$n(\bar{\mathbf{x}} - \boldsymbol{\mu})^\top \boldsymbol{\Sigma}^{-1} (\bar{\mathbf{x}} - \boldsymbol{\mu}) \geq 0,$$

con la igualdad, si y solo si $\boldsymbol{\mu} = \bar{\mathbf{x}}$, es decir $\hat{\boldsymbol{\mu}} = \bar{\mathbf{x}}$ corresponde al MLE para $\boldsymbol{\mu}$.



Estimación máximo verosímil (ML) de μ y Σ

Por lo tanto,

$$\ell(\hat{\mu}, \Sigma) = \ell(\bar{x}, \Sigma) = -\frac{n}{2} \log |\Sigma| - \frac{1}{2} \text{tr} \Sigma^{-1} Q,$$

como $|\Sigma^{-1}| = |\Sigma^{-1} Q Q^{-1}| = |\Sigma^{-1} Q| |Q|^{-1}$, obtenemos

$$\ell(\bar{x}, \Sigma) = \frac{n}{2} \log |\Sigma^{-1} Q| - \frac{1}{2} \text{tr} \Sigma^{-1} Q - \frac{n}{2} \log |Q|.$$

Además,

$$|\Sigma^{-1} Q| = |\Sigma^{-1} Q^{1/2} Q^{1/2}| = |Q^{1/2}| |\Sigma^{-1}| |Q^{1/2}| = |Q^{1/2} \Sigma^{-1} Q^{1/2}|,$$

y

$$\text{tr} \Sigma^{-1} Q = \text{tr} \Sigma^{-1} Q^{1/2} Q^{1/2} = \text{tr} Q^{1/2} \Sigma^{-1} Q^{1/2},$$

es decir

$$\ell(\bar{x}, \Sigma) = \frac{n}{2} \log |Q^{1/2} \Sigma^{-1} Q^{1/2}| - \frac{1}{2} \text{tr} Q^{1/2} \Sigma^{-1} Q^{1/2} - \frac{n}{2} \log |Q|.$$



Estimación máximo verosímil (ML) de μ y Σ

Sea $\lambda_1, \dots, \lambda_p$ los valores propios de $\mathbf{Q}^{1/2}\Sigma^{-1}\mathbf{Q}^{1/2}$ (o bien de $\Sigma^{-1}\mathbf{Q}$), entonces

$$\begin{aligned}\ell(\bar{\mathbf{x}}, \Sigma) &= \frac{n}{2} \log \prod_{i=1}^p \lambda_i - \frac{1}{2} \sum_{i=1}^p \lambda_i - \frac{n}{2} \log |\mathbf{Q}| \\ &= \frac{1}{2} \sum_{i=1}^p (n \log \lambda_i - \lambda_i) - \frac{n}{2} \log |\mathbf{Q}|.\end{aligned}$$

Dado que la función

$$g(\lambda) = n \log \lambda - \lambda,$$

tiene un único máximo en $\lambda = n$, sigue que

$$\ell(\bar{\mathbf{x}}, \Sigma) \leq \frac{p}{2}(n \log n - n) - \frac{n}{2} \log |\mathbf{Q}|,$$

con la igualdad si $\lambda_i = n$ ($i = 1, \dots, p$). Esta última condición es equivalente a

$$\mathbf{Q}^{1/2}\Sigma^{-1}\mathbf{Q}^{1/2} = n\mathbf{I}_p.$$



De ahí que

$$\widehat{\Sigma} = \frac{1}{n} \mathbf{Q},$$

Finalmente se concluye que

$$L(\boldsymbol{\mu}, \boldsymbol{\Sigma}) \leq n^{np/2} e^{-np/2} |\mathbf{Q}|^{-1/2},$$

con la igualdad si $\widehat{\boldsymbol{\mu}} = \bar{\mathbf{x}}$ y $\widehat{\boldsymbol{\Sigma}} = \frac{1}{n} \mathbf{Q}$, lo que finaliza la prueba.



Resultado 3

Sea $\mathbf{x}_1, \dots, \mathbf{x}_n$ vectores aleatorios IID, tales que $\mathbf{x}_i \sim N_p(\boldsymbol{\mu}, \boldsymbol{\Sigma})$, para $i = 1, \dots, n$, donde $\boldsymbol{\Sigma} > 0$. La matriz de información de Fisher para $\boldsymbol{\theta} = (\boldsymbol{\mu}^\top, (\text{vech } \boldsymbol{\Sigma})^\top)^\top$ es dada por:

$$\mathcal{F}_n(\boldsymbol{\theta}) = n \begin{pmatrix} \boldsymbol{\Sigma}^{-1} & \mathbf{0} \\ \mathbf{0} & \frac{1}{2} \mathbf{D}_p^\top (\boldsymbol{\Sigma}^{-1} \otimes \boldsymbol{\Sigma}^{-1}) \mathbf{D}_p \end{pmatrix},$$

donde $\text{vech}(\cdot)$ denota la vectorización de todos los elementos diferentes de $\boldsymbol{\Sigma}$ y \mathbf{D}_p es la matriz de duplicación de orden p .



Definición 1 (matriz de duplicación)

Para \mathbf{A} matriz simétrica $p \times p$, sea $\text{vech}(\mathbf{A})$ la vectorización de los elementos distintos de \mathbf{A}^2 . Existe una única matriz $D_p \in \mathbb{R}^{p^2 \times p(p+1)/2}$ que transforma $\text{vech}(\mathbf{A})$ en $\text{vec}(\mathbf{A})$, es decir:

$$D_p \text{vech}(\mathbf{A}) = \text{vec}(\mathbf{A}), \quad (\mathbf{A} = \mathbf{A}^\top),$$

y análogamente,

$$\text{vech}(\mathbf{A}) = D_p^+ \text{vec}(\mathbf{A}), \quad D_p^+ = (D_p^\top D_p)^{-1} D_p^\top.$$

²En efecto, tenemos $p(p+1)/2$ elementos distintos.



Ejemplo:

Considere una matriz 3×3 ,

$$\mathbf{A} = \begin{pmatrix} a_{11} & a_{12} & a_{13} \\ a_{21} & a_{22} & a_{23} \\ a_{31} & a_{32} & a_{33} \end{pmatrix}$$

De este modo,

$$\text{vech } \mathbf{A} = \begin{pmatrix} a_{11} \\ a_{12} \\ a_{22} \\ a_{13} \\ a_{23} \\ a_{33} \end{pmatrix}, \quad \mathbf{D}_3 = \begin{pmatrix} 1 & 0 & 0 & 0 & 0 & 0 \\ 0 & 1 & 0 & 0 & 0 & 0 \\ 0 & 0 & 1 & 0 & 0 & 0 \\ 0 & 1 & 0 & 0 & 0 & 0 \\ 0 & 0 & 0 & 1 & 0 & 0 \\ 0 & 0 & 0 & 0 & 1 & 0 \\ 0 & 0 & 1 & 0 & 0 & 0 \\ 0 & 0 & 0 & 0 & 1 & 0 \\ 0 & 0 & 0 & 0 & 0 & 1 \end{pmatrix}.$$

La función `duplication` disponible en la biblioteca `MVT` permite obtener D_p .³

³URL: <http://mvt.mat.utfsm.cl>.



Demostración del Resultado 3:

Diferenciando $d_{\mu} \ell(\theta)$ con relación a μ y Σ , obtenemos

$$\begin{aligned}d_{\mu}^2 \ell(\theta) &= n(d\mu)^{\top} \Sigma^{-1} d(\bar{x} - \mu) \\ &= -n(d\mu)^{\top} \Sigma^{-1} d\mu, \\ d_{\Sigma\mu}^2 \ell(\theta) &= n(d\mu)^{\top} (d\Sigma^{-1})(\bar{x} - \mu) \\ &= -n(d\mu)^{\top} \Sigma^{-1} (d\Sigma) \Sigma^{-1} (\bar{x} - \mu).\end{aligned}$$

Ahora, diferenciando $d_{\Sigma} \ell(\theta)$ con relación a Σ se tiene que

$$\begin{aligned}d_{\Sigma}^2 \ell(\theta) &= -\frac{1}{2} \operatorname{tr} \Sigma^{-1} (d\Sigma) \Sigma^{-1} \{Q(\mu) - n\Sigma\} \Sigma^{-1} d\Sigma \\ &\quad + \frac{1}{2} \operatorname{tr} \Sigma^{-1} d\{Q(\mu) - n\Sigma\} \Sigma^{-1} d\Sigma \\ &\quad - \frac{1}{2} \operatorname{tr} \Sigma^{-1} \{Q(\mu) - n\Sigma\} \Sigma^{-1} (d\Sigma) \Sigma^{-1} d\Sigma \\ &= -\frac{1}{2} \operatorname{tr} \Sigma^{-1} \{Q(\mu) - n\Sigma\} \Sigma^{-1} (d\Sigma) \Sigma^{-1} d\Sigma \\ &\quad - \frac{1}{2} \operatorname{tr} \Sigma^{-1} \{Q(\mu) - n\Sigma\} \Sigma^{-1} (d\Sigma) \Sigma^{-1} d\Sigma \\ &\quad - \frac{n}{2} \operatorname{tr} \Sigma^{-1} (d\Sigma) \Sigma^{-1} d\Sigma.\end{aligned}$$



Matriz de información de Fisher

Recordando que $E(\bar{x}) = \boldsymbol{\mu}$ y $E\{Q(\boldsymbol{\mu})\} = n\boldsymbol{\Sigma}$, sigue:

$$\begin{aligned}E\{-d_{\boldsymbol{\mu}}^2 \ell(\boldsymbol{\theta})\} &= n(d\boldsymbol{\mu})^\top \boldsymbol{\Sigma}^{-1} d\boldsymbol{\mu}, \\E\{-d_{\boldsymbol{\Sigma}\boldsymbol{\mu}}^2 \ell(\boldsymbol{\theta})\} &= \mathbf{0} \\E\{-d_{\boldsymbol{\Sigma}}^2 \ell(\boldsymbol{\theta})\} &= \frac{n}{2} \text{tr } \boldsymbol{\Sigma}^{-1} (d\boldsymbol{\Sigma}) \boldsymbol{\Sigma}^{-1} d\boldsymbol{\Sigma}.\end{aligned}$$

Note que podemos escribir:

$$\begin{aligned}\frac{n}{2} \text{tr } \boldsymbol{\Sigma}^{-1} (d\boldsymbol{\Sigma}) \boldsymbol{\Sigma}^{-1} d\boldsymbol{\Sigma} &= \frac{n}{2} (\text{vec } \boldsymbol{\Sigma})^\top (\boldsymbol{\Sigma}^{-1} \otimes \boldsymbol{\Sigma}^{-1}) \text{vec } \boldsymbol{\Sigma} \\&= \frac{n}{2} (\text{vech } \boldsymbol{\Sigma})^\top \mathbf{D}_p^\top (\boldsymbol{\Sigma}^{-1} \otimes \boldsymbol{\Sigma}^{-1}) \mathbf{D}_p \text{vech } \boldsymbol{\Sigma}.\end{aligned}$$

De ahí sigue que:⁴

$$\begin{aligned}E\left\{-\frac{\partial^2 \ell(\boldsymbol{\theta})}{\partial \boldsymbol{\mu} \partial \boldsymbol{\mu}^\top}\right\} &= n\boldsymbol{\Sigma}^{-1}, & E\left\{-\frac{\partial^2 \ell(\boldsymbol{\theta})}{\partial \boldsymbol{\mu} \partial (\text{vech } \boldsymbol{\Sigma})^\top}\right\} &= \mathbf{0}, \\E\left\{-\frac{\partial^2 \ell(\boldsymbol{\theta})}{\partial \text{vech } \boldsymbol{\Sigma} \partial (\text{vech } \boldsymbol{\Sigma})^\top}\right\} &= \frac{n}{2} \mathbf{D}_p^\top (\boldsymbol{\Sigma}^{-1} \otimes \boldsymbol{\Sigma}^{-1}) \mathbf{D}_p.\end{aligned}$$

⁴Usando el 2do Teorema de identificación de Magnus y Neudecker (2007).



Resultado 4

Sea $\mathbf{x}_1, \dots, \mathbf{x}_n$ una muestra aleatoria desde una distribución $N_p(\boldsymbol{\mu}, \boldsymbol{\Sigma})$. Entonces $\bar{\mathbf{x}}$ y $\widehat{\boldsymbol{\Sigma}}$ son **estimadores consistentes**⁵ de $\boldsymbol{\mu}$ y $\boldsymbol{\Sigma}$, respectivamente. Además, $\bar{\mathbf{x}}$ y $\widehat{\boldsymbol{\Sigma}}$ son **asintóticamente independientes** con distribuciones

$$\begin{aligned}\sqrt{n}(\bar{\mathbf{x}} - \boldsymbol{\mu}) &\xrightarrow{D} N_p(\mathbf{0}, \boldsymbol{\Sigma}), \\ \sqrt{n}(\text{vech } \widehat{\boldsymbol{\Sigma}} - \text{vech } \boldsymbol{\Sigma}) &\xrightarrow{D} N_{p^*}(\mathbf{0}, 2\mathbf{D}_p^+(\boldsymbol{\Sigma} \otimes \boldsymbol{\Sigma})(\mathbf{D}_p^+)^{\top}),\end{aligned}$$

con $p^* = p(p+1)/2$.

⁵Es decir, $\bar{\mathbf{x}} \xrightarrow{P} \boldsymbol{\mu}$ y $\widehat{\boldsymbol{\Sigma}} \xrightarrow{P} \boldsymbol{\Sigma}$.



Casos particulares (Tarea)

Suponga $\mathbf{x}_1, \dots, \mathbf{x}_n$ vectores aleatorios IID desde $N_p(\boldsymbol{\mu}, \boldsymbol{\Sigma})$ y considere:

1. $\boldsymbol{\mu} = \boldsymbol{\mu}_0$ conocido. Entonces,

$$\widehat{\boldsymbol{\Sigma}} = \frac{1}{n} \sum_{i=1}^n (\mathbf{x}_i - \boldsymbol{\mu}_0)(\mathbf{x}_i - \boldsymbol{\mu}_0)^\top.$$

2. $\boldsymbol{\Sigma} = \boldsymbol{\Sigma}_0$ conocido. De este modo,

$$\widehat{\boldsymbol{\mu}} = \bar{\mathbf{x}}.$$

3. $\boldsymbol{\mu} = \gamma \mathbf{a}$, $\gamma \in \mathbb{R}$ con $\mathbf{a} \in \mathbb{R}^p$ conocido. Luego,

$$\widehat{\gamma}_\Sigma = \frac{\mathbf{a}^\top \boldsymbol{\Sigma}^{-1} \bar{\mathbf{x}}}{\mathbf{a}^\top \boldsymbol{\Sigma}^{-1} \mathbf{a}}.$$

Para $\boldsymbol{\Sigma}$ desconocido, tenemos:

$$\widehat{\gamma} = \frac{\mathbf{a}^\top \mathbf{S}^{-1} \bar{\mathbf{x}}}{\mathbf{a}^\top \mathbf{S}^{-1} \mathbf{a}}.$$



4. $A\boldsymbol{\mu} = \mathbf{a}$, $A \in \mathbb{R}^{q \times p}$, $\mathbf{a} \in \mathbb{R}^q$ matrices conocidas. Luego

$$\hat{\boldsymbol{\mu}}_{\Sigma} = \bar{\mathbf{x}} - \Sigma \mathbf{A}^{\top} (\mathbf{A} \Sigma \mathbf{A}^{\top})^{-1} (\mathbf{A} \bar{\mathbf{x}} - \mathbf{a}),$$

para Σ desconocido

$$\hat{\boldsymbol{\mu}} = \bar{\mathbf{x}} - \mathbf{S} \mathbf{A}^{\top} (\mathbf{A} \mathbf{S} \mathbf{A}^{\top})^{-1} (\mathbf{A} \bar{\mathbf{x}} - \mathbf{a}).$$

5. $\Sigma = \phi \mathbf{V}$ con $\mathbf{V} > 0$ conocida y $\phi > 0$. Por tanto,

$$\hat{\boldsymbol{\mu}} = \bar{\mathbf{x}}, \quad \hat{\phi} = \frac{1}{p} \text{tr}(\mathbf{V}^{-1} \mathbf{S}).$$

