

# Alkalmazott statisztika jegyzetvázlat

Kevei Péter

2018. november 30.

## Tartalomjegyzék

<b>1. Többdimenziós normális eloszlás</b>	<b>2</b>
1.1. Véletlen vektorváltozók . . . . .	2
1.2. Többdimenziós normális eloszlás . . . . .	3
1.3. Paraméterek ML becslése . . . . .	6
1.4. Hotelling-féle $T^2$ eloszlás . . . . .	10
1.5. Várható érték tesztelése . . . . .	13
1.5.1. Ismert kovarianciamátrix esete . . . . .	13
1.5.2. Ismeretlen kovarianciamátrix esete . . . . .	13
1.6. Többdimenziós CHT . . . . .	14
<b>2. Lineáris módszerek</b>	<b>15</b>
2.1. Főkomponensanalízis . . . . .	15
2.2. Merőleges vetítés . . . . .	17
2.3. Lineáris regresszió véletlen regresszorral . . . . .	20
2.4. Determinisztikus változók . . . . .	21
2.5. Varianciaanalízis . . . . .	22

# 1. Többdimenziós normális eloszlás

## 1.1. Véletlen vektorváltozók

Az 1.1 és 1.2 fejezetek nagyrészt a Csörgő jegyzetből valók ([2, 33. fejezet]).

Legyen  $\mathbf{X}^\top = (X_1, \dots, X_k)$  véletlen vektor az  $(\Omega, \mathcal{A}, \mathbf{P})$  valószínűségi mezőn. Ha  $\mathbf{E}(|X_j|) < \infty$  és  $m_j = \mathbf{E}(X_j)$ ,  $1 \leq j \leq k$ , akkor az  $\mathbf{m}^\top = (m_1, \dots, m_k)$  jelöléssel, a várható értéket komponensenként véve  $\mathbf{E}(\mathbf{X}) = \mathbf{m}$  az  $\mathbf{X}$  véletlen vektor *várható érték vektora*. Ha a szórások is végesek, azaz  $\mathbf{E}(X_j^2) < \infty$ ,  $1 \leq j \leq k$ , akkor a  $\sigma_{jl} = \mathbf{Cov}(X_j, X_l)$  kovariancia definiált minden  $1 \leq j, l \leq k$  párra. A kovarianciákból képzett  $k \times k$ -as

$$\Sigma = \Sigma_X = \begin{pmatrix} \sigma_{11} & \dots & \sigma_{1k} \\ \vdots & \ddots & \vdots \\ \sigma_{k1} & \dots & \sigma_{kk} \end{pmatrix} = \mathbf{E}((\mathbf{X} - \mathbf{m})(\mathbf{X} - \mathbf{m})^\top) = \mathbf{Cov}(\mathbf{X})$$

szimmetrikus mátrixot  $\mathbf{X}$  *kovarianciamátrixának* nevezzük.

A  $k \times k$ -as  $A$  mátrix *pozitív szemidefinit*, ha a

$$\mathbf{x}^\top A \mathbf{x} = \sum_{i,j} a_{i,j} x_i x_j \geq 0$$

minden  $\mathbf{x} \in \mathbb{R}^k$  esetén, és *pozitív definit*, ha az  $\mathbf{x}^\top A \mathbf{x}$  kvadratikus alak pozitív minden  $\mathbf{x} \neq \mathbf{0}^\top = (0, \dots, 0)$  vektor esetén. Egy nemnegatív definit mátrix pontosan akkor pozitív definit, ha nonszinguláris, azaz  $\det A \neq 0$ .

**1.1. Állítás.** *A kovarianciamátrix szimmetrikus, pozitív szemidefinit mátrix.*

Ha  $\sigma_j^2 > 0$ ,  $1 \leq j \leq k$ , akkor definiálhatjuk a  $\varrho_{jl} = \varrho(X_j, X_l) = \sigma_{jl}/(\sigma_j \sigma_l)$ ,  $1 \leq j, l \leq k$  korrelációs együtthatókat. Legyen

$$R = \begin{pmatrix} \varrho_{11} & \dots & \varrho_{1k} \\ \vdots & \ddots & \vdots \\ \varrho_{k1} & \dots & \varrho_{kk} \end{pmatrix} \quad \text{és} \quad D_0 = \begin{pmatrix} \sigma_1 & & 0 \\ & \ddots & \\ 0 & & \sigma_k \end{pmatrix}.$$

A szimmetrikus nemnegatív definit  $R = R_X$  mátrix az  $\mathbf{X}$  *korrelációmátrixa*. Most is  $\det(R) \geq 0$ , és  $\varrho_{11} = \dots = \varrho_{kk} = 1$ . A  $D_0$  diagonális mátrix a  $\Sigma = D_0 R D_0$  azonosság miatt hasznos.

**1.2. Definíció.** Legyenek  $X_1, \dots, X_k$  olyan véletlen változók, melyeknek  $\Sigma$  kovarianciamátrixa létezik. Akkor mondjuk, hogy az  $X_1, \dots, X_k$  változók

lineárisan függetlenek, ha a  $\mathbf{P}\{\sum_{j=1}^k x_j(X_j - m_j) = 0\} = 1$  egyenlőség esetén  $x_1^2 + \dots + x_k^2 = 0$ , azaz  $(x_1, \dots, x_k) = (0, \dots, 0)$ .

Gondoljuk meg, hogy a definíció szemléletesen azt jelenti, hogy  $X_1, \dots, X_k$  pontosan akkor függőek, ha az  $\mathbf{X} = (X_1, \dots, X_k)^\top$  véletlen vektor 1 valószínűséggel egy hipersíkra koncentrált, azaz az eloszlás degenerált.

**1.3. Állítás.** Legyen  $\mathbf{X}^\top = (X_1, \dots, X_k)$  véletlen vektor, melyre  $\mathbf{E}(X_j^2) < \infty$ ,  $1 \leq j \leq k$ ,  $\mathbf{E}(\mathbf{X}) = \mathbf{m}$  és  $\mathbf{Cov}(\mathbf{X}) = \Sigma$ .

1. A következő öt állítás ekvivalens:  $\Sigma$  pozitív definit;  $R$  pozitív definit;  $\det \Sigma > 0$ ;  $\det R > 0$ ;  $X_1, \dots, X_k$  lineárisan függetlenek.
2. Ha  $r \in \mathbb{N}$ ,  $A \in \mathbb{R}^{r \times k}$  és  $\mathbf{b} \in \mathbb{R}^r$ , akkor  $\mathbf{E}(A\mathbf{X} + \mathbf{b}) = A\mathbf{m} + \mathbf{b}$  és  $\mathbf{Cov}(A\mathbf{X} + \mathbf{b}) = A\Sigma A^\top$ .

**1.4. Feladat.** Bizonyítsuk be az állítást!

## 1.2. Többdimenziós normális eloszlás

Legyenek  $Z_1, \dots, Z_k$  független standard normális eloszlású véletlen változók egy  $(\Omega, \mathcal{A}, \mathbf{P})$  valószínűségi mezőn. Ekkor  $\mathbf{Z}^\top = (Z_1, \dots, Z_k)$  kovarianciamátrixa  $I = (\delta_{jl})_{j,l=1}^k$  a  $k \times k$ -as egységmátrix. Ekkor  $Z$   $k$ -dimenziós standard normális eloszlású véletlen vektorváltozó, jelben  $Z \sim \mathcal{N}_k(0, I)$ . A függetlenség miatt  $Z$  sűrűségfüggvénye

$$f_{0,I}(\mathbf{x}) = \frac{1}{(2\pi)^{k/2}} e^{-\frac{1}{2}|\mathbf{x}|^2} = \frac{1}{(2\pi)^{k/2}} e^{-\frac{1}{2}\langle \mathbf{x}, \mathbf{x} \rangle}, \quad \mathbf{x} \in \mathbb{R}^k,$$

Persze ha egy  $Z$  véletlen vektor  $Z \sim \mathcal{N}_k(0, I)$  eloszlású, akkor komponensei szükségképpen független standard normálisok.

Legyenek  $A \in \mathbb{R}^{k \times k}$  és  $\mathbf{m} \in \mathbb{R}^k$  tetszőlegesek,  $Z \sim \mathcal{N}_k(0, I)$ . Tekintsük az  $\mathbf{X} = AZ + \mathbf{m}$   $k$ -dimenziós véletlen vektort. Az 1.3. Állítás szerint  $\mathbf{E}(\mathbf{X}) = \mathbf{m}$ ,  $\Sigma := \mathbf{Cov}(\mathbf{X}) = AIA^\top = AA^\top$ .

Legyen  $\Sigma \in \mathbb{R}^{k \times k}$  szimmetrikus nemnegatív definit mátrix, és tekintsük  $\lambda_j$  sajátértékeit és  $x_j \in \mathbb{R}^k$  sajátvektorait, azaz  $\Sigma x_j = \lambda x_j$ ,  $j = 1, \dots, k$ . Alapvető eredmény lineáris algebrából, hogy az  $x_1, \dots, x_k$  sajátvektorokból ortogonális  $U$  mátrix képezhető, és a  $D = U^\top \Sigma U$  mátrix, ill. ennek  $D_0$  négyzetgyöke a következő alakú:

$$D = \begin{pmatrix} \lambda_1 & & 0 \\ & \ddots & \\ 0 & & \lambda_k \end{pmatrix} \quad \text{és} \quad D_0 = \begin{pmatrix} \sqrt{\lambda_1} & & 0 \\ & \ddots & \\ 0 & & \sqrt{\lambda_k} \end{pmatrix}.$$

Mivel  $\Sigma$  nemnegatív definit, ezért  $\lambda_1 \geq 0, \dots, \lambda_k \geq 0$ , azaz  $D_0$  valóban definiálható valós mátrix. Bevezetve az  $A = UD_0$  mátrixot látjuk, hogy

$$AA^T = UD_0(UD_0)^T = UD_0D_0^T U^T = UD_0D_0U^T = UDU^T,$$

azaz  $AA^T = \Sigma$ . [Emlékeztetünk, hogy egy  $U = (u_{jl})_{j,l=1}^k$  mátrix akkor ortogonális, ha  $\sum_{j=1}^k u_{lj}u_{mj} = \delta_{lm}$ ,  $1 \leq l, m \leq k$ , vagyis oszlopai (sorai) merőlegesek egymásra és normáltak. Ekkor persze  $U^{-1} = U^T$ .]

Ezzel beláttuk, a következőt.

**1.5. Állítás.** Adott  $\Sigma \in \mathbb{R}^{k \times k}$  szimmetrikus pozitív szemidefinit mátrixhoz és  $\mathbf{m} \in \mathbb{R}^k$  vektorhoz létezik olyan véletlen, melynek  $\Sigma$  a kovarianciamátrixa, és  $\mathbf{m}$  a várható érték vektora.

**1.6. Definíció.** A  $k$ -dimenziós  $\mathbf{X}$  véletlen vektor *normális eloszlású*, ha van olyan  $\mathbf{m} \in \mathbb{R}^k$ ,  $A \in \mathbb{R}^{k \times k}$ , és  $\mathbf{Z}$   $k$  dimenziós standard normális vektorváltozó, hogy

$$\mathbf{X} = A\mathbf{Z} + \mathbf{m}.$$

Ekkor  $\mathbf{X} \sim \mathcal{N}_k(\mathbf{m}, \Sigma)$ , ahol  $\mathbf{m} \in \mathbb{R}^k$  és  $\Sigma = AA^T$  szimmetrikus nemnegatív definit mátrix. Ekkor  $\mathbf{E}(\mathbf{X}) = \mathbf{m}$  és  $\mathbf{Cov}(\mathbf{X}) = \Sigma$ .

Ha  $\Sigma$  szinguláris, azaz  $\det \Sigma = 0$ , akkor az 1.3. Állítás szerint  $\mathbf{X} \sim \mathcal{N}_k(\mathbf{m}, \Sigma)$  koordinátái lineárisan függőek, és így  $\mathbf{X}$  degenerált abban az értelemben, hogy majdnem biztosan egy  $k$ -nál kisebb dimenziós hipersíkra koncentrált. Ekkor persze eloszlása nem lehet folytonos.

A nemdegenerált esetben az  $\mathcal{N}_k(\mathbf{m}, \Sigma)$  eloszlás folytonos és sűrűségét is meg tudjuk határozni.

**1.7. Állítás.** Jelölje  $\mathbf{X}$  véletlen vektor  $\mathcal{N}_k(\mathbf{m}, \Sigma)$  normális eloszlású, ahol  $\mathbf{m} \in \mathbb{R}^k$  és  $\Sigma \in \mathbb{R}^{k \times k}$  szimmetrikus pozitív definit kovarianciamátrix. Ekkor  $\mathbf{X}$  folytonos és sűrűségfüggvénye

$$f_{\mathbf{m}, \Sigma}(\mathbf{x}) = \frac{1}{(2\pi)^{k/2} \sqrt{\det \Sigma}} e^{-\frac{1}{2}(\mathbf{x}-\mathbf{m})^T \Sigma^{-1}(\mathbf{x}-\mathbf{m})}, \quad \mathbf{x} \in \mathbb{R}^k.$$

*Bizonyítás.* Legyen  $\mathbf{Z} \sim \mathcal{N}_k(0, I)$ . Ekkor  $A\mathbf{Z} + \mathbf{m} \sim \mathcal{N}_k(\mathbf{m}, \Sigma)$ , ahol  $A$  az a fent definiált  $k \times k$ -as mátrix, melyre  $\Sigma = AA^T$ . Ekkor  $A$  is nonsinguláris, hiszen  $0 \neq \det(\Sigma) = \det(A) \det(A^T)$ . Legyen  $M : \mathbb{R}^k \rightarrow \mathbb{R}^k$  az a lineáris

transzformáció, melyre  $M(\mathbf{x}) = A^{-1}(\mathbf{x} - \mathbf{m})$ ,  $\mathbf{x} \in \mathbb{R}^k$ . Tetszőleges  $B$  Borel-halmazra

$$\begin{aligned}
\mathbf{P}(\mathbf{x} \in B) &= \mathbf{P}\{AZ + \mathbf{m} \in B\} = \mathbf{P}\{\mathbf{Z} \in M(B)\} \\
&= \int_{M(B)} \frac{1}{(2\pi)^{k/2}} e^{-\frac{1}{2}|y|^2} \lambda^k(dy) \\
&= \int_B \frac{1}{(2\pi)^{k/2}} e^{-\frac{1}{2}|A^{-1}(\mathbf{x}-\mathbf{m})|^2} |\det(A^{-1})| \lambda^k(dx) \\
&= \int_B \frac{1}{(2\pi)^{k/2} |\det(A)|} e^{-\frac{1}{2}\langle A^{-1}(\mathbf{x}-\mathbf{m}), A^{-1}(\mathbf{x}-\mathbf{m}) \rangle} \lambda^k(dx) \\
&= \int_B \frac{1}{(2\pi)^{k/2} \sqrt{|\det(\Sigma)|}} e^{-\frac{1}{2}\langle (A^{-1})^T A^{-1}(\mathbf{x}-\mathbf{m}), \mathbf{x}-\mathbf{m} \rangle} \lambda^k(dx) \\
&= \int_B \frac{1}{(2\pi)^{k/2} \sqrt{\det(\Sigma)}} e^{-\frac{1}{2}\langle \Sigma^{-1}(\mathbf{x}-\mathbf{m}), \mathbf{x}-\mathbf{m} \rangle} \lambda^k(dx) \\
&= \int_B f_{\mathbf{m}, \Sigma}(x) dx,
\end{aligned}$$

ahol felhasználtuk azt az egyszerű tényt, hogy  $(A^{-1})^\top = (A^\top)^{-1}$ .  $\square$

Tekintsük a  $\Sigma = UDU^\top$  spektrálfelbontást, ahol  $D$  diagonális,  $U$  pedig ortogonális. Bevezetve a  $\mathbf{z} = U^\top(\mathbf{x} - \mathbf{m})$  változót (vegyük észre, hogy ez a transzformáció egy eltolás majd egy forgatás), a sűrűségfüggvényben az exponens

$$\begin{aligned}
(\mathbf{x} - \mathbf{m})^\top \Sigma^{-1}(\mathbf{x} - \mathbf{m}) &= (\mathbf{x} - \mathbf{m})^\top U D^{-1} U^\top (\mathbf{x} - \mathbf{m}) \\
&= \mathbf{z}^\top D^{-1} \mathbf{z} \\
&= \sum_{i=1}^k \frac{1}{\lambda_i} z_i^2,
\end{aligned}$$

alakra hozható. Innen látjuk, hogy a sűrűségfüggvény szintvonalai ellipszoidok.

A sűrűségfüggvény explicit alakjából azonnal adódik a következő állítás.

**1.8. Állítás.** *Az  $X_1, X_2, \dots, X_k$  együttesen normális eloszlású véletlen változók pontosan akkor függetlenek, ha kovarianciamátrixuk diagonális.*

A következő állítás szerint a többváltozós normális eloszlások osztálya zárt a lineáris transzformációkra nézve.

**1.9. Állítás.** *Ha  $\mathbf{X} \sim \mathcal{N}_k(\mathbf{m}, \Sigma)$ ,  $\mathbf{b} \in \mathbb{R}^r$ ,  $r \in \mathbb{N}$ , és  $A \in \mathbb{R}^{r \times k}$ , akkor  $A\mathbf{X} + \mathbf{b} \sim \mathcal{N}_r(A\mathbf{m} + \mathbf{b}, A\Sigma A^\top)$ .*

Az 1.9. Állítás szerint az egydimenziós esetben megszokott módon lehet standardizálni.

**1.10. Következmény.** Ha  $\mathbf{X} \sim \mathcal{N}_k(\mathbf{m}, \Sigma)$ , és  $\Sigma = AA^\top$ , akkor

1.  $\mathbf{Y} = A^{-1}(\mathbf{X} - \mathbf{m}) \sim \mathcal{N}_k(0, I_k)$ .
2.  $(\mathbf{X} - \mathbf{m})^\top \Sigma^{-1}(\mathbf{X} - \mathbf{m}) \sim \chi^2(k)$ .

*Bizonyítás.* Az első állítás az 1.9. Állítás következménye, míg a második következik a  $\chi^2$ -eloszlás definíciójából és az elsőből.  $\square$

Az 1.9. Állítás speciális esete a következő.

**1.11. Következmény.** Ha  $\mathbf{X} \sim \mathcal{N}_k(\mathbf{m}, \Sigma)$ , akkor minden  $\mathbf{t} \in \mathbb{R}^k$  esetén  $\langle \mathbf{t}, X \rangle \sim \mathcal{N}(\langle \mathbf{t}, \mathbf{m} \rangle, \mathbf{t}^\top \Sigma \mathbf{t})$ , ha  $\mathbf{t}^\top \Sigma \mathbf{t} > 0$  és  $\langle \mathbf{t}, \mathbf{X} \rangle$  degenerált – majdnem biztosan  $\langle \mathbf{t}, \mathbf{m} \rangle$  – ha  $\mathbf{t}^\top \Sigma \mathbf{t} = 0$ .

A többdimenziós normális eloszlás számos szép tulajdonsága ismert. Itt csak további kettőt említünk: Az 1.7. Állítás megfordítása is igaz, nevezetesen ha  $\mathbf{X} \sim \mathcal{N}_k(\mathbf{m}, \Sigma)$  és  $\mathbf{X}$  eloszlása abszolút folytonos, akkor  $\Sigma$  pozitív definit. Az utóbbi következmény megfordítása is igaz, azaz a következményben megfogalmazott tulajdonság karakterizálja a normális eloszlást.

### 1.3. Paraméterek ML becslése

Itt Johnson, Wichern [3, Chapter 4.3] jegyzetet követjük.

Legyenek  $\mathbf{X}_1, \mathbf{X}_2, \dots, \mathbf{X}_n$  független  $\mathcal{N}_k(\mathbf{m}, \Sigma)$  eloszlású véletlen vektorok. A következőkben megadjuk  $(\mathbf{m}, \Sigma)$  maximum likelihood becslését. A függetlenség miatt az együttes sűrűségfüggvény

$$\begin{aligned} f(\mathbf{x}_1, \dots, \mathbf{x}_n) &= \prod_{j=1}^n \frac{1}{(2\pi)^{k/2} |\Sigma|^{1/2}} e^{-\frac{1}{2}(\mathbf{x}_j - \mathbf{m})^\top \Sigma^{-1}(\mathbf{x}_j - \mathbf{m})} \\ &= \frac{1}{(2\pi)^{nk/2} |\Sigma|^{n/2}} \exp \left\{ -\frac{1}{2} \sum_{i=1}^n (\mathbf{x}_i - \mathbf{m})^\top \Sigma^{-1}(\mathbf{x}_i - \mathbf{m}) \right\}. \end{aligned}$$

Az alábbi jól ismert lineáris algebrából.

**1.12. Feladat.** Egy négyzetes mátrix *nyoma* a főátlóban lévő elemeinek összege, azaz  $\text{tr}(A) = \sum_{i=1}^k a_{ii}$ . Igazoljuk, hogy

1.  $\text{tr}(BC) = \text{tr}(CB)$ , ahol  $B \in \mathbb{R}^{k \times \ell}$ ,  $C \in \mathbb{R}^{\ell \times k}$  (azaz a nyom *ciklikus*);

2.  $\mathbf{x}^\top \mathbf{A} \mathbf{x} = \text{tr}(\mathbf{x}^\top \mathbf{A} \mathbf{x}) = \text{tr}(\mathbf{A} \mathbf{x} \mathbf{x}^\top)$ , ahol  $A \in \mathbb{R}^{k \times k}$ ,  $\mathbf{x} \in \mathbb{R}^k$ ;
3.  $\text{tr} A = \sum_{i=1}^k \lambda_i$ , ahol  $\lambda_i$ -k az  $A$  sajátértékei.

A Steiner-formula magasabb dimenziós megfelelője az alábbi. A bizonyítás az egydimenziós esethez hasonlóan egyszerű.

**1.13. Feladat.** *Többdimenziós Steiner-formula.* Igazoljuk, hogy tetszőleges  $\mathbf{x}_1, \dots, \mathbf{x}_n \in \mathbb{R}^k$ ,  $\mathbf{v} \in \mathbb{R}^k$  esetén

$$\sum_{i=1}^n (\mathbf{x}_i - \mathbf{v})(\mathbf{x}_i - \mathbf{v})^\top = \sum_{i=1}^n (\mathbf{x}_i - \bar{\mathbf{x}})(\mathbf{x}_i - \bar{\mathbf{x}})^\top + n(\bar{\mathbf{x}} - \mathbf{v})(\bar{\mathbf{x}} - \mathbf{v})^\top,$$

ahol  $\bar{\mathbf{x}} = n^{-1} \sum_{i=1}^n \mathbf{x}_i$ .

A levezetésnél szükségünk lesz az alábbi egyszerű állításra.

**1.14. Feladat.** Legyen  $\Sigma$  pozitív definit szimmetrikus mátrix. Igazoljuk, hogy ha  $\Sigma \mathbf{x} = \lambda \mathbf{x}$ , akkor  $\Sigma^{-1} \mathbf{x} = \lambda^{-1} \mathbf{x}$ , és  $\Sigma^{-1}$  pozitív definit!

A nyom ciklikusságát és a Steiner-formulát felhasználva, némi számolás után kapjuk, hogy

$$\begin{aligned} \sum_{i=1}^n (\mathbf{x}_i - \mathbf{m})^\top \Sigma^{-1} (\mathbf{x}_i - \mathbf{m}) &= \text{tr} \left( \Sigma^{-1} \sum_{i=1}^n (\mathbf{x}_i - \bar{\mathbf{x}})(\mathbf{x}_i - \bar{\mathbf{x}})^\top \right) \\ &\quad + n(\bar{\mathbf{x}} - \mathbf{m})^\top \Sigma^{-1} (\bar{\mathbf{x}} - \mathbf{m}), \end{aligned}$$

ahol

$$\bar{\mathbf{x}} = \bar{\mathbf{x}} = \frac{1}{n} \sum_{i=1}^n \mathbf{x}_i. \quad (1)$$

A formulát beírva a sűrűségfüggvényre, és áttérve a likelihood függvényre (ami persze ugyanaz, csak az argumentum változott)

$$\begin{aligned} L(\mathbf{m}, \Sigma) &= \frac{1}{(2\pi)^{nk/2} |\Sigma|^{n/2}} \times \\ &\quad \times \exp \left\{ -\frac{1}{2} \text{tr} \left( \Sigma^{-1} \sum_{i=1}^n (\mathbf{x}_i - \bar{\mathbf{x}})(\mathbf{x}_i - \bar{\mathbf{x}})^\top \right) \right. \\ &\quad \left. - n(\bar{\mathbf{x}} - \mathbf{m})^\top \Sigma^{-1} (\bar{\mathbf{x}} - \mathbf{m}) \right\}. \end{aligned} \quad (2)$$

Mivel pozitív definit mátrix inverze is pozitív definit (lásd 1.14. Feladat), ezért  $\mathbf{y}^\top \Sigma^{-1} \mathbf{y} \geq 0$ , tehát a  $L$  maximuma  $\mathbf{m}$ -ben

$$\mathbf{m} = \bar{\mathbf{x}}.$$

Mivel ez nem függ  $\Sigma$ -tól, ezért egyszerűen beírhatjuk a formulába, és maximalizálhatunk  $\Sigma$ -ban, ami érdekesebb feladat, hiszen egy pozitív definit mátrixban keressük a maximumot. Kapjuk, hogy

$$L(\bar{\mathbf{x}}, \Sigma) = \frac{1}{(2\pi)^{nk/2} |\Sigma|^{n/2}} \exp \left\{ -\frac{1}{2} \text{tr} \left( \Sigma^{-1} \sum_{i=1}^n (\mathbf{x}_i - \bar{\mathbf{x}})(\mathbf{x}_i - \bar{\mathbf{x}})^\top \right) \right\}. \quad (3)$$

A szélsőérték-feladatot a következő állítás segítségével oldjuk meg.

**1.15. Lemma.** *Legyen  $B \in \mathbb{R}^{k \times k}$  szimmetrikus pozitív definit mátrix,  $b > 0$ . Tetszőleges  $\Sigma \in \mathbb{R}^{k \times k}$  pozitív definit mátrixra*

$$\frac{1}{|\Sigma|^b} \exp \left\{ -\frac{1}{2} \text{tr}(\Sigma^{-1} B) \right\} \leq \frac{1}{|B|^b} (2b)^{kb} e^{-bk}.$$

*Továbbá pontosan akkor teljesül egyenlőség, ha  $\Sigma = \frac{1}{2b} B$ .*

*Bizonyítás.* Tekintsük a  $B = UDU^\top$  spektrálfelbontást, és legyen  $B^{1/2} = UD^{1/2}U^\top$ . Legyenek  $\lambda_1, \dots, \lambda_k$  a  $B^{1/2}\Sigma^{-1}B^{1/2}$  pozitív definit mátrix sajátértékei. A  $\text{tr}$  ciklikussága miatt

$$\text{tr}(\Sigma^{-1} B) = \text{tr}(B^{1/2}\Sigma^{-1}B^{1/2}) = \sum_{i=1}^k \lambda_i.$$

Mivel  $|B^{1/2}\Sigma^{-1}B^{1/2}| = \prod_{i=1}^k \lambda_i = |B|/|\Sigma|$ , így

$$\frac{1}{|\Sigma|^b} \exp \left\{ -\frac{1}{2} \text{tr}(\Sigma^{-1} B) \right\} = \frac{\left( \prod_{i=1}^k \lambda_i \right)^b}{|B|^b} e^{-\frac{1}{2} \sum \lambda_i} = \frac{1}{|B|^b} \prod_{i=1}^k \lambda_i^b e^{-\frac{1}{2} \sum \lambda_i}.$$

Egyszerű számolás mutatja, hogy a  $x^b e^{-x/2}$  függvény a maximumát az  $x = 2b$  helyen veszi fel, ahonnan az egyenlőtlenség már adódik. Egyenlőség pontosan akkor van, ha

$$\lambda_1 = \dots = \lambda_k = 2b,$$

ami pedig éppen azt jelenti, hogy  $\Sigma = \frac{1}{2b} B$ . □

A lemmából következik, hogy (3) formulában a maximum a

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

helyen vétetik fel. Ezzel beláttuk a következőt.



**1.16. Tétel.** *A többdimenziós normális eloszlásnál az  $(\mathbf{m}, \Sigma)$  pár maximum likelihood becslése*

$$\hat{\mathbf{m}} = \frac{1}{n} \sum_{i=1}^n \mathbf{X}_i = \bar{\mathbf{X}}_n,$$

$$\hat{\Sigma} = \frac{1}{n} \sum_{i=1}^n (\mathbf{X}_i - \bar{\mathbf{X}})(\mathbf{X}_i - \bar{\mathbf{X}})^\top = \frac{1}{n} S.$$

A várható érték becslése torzítatlan, míg a kovarianciamátrix becslése csak aszimptotikusan torzítatlan.

**1.17. Feladat.** Igazoljuk, hogy

$$\mathbf{E}\bar{\mathbf{X}} = \mathbf{m}, \quad \mathbf{E}\frac{1}{n}S = \frac{n-1}{n}\Sigma.$$

A konzisztencia egyszerűen következik a nagy számok törvényéből.

**1.18. Feladat.** Igazoljuk, hogy

$$\bar{\mathbf{X}}_n \rightarrow \mathbf{m}, \quad \text{és} \quad \frac{1}{n}S \rightarrow \Sigma, \quad \text{amint } n \rightarrow \infty,$$

egy valószínűséggel, és (persze ebből már következik) gyengén.

A továbbiakban a Bolla és Krámlí [1, 5.4 fejezet] jegyzetét követjük.

**1.19. Definíció.** Egy  $W \in \mathbb{R}^{k \times k}$  véletlen mátrix  $n$  szabadsági fokú és  $\Sigma$  kovarianciájú Wishart-mátrix, jelben  $W \sim \mathcal{W}_k(n, \Sigma)$ , ha  $W = XX^\top$ , ahol  $X \in \mathbb{R}^{k \times n}$  véletlen mátrix oszlopai független  $\mathcal{N}_k(0, \Sigma)$  eloszlású normálisok. Ha  $\Sigma = I_k$  akkor standard Wishart-eloszlásról beszélünk.

Az alábbi az 1.9. Állítás egyszerű következménye.

**1.20. Állítás.** *Legyen  $\Sigma \in \mathbb{R}^{k \times k}$  pozitív definit. Ekkor  $W \sim \mathcal{W}_k(n, \Sigma)$  pontosan akkor, ha  $\Sigma^{-1/2}W\Sigma^{-1/2} \sim \mathcal{W}_k(n, I_k)$ .*

**1.21. Feladat.** Lássuk be az állítást!

A következő tétel, mely Lukács Jenő tételének többdimenziós változata, a Hotelling-féle T-eloszlás tulajdonságainál lesz fontos.

**1.22. Tétel.** *Legyenek  $\mathbf{X}_1, \dots, \mathbf{X}_n$  független  $\mathcal{N}_k(\mathbf{m}, \Sigma)$  eloszlású véletlen változók. Ekkor  $\bar{\mathbf{X}} \sim \mathcal{N}_k(\mathbf{m}, \Sigma/n)$ ,  $S \sim \mathcal{W}_k(n-1, \Sigma)$ , és  $\bar{\mathbf{X}}$  és  $S$  függetlenek.*

*Bizonyítás.* Legyen  $V \in \mathbb{R}^{n \times n}$  egy olyan ortogonális mátrix, melynek utolsó sora  $(1/\sqrt{n}, \dots, 1/\sqrt{n})$ , különben tetszőleges. Legyen

$$\mathbf{Y}_i = \sum_{j=1}^n v_{ij} \mathbf{X}_j \in \mathbb{R}^k.$$

Az  $Y = (\mathbf{Y}_1, \dots, \mathbf{Y}_n) \in \mathbb{R}^{k \times n}$  jelöléssel

$$Y^\top = VX^\top.$$

Világos, hogy  $\mathbf{Y}_1, \dots, \mathbf{Y}_n$  együttesen normálisok, és egyszerű számolás mutatja, hogy

$$\mathbf{Cov}(\mathbf{Y}_i, \mathbf{Y}_j) = \delta_{ij} \Sigma,$$

azaz  $\mathbf{Y}_1, \dots, \mathbf{Y}_n$  függetlenek közös  $\Sigma$  kovarianciamátrixszal. Mivel  $U$  ortogonális, és az utolsó sor minden komponense egyenlő, ezért a többi sorösszeg 0, tehát

$$\mathbf{E}\mathbf{Y}_i = \delta_{in} \sqrt{n} \mathbf{m}.$$

Vegyük észre, hogy

$$\sum_{i=1}^n \mathbf{Y}_i \mathbf{Y}_i^\top = YY^\top = XV^\top VX = X^\top X = \sum_{i=1}^n \mathbf{X}_i \mathbf{X}_i^\top,$$

és  $\mathbf{Y}_n = \sqrt{n} \bar{\mathbf{X}}$ . Tehát

$$\begin{aligned} S &= \sum_{i=1}^n (\mathbf{X}_i - \bar{\mathbf{X}})(\mathbf{X}_i - \bar{\mathbf{X}})^\top \\ &= \sum_{i=1}^n \mathbf{X}_i \mathbf{X}_i^\top - n \bar{\mathbf{X}} \bar{\mathbf{X}}^\top \\ &= \sum_{i=1}^n \mathbf{Y}_i \mathbf{Y}_i^\top - \mathbf{Y}_n \mathbf{Y}_n^\top \\ &= \sum_{i=1}^{n-1} \mathbf{Y}_i \mathbf{Y}_i^\top, \end{aligned}$$

amiből már adódik az állítás. □

## 1.4. Hotelling-féle $T^2$ eloszlás

Emlékeztetünk, hogy a Fisher-féle F-eloszlás független  $\chi^2$  eloszlású változók hányadosa. Azaz  $F \sim \mathcal{F}(m, n)$ , ha  $X \sim \chi^2(m)$ ,  $Y \sim \chi^2(n)$ ,  $X$  és  $Y$  függetlenek, és

$$F = \frac{X/m}{Y/n};$$

informálisan  $\mathcal{F}(m, n) = \frac{\chi^2(m)/m}{\chi^2(n)/n}$ .

**1.23. Tétel.** [Hotelling] Legyenek  $W \sim W_k(n, \Sigma)$ ,  $\xi \sim \mathcal{N}_k(0, \Sigma)$  függetlenek. Ekkor  $T^2 = \xi^\top W^{-1} \xi$  jelöléssel

$$\frac{n-k+1}{k} T^2 \sim \mathcal{F}(k, n-k+1).$$

A bizonyítás a következő két segédtelemen alapszik.

**1.24. Lemma.** Legyen  $X \in \mathbb{R}^{k \times n}$  független standard normálisokból álló mátrix, és  $Q \in \mathbb{R}^{n \times n}$  egy  $X$ -től független véletlen ortogonális mátrix. Ekkor  $XQ \in \mathbb{R}^{k \times n}$  elemei független standard normálisok, melyek függetlenek  $Q$ -tól.

*Bizonyítás.* Ez determinisztikus  $Q$ -ra világos, és mivel  $Q$  és  $X$  függetlenek, ezért  $Q$ -ra feltételesen minden működik.  $\square$

**1.25. Lemma.** Legyen  $X \in \mathbb{R}^{k \times n}$ ,  $n > k$ , független standard normálisokból álló mátrix. Legyen  $S = XX^\top \in \mathbb{R}^{k \times k}$ , és  $S_1 = (s_{ij})_{i,j \leq k-1} \in \mathbb{R}^{(k-1) \times (k-1)}$ , azaz  $S_1$  az  $S$  utolsó sorának és oszlopának elhagyásával kapott mátrix. Ekkor

$$\frac{|S|}{|S_1|} \sim \chi^2(n-k+1).$$

*Bizonyítás.* Legyen  $Q \in \mathbb{R}^{n \times n}$  egy olyan véletlen ortogonális mátrix, melynek első oszlopa  $Q_{\cdot 1} = R^{-1}X_{\cdot 1}$ , ahol  $R = |X_{\cdot 1}| = \sqrt{\sum_{i=1}^n X_{1i}^2}$ . Ekkor

$$S = XX^\top = XQQ^\top X^\top = \begin{pmatrix} R & 0 & \dots & 0 \\ \tilde{X}_{21} & \tilde{X}_{22} & \dots & \tilde{X}_{2n} \\ \vdots & \vdots & \ddots & \vdots \\ \tilde{X}_{k1} & \tilde{X}_{k2} & \dots & \tilde{X}_{kn} \end{pmatrix} \begin{pmatrix} R & \tilde{X}_{21} & \dots & \tilde{X}_{k1} \\ 0 & \tilde{X}_{22} & \dots & \tilde{X}_{k2} \\ \vdots & \vdots & \ddots & \vdots \\ 0 & \tilde{X}_{2n} & \dots & \tilde{X}_{kn} \end{pmatrix}. \quad (4)$$

Másrészt

$$XQ = \begin{pmatrix} R & 0 & \dots & 0 \\ \tilde{X}_{21} & 1 & \dots & 0 \\ \vdots & \vdots & \ddots & \vdots \\ \tilde{X}_{k1} & 0 & \dots & 1 \end{pmatrix} \begin{pmatrix} 1 & 0 & \dots & 0 \\ 0 & \tilde{X}_{22} & \dots & \tilde{X}_{2n} \\ \vdots & \vdots & \ddots & \vdots \\ 0 & \tilde{X}_{kn} & \dots & \tilde{X}_{kn} \end{pmatrix}, \quad (5)$$

ahol  $\tilde{X} = (\tilde{X}_{ij})_{1 \leq i \leq k-1; 1 \leq j \leq n-1} \in \mathbb{R}^{(k-1) \times (n-1)}$  független standard normálisokból álló mátrix az előző lemma szerint. Ekkor a (4) és (5) formulák szerint  $|S| = R^2 |\tilde{X} \tilde{X}^\top|$ . Ugyanezt el lehet játszani  $S_1$ -re, hiszen őt úgy kapjuk  $X$ -ből mint  $S$ -et, csak töröljük  $X$  utolsó sorát. Tehát  $|S_1| = R^2 |(\tilde{X} \tilde{X}^\top)_{i,j \leq k-2}|$ . Azaz

$$\frac{|S|}{|S_1|} = \frac{|\tilde{X} \tilde{X}^\top|}{|(\tilde{X} \tilde{X}^\top)_{i,j \leq k-2}|},$$

ami éppen olyan hányados, mint a definícióban szereplő, csak független standard normálisokból álló  $\tilde{X} \in \mathbb{R}^{(k-1) \times (n-1)}$  véletlen mátrix  $(k-1) \times (n-1)$ -es.

Tehát elég  $k = 2$ -re igazolni az állítást, utána működik az indukció. Na de ekkor, az  $S_1$  mátrix egy szám, és  $\tilde{X} \in \mathbb{R}^{n-1}$ , ezért  $|\tilde{X} \tilde{X}^\top| \sim \chi^2(n-1)$  így

$$\frac{|S|}{|S_1|} = \frac{R^2 |\tilde{X} \tilde{X}^\top|}{R^2} = |\tilde{X} \tilde{X}^\top| \sim \chi^2(n-1),$$

amint állítottuk. □

*Az 1.23. tétel bizonyítása.. A*

$$T^2 = \boldsymbol{\xi}^t \text{op} \Sigma^{-1/2} (\Sigma^{-1/2} W \Sigma^{-1/2})^{-1} \Sigma^{-1/2} \boldsymbol{\xi}$$

előállításban  $\Sigma^{-1/2} \boldsymbol{\xi} \sim \mathcal{N}_k(0, I_k)$  és  $\Sigma^{-1/2} W \Sigma^{-1/2} \sim \mathcal{W}_k(n, I_k)$ . Emiatt feltehető, hogy  $\Sigma = I_k$ . Legyen  $Q$  olyan  $\boldsymbol{\xi}$ -től függő ortogonális mátrix, hogy

$$\boldsymbol{\xi}^\top Q = (0, 0, \dots, 0, |\boldsymbol{\xi}|)^\top.$$

Ezzel a transzformációval

$$T^2 = \boldsymbol{\xi}^\top Q Q^\top W^{-1} Q Q^\top \boldsymbol{\xi} = ((Q^\top W Q)^{-1})_{kk} |\boldsymbol{\xi}|^2,$$

ahol persze  $|\boldsymbol{\xi}|^2 = \sum_{i=1}^k \xi_i^2 \sim \chi^2(k)$ . Vegyük észre, hogy az egész  $(Q^\top W Q)^{-1}$  nekünk csak a jobb alsó sarokban levő elem kell a  $\boldsymbol{\xi}^\top Q$  vektor miatt. A  $W$  definíció szerint  $W = X X^\top$  alakú, amit beírva

$$((Q^\top W Q)^{-1})_{kk} = ((Q^\top X X^\top Q)^{-1})_{kk}.$$

Az inverzmátrix jobb alsó elem, az inverzmátrix alakjából következően, a  $(k-1) \times (k-1)$ -es bal felső aldetemináns és a determináns hányadosa. Az 1.25. Lemma szerint ennek reciproka éppen  $\chi^2(n-k+1)$  eloszlású, és az 1.24. Lemma szerint ez független  $\boldsymbol{\xi}$ -től. Ezzel az állítást igazoltuk. □

## 1.5. Várható érték tesztelése

### 1.5.1. Ismert kovarianciamátrix esete

**Egymintás eset.** Legyenek  $\mathbf{X}_1, \dots, \mathbf{X}_n$  független  $\mathcal{N}_k(\mathbf{m}, \Sigma)$  eloszlású vektorok, ahol a  $\Sigma$  pozitív definit kovarianciamátrix ismert. A következő hipotézist vizsgáljuk:

$$H_0 : \mathbf{m} = \mathbf{m}_0 \quad H_A : \mathbf{m} \neq \mathbf{m}_0.$$

Ekkor  $H_0$  fennállása esetén  $\bar{\mathbf{X}}_n \sim \mathcal{N}_k(\mathbf{m}_0, n^{-1}\Sigma)$ , és így az 1.10. Következmény szerint

$$t_1 = n (\bar{\mathbf{X}} - \mathbf{m}_0)^\top \Sigma^{-1} (\bar{\mathbf{X}} - \mathbf{m}_0) \sim \chi^2(k), \quad (6)$$

azaz a próba  $\chi^2(k)$  eloszlású. Ez az egymintás u-próba többdimenziós változata.

**Kétmintás eset.** Legyenek  $\mathbf{X}_1, \dots, \mathbf{X}_n$  független  $\mathcal{N}_k(\mathbf{m}, \Sigma)$  eloszlású vektorok és  $\mathbf{Y}_1, \dots, \mathbf{Y}_m$  az  $\mathbf{X}$ -ektől független  $\mathcal{N}_k(\mathbf{m}', \Sigma)$  eloszlású vektorok, ahol a  $\Sigma$  pozitív definit kovarianciamátrix (közös!) ismert. A következő hipotézist vizsgáljuk:

$$H_0 : \mathbf{m} = \mathbf{m}' \quad H_A : \mathbf{m} \neq \mathbf{m}'.$$

Ekkor az egymintás esethez hasonlóan  $H_0$  fennállása esetén  $\bar{\mathbf{X}}_n - \bar{\mathbf{Y}}_m \sim \mathcal{N}_k(0, (n^{-1} + m^{-1})\Sigma)$ , és így az 1.10. Következmény szerint

$$t_2 = \frac{nm}{n+m} (\bar{\mathbf{X}}_n - \bar{\mathbf{Y}}_m)^\top \Sigma^{-1} (\bar{\mathbf{X}}_n - \bar{\mathbf{Y}}_m) \sim \chi^2(k),$$

azaz a próba  $\chi^2(k)$  eloszlású. Ez az kétmintás u-próba többdimenziós változata.

### 1.5.2. Ismeretlen kovarianciamátrix esete

**Egymintás eset.** Legyenek  $\mathbf{X}_1, \dots, \mathbf{X}_n$  független  $\mathcal{N}_k(\mathbf{m}, \Sigma)$  eloszlású vektorok, ahol a  $\Sigma$  pozitív definit kovarianciamátrix nem ismert. A következő hipotézist vizsgáljuk:

$$H_0 : \mathbf{m} = \mathbf{m}_0 \quad H_A : \mathbf{m} \neq \mathbf{m}_0.$$

A (6) próbastatisztikában most a kovarianciamátrixot a ML becslésével (1.16. Tétel) helyettesítjük. Ekkor a  $\Sigma$  helyére

$$\hat{\Sigma} = \frac{1}{n} \sum_{i=1}^n (\mathbf{X}_i - \bar{\mathbf{X}})(\mathbf{X}_i - \bar{\mathbf{X}})^\top = \frac{1}{n} S$$

írva

$$T_1^2 = n (\bar{\mathbf{X}} - \mathbf{m}_0)^\top S^{-1} (\bar{\mathbf{X}} - \mathbf{m}_0) \quad (7)$$

próbataszitkát kapjuk. Az 1.22. Tétel szerint  $S$  és  $\bar{\mathbf{X}}$  függetlenek, és ezért  $H_0$  fennállása esetén az 1.23. Tétel szerint  $(n - k)/k \cdot T_1^2 \sim \mathcal{F}(k, n - k)$ . Ez az egymintás t-próba többdimenziós változata.

**Kétmintás eset.** Legyenek  $\mathbf{X}_1, \dots, \mathbf{X}_n$  független  $\mathcal{N}_k(\mathbf{m}, \Sigma)$  eloszlású vektorok és  $\mathbf{Y}_1, \dots, \mathbf{Y}_m$  az  $\mathbf{X}$ -ektől független  $\mathcal{N}_k(\mathbf{m}', \Sigma)$  eloszlású vektorok, ahol a  $\Sigma$  pozitív definit kovarianciamátrix (közös!) ismeretlen. A következő hipotézist vizsgáljuk:

$$H_0 : \mathbf{m} = \mathbf{m}' \quad H_A : \mathbf{m} \neq \mathbf{m}'.$$

Legyen

$$S = \sum_{i=1}^n (\mathbf{X}_i - \bar{\mathbf{X}})(\mathbf{X}_i - \bar{\mathbf{X}})^\top + \sum_{i=1}^m (\mathbf{Y}_i - \bar{\mathbf{Y}})(\mathbf{Y}_i - \bar{\mathbf{Y}})^\top.$$

Ekkor  $S$  és  $(\bar{\mathbf{X}} - \bar{\mathbf{Y}})$  függetlenek, így az egymintás esethez hasonlóan  $H_0$  fennállása esetén

$$T_2^2 = \frac{nm}{n + m} (\bar{\mathbf{X}}_n - \bar{\mathbf{Y}}_m)^\top S^{-1} (\bar{\mathbf{X}}_n - \bar{\mathbf{Y}}_m)$$

statisztikára, az 1.23. Tétel szerint

$$\frac{n + m - k - 1}{k} T_2^2 \sim \mathcal{F}(k, n + m - k - 1).$$

## 1.6. Többdimenziós CHT

Egydimenziós esetben is láttuk, hogy a normális eloszlás azért különösen fontos, mert független véletlen változók összegének a normált és centrált határeloszlása. Ez a centrális határeloszlás-tétel, speciális esetben a de Moivre-Laplace tétel. Ennek a többváltozós megfelelője is igaz. Először az eloszlásbeli konvergencia fogalmát vezetjük be.

**1.26. Definíció.** Az  $\mathbf{X}_n \in \mathbb{R}^k$  véletlen vektorváltozók *eloszlásban konvergálnak*  $\mathbf{X} \in \mathbb{R}^k$  véletlen vektorhoz, ha tetszőleges olyan  $\mathbf{x} = (x_1, \dots, x_k) \in \mathbb{R}^k$  pontra, ami folytonossági pontja az

$$F(\mathbf{x}) = F(x_1, \dots, x_k) = \mathbf{P}(\mathbf{X} \leq \mathbf{x}) = \mathbf{P}(X_1 \leq x_1, \dots, X_k \leq x_k)$$

eloszlásfüggvénynek, teljesül, hogy

$$\lim_{n \rightarrow \infty} \mathbf{P}(\mathbf{X}_n \leq \mathbf{x}) = F(\mathbf{x}).$$

Mivel a többdimenziós normális eloszlásfüggvénye folytonos, ezért a konvergencia minden pontban teljesül. Ezek után kimondjuk a többdimenziós CHT-t.

**1.27. Tétel.** *CHT független, azonos eloszlású véletlen vektorokra Legyenek  $\mathbf{X}_1, \mathbf{X}_2, \dots$  független azonos eloszlású véletlen vektorok  $\mathbb{R}^k$ -ban véges  $\Sigma$  kovarianciamátrixszal és  $\mathbf{m}$  várható érték vektorral. Ekkor az  $\mathbf{S}_n = \sum_{j=1}^n \mathbf{X}_j$ ,  $n \in \mathbb{N}$ , részletösszegekre*

$$\frac{1}{\sqrt{n}} (\mathbf{S}_n - n\mathbf{m}) \xrightarrow{\mathcal{D}} \mathbf{Y}, \quad \text{amint } n \rightarrow \infty, \quad \text{ahol } \mathbf{Y} \sim \mathcal{N}_k(0, \Sigma).$$

Emiatt a tétel miatt a többdimenziós normálisra kapott próbák érvényesek tetszőleges olyan véletlen vektorra, melynek létezik kovarianciamátrixa. Ekkor persze csak nagy mintaelemszám esetén ( $n \rightarrow \infty$ ) érvényes a kapott eredmény.

## 2. Lineáris módszerek

### 2.1. Főkomponensanalízis

Legyen  $\mathbf{X} \sim \mathcal{N}_k(\mathbf{m}, \Sigma)$ . Keressük  $\mathbf{X}$  előállítását

$$\mathbf{X} = V\mathbf{Y} + \mathbf{m}$$

alakban, ahol  $V \in \mathbb{R}^{k \times k}$  ortogonális mátrix,  $\mathbf{Y} \in \mathbb{R}^k$  független komponensekből álló  $k$ -dimenziós normális eloszlású véletlen vektor, 0 várható érték vektorral. Feltesszük továbbá, hogy  $\mathbf{Y}$  komponenseinek a szórásnégyzete csökkenő. Mivel  $V$  ortogonális, így  $\mathbf{Y} = V^\top(\mathbf{X} - \mathbf{m})$ , és

$$\mathbf{E}\mathbf{Y}\mathbf{Y}^\top = V^\top U \Lambda U^\top V,$$

ahol a  $\Sigma = U \Lambda U^\top$  spektrálfelbontást használtuk. Mivel  $\mathbf{E}\mathbf{Y}\mathbf{Y}^\top$  diagonális, így  $V = U$ , és a  $\mathbf{Y} = U^\top(\mathbf{X} - \mathbf{m})$  előállítást kapjuk. Az  $\mathbf{Y}$  vektor komponenseit  $\mathbf{X}$  főkomponenseinek nevezzük. Vegyük észre, hogy  $\mathbf{Y}$  komponensei  $\mathbf{X} - \mathbf{m}$  komponenseinek lineáris kombinációja; pontosabban, az  $\mathbf{Y} = (Y_1, \dots, Y_k)^\top$  jelöléssel

$$Y_i = \langle \mathbf{u}_i, \mathbf{X} - \mathbf{m} \rangle, \quad i = 1, \dots, k,$$

ahol  $\mathbf{u}_1, \dots, \mathbf{u}_k$  a  $\Sigma$  sajátvektorai.

A főkomponensfelbontás az alábbi optimalitási tulajdonság miatt fontos.

**2.1. Tétel.** *Az  $Y_1$  szórásnégyzete maximális az  $\langle \mathbf{v}, \mathbf{X} - \mathbf{m} \rangle$  változók szórásnégyzetei között, ahol  $|\mathbf{v}| = 1$ , továbbá a maximum a  $\mathbf{v} = \mathbf{u}_1$  sajátvektoron vétetik fel, értéke  $\lambda_1$ . Az  $Y_2$  szórásnégyzete maximális az  $Y_1$ -től független  $\langle \mathbf{v}, \mathbf{X} - \mathbf{m} \rangle$  változók szórásnégyzetei között, ahol  $|\mathbf{v}| = 1$ , továbbá a maximum a  $\mathbf{v} = \mathbf{u}_2$  sajátvektoron vétetik fel, értéke  $\lambda_2$ . Általánosan,  $Y_\ell$ ,  $\ell \in \{2, \dots, k\}$ , szórásnégyzete maximális az  $Y_1, \dots, Y_{\ell-1}$  változóktól független  $\langle \mathbf{v}, \mathbf{X} - \mathbf{m} \rangle$  változók szórásnégyzetei között, ahol  $|\mathbf{v}| = 1$ , továbbá a maximum a  $\mathbf{v} = \mathbf{u}_\ell$  sajátvektoron vétetik fel, értéke  $\lambda_\ell$ .*

A bizonyítás a sajátvektorok következő maximumtulajdonságán múlik.

**2.2. Tétel.** *Legyen  $A \in \mathbb{R}^{k \times k}$  szimmetrikus mátrix, és legyenek  $\lambda_1 \geq \lambda_2 \geq \dots \geq \lambda_k$  az  $A$  sajátértékei,  $\mathbf{u}_1, \dots, \mathbf{u}_k$  pedig a hozzájuk tartozó sajátvektorok. Ekkor*

$$\max_{|\mathbf{v}|=1} \mathbf{v}^\top A \mathbf{v} = \lambda_1,$$

*és a maximum a  $\mathbf{u}_1$  vektoron vétetik fel. Továbbá, tetszőleges  $\ell \in \{2, \dots, k\}$  esetén*

$$\max \{ \mathbf{v}^\top A \mathbf{v} : |\mathbf{v}| = 1, \mathbf{v} \perp \text{span}\{\mathbf{u}_1, \dots, \mathbf{u}_{\ell-1}\} \} = \lambda_\ell,$$

*és a maximum a  $\mathbf{u}_\ell$  sajátvektoron vétetik fel.*

*Bizonyítás.* Az egyszerűség kedvéért tegyük fel, hogy  $\lambda_1 > \lambda_2 > \dots > \lambda_k$ , azaz minden sajátérték multiplicitása egy. A bizonyításból világos, hogy különben az egyértelműség nem igaz.

Tekintsük az  $A = U \Lambda U^\top$  spektrálfelbontást. Legyen  $\mathbf{v} \in \mathbb{R}^k$  tetszőleges, és tekintsük az  $\mathbf{u}_1, \dots, \mathbf{u}_k$  bázisban való kifejtését:

$$\mathbf{v} = \sum_{i=1}^k \alpha_i \mathbf{u}_i.$$

Ekkor, ha  $|\mathbf{v}|^2 = \sum_{i=1}^k \alpha_i^2 = 1$ , akkor

$$\mathbf{v}^\top A \mathbf{v} = \sum_{i=1}^k \lambda_i \alpha_i^2 \leq \lambda_1,$$

és egyenlőség pontosan akkor van, ha  $\mathbf{v} = \mathbf{u}_1$ . Ez persze csak akkor igaz, ha  $\lambda_1 > \lambda_2$ . Ha vannak egyenlő sajátértékek, akkor nincs teljes egyértelműség, a megfelelő sajátaltérben a bázis tetszőlegesen választható.



A  $\mathbf{v}$  pontosan akkor merőleges az  $\mathbf{u}_1, \dots, \mathbf{u}_{\ell-1}$  vektorok által feszített altérre, ha  $\alpha_1 = \dots = \alpha_{\ell-1} = 0$ . Ekkor, ha  $|\mathbf{v}| = 1$ ,

$$\mathbf{v}^\top A \mathbf{v} = \sum_{i=\ell}^k \lambda_i \alpha_i^2 \leq \lambda_\ell,$$

és egyenlőség pontosan akkor van, ha  $\mathbf{v} = \mathbf{u}_\ell$ . Ezzel a tételt igazoltuk.  $\square$

*A 2.1. Tétel bizonyítása.* Tetszőleges  $\mathbf{v} \in \mathbb{R}^k$  esetén

$$\mathbf{E}(\langle \mathbf{v}, \mathbf{X} - \mathbf{m} \rangle^2) = \mathbf{v}^\top \Sigma \mathbf{v}.$$

Tehát a feladat a 2.2. Tételben tárgyalt maximumfeladatra egyszerűsödött. Azt kell még észrevenni, hogy az együttes normalitás miatt  $\langle \mathbf{v}, \mathbf{X} - \mathbf{m} \rangle$  pontosan akkor független a  $\langle \mathbf{u}_1, \mathbf{X} - \mathbf{m} \rangle, \dots, \langle \mathbf{u}_{\ell-1}, \mathbf{X} - \mathbf{m} \rangle$  változóktól, ha

$$0 = \mathbf{E}(\langle \mathbf{u}_i, \mathbf{X} - \mathbf{m} \rangle \langle \mathbf{v}, \mathbf{X} - \mathbf{m} \rangle) = \lambda_i \langle \mathbf{v}, \mathbf{u}_i \rangle.$$

Azaz a függetlenségi megkötés éppen a 2.2. Tételben szereplő merőlegességi feltételt jelenti. Tehát minden következik a 2.2. Tételből.  $\square$

## 2.2. Merőleges vetítés

**2.3. Definíció.** Legyen  $\mathcal{H}$  egy lineáris vektortér a valós számtest felett. Ekkor  $\langle \cdot, \cdot \rangle : \mathcal{H} \times \mathcal{H} \rightarrow \mathbb{R}$  *belső szorzat*, ha tetszőleges  $x, y, z \in \mathcal{H}$ ,  $\alpha \in \mathbb{R}$  esetén

- (i)  $\langle x, y \rangle = \langle y, x \rangle$ ;
- (ii)  $\langle x + y, z \rangle = \langle x, z \rangle + \langle y, z \rangle$ ;
- (iii)  $\langle \alpha x, y \rangle = \alpha \langle x, y \rangle$ ;
- (iv)  $\langle x, x \rangle \geq 0$ , és pontosan akkor 0, ha  $x = 0$ .

**2.4. Feladat.** Legyen  $\mathcal{H} = \mathbb{R}^k$ ,  $k \geq 1$ . Igazoljuk, hogy  $\langle x, y \rangle = \sum_{i=1}^k x_i y_i$  *belső szorzat!*

Ekkor  $(\mathcal{H}, \langle \cdot, \cdot \rangle)$ , vagy egyszerűen csak  $\mathcal{H}$  *belső szorzattér*. Belső szorzattéren használjuk az euklideszi terekben megszokott terminológiát. Egy  $x \in \mathcal{H}$  vektor *normája*  $\|x\| = \sqrt{\langle x, x \rangle}$ . Az  $x$  *merőleges*  $y$ -ra, ha  $\langle x, y \rangle = 0$ .

**2.5. Állítás.** *Norma tulajdonságai.*

- (i) Teljesül a háromszög-egyenlőtlenség:  $\|x + y\| \leq \|x\| + \|y\|$ ;
- (ii)  $\|\alpha x\| = |\alpha| \|x\|$ ;
- (iii)  $\|x\| \geq 0$  és pontosan akkor 0, ha  $x = 0$ ;
- (iv) Cauchy–Bunyakovszkij–Schwarz egyenlőtlenség:  $\|\langle x, y \rangle\| \leq \|x\| \|y\|$ ;
- (v) Paralelogramma azonosság:  $\|x + y\|^2 + \|x - y\|^2 = 2\|x\|^2 + 2\|y\|^2$ .

Az első három tulajdonság a norma definiáló tulajdonsága.

**2.6. Feladat.** Bizonyítsuk be a fenti állítást!

A normából származik távolság, ami definiál egy konvergenciát. Akkor mondjuk, hogy  $x_n \rightarrow x$  amint  $n \rightarrow \infty$  ha  $\|x_n - x\| \rightarrow 0$ . Ekkor pedig van folytonosság.

**2.7. Állítás.** A norma és a belső szorzat folytonosak. Azaz, ha  $x_n \rightarrow x$  akkor  $\|x_n\| \rightarrow \|x\|$ , és ha  $x_n \rightarrow x$  és  $y_n \rightarrow y$  akkor  $\langle x_n, y_n \rangle \rightarrow \langle x, y \rangle$ .

**2.8. Feladat.** Bizonyítsuk be a fenti állítást!

**2.9. Definíció.** Az  $(x_n)$  sorozat *Cauchy-sorozat*, ha minden  $\varepsilon > 0$  esetén megadható  $n_0$ , hogy bármely  $m, n \geq n_0$  esetén  $\|x_n - x_m\| \leq \varepsilon$ . Akkor mondjuk, hogy a  $\mathcal{H}$  belső szorzattér *Hilbert-tér*, ha benne minden Cauchy-sorozat konvergens.

Analízisből tudjuk, hogy  $\mathbb{R}^n$  Hilbert-tér.

**2.10. Példa.** Számunkra a legfontosabb Hilbert-tér a négyzetintegrálható véletlen változók tere. Legyen  $(\Omega, \mathcal{A}, \mathbf{P})$  egy valószínűségi mező. Legyen  $L^2 = \{X : \Omega \rightarrow \mathbb{R}; \mathbf{E}X^2 < \infty\}$ , azaz a véges második momentummal rendelkező véletlen változók. Ekkor  $L^2$  lineáris vektortér. Ezt láttuk valószínűség-számításból, hiszen csak annyi kell, hogy  $X, Y \in L^2$  akkor  $X + Y \in L^2$ . Ez a Cauchy–Schwarz egyenlőtlenségből következik. Azt is könnyű látni, hogy  $\langle X, Y \rangle = \mathbf{E}(XY)$  belső szorzat.

Az már lényegesen bonyolultabb, hogy  $L^2$  Hilbert-tér. Ez majd mérték-elméletből lesz.

**2.11. Feladat.** Tekintsük az előző példában látott  $L^2$  teret. Legyenek  $X, X_1, X_2, \dots$  független standard normálisok, és legyen  $(a_n)$  determinisztikus sorozat. Igazoljuk, hogy  $S_n = \sum_{i=1}^n a_i X_i$  pontosan akkor Cauchy-sorozat, ha  $\sum_{i=1}^{\infty} a_i^2 < \infty$ .

**2.12. Definíció.** Az  $\mathcal{M} \subset \mathcal{H}$  lineáris altér *zárt*, ha minden torlódási pontját tartalmazza. Az  $\mathcal{M}$  *ortogonális komplementere*

$$\mathcal{M}^\perp = \{x : x \in \mathcal{H}, \forall y \in \mathcal{M}, \langle x, y \rangle = 0\}.$$

Ez az  $\mathcal{M}$ -re merőleges altér. A belső szorzat folytonosságából azonnal adódik, hogy  $\mathcal{M}^\perp$  mindig zárt.

**2.13. Példa.** Nem minden lineáris altér zárt. Legyen  $\mathcal{H}$  a  $[0, 1]$ -en folytonos függvények tere. Ez Hilbert-tér a  $\langle f, g \rangle = \int_0^1 f(x)g(x)dx$  belső szorzattal. Ekkor a polinomok (szokásos véges fokszámú valós együtthatós) altere nem zárt. Hát persze, a Weierstrass-féle approximációs tétel szerint minden folytonos függvény közelíthető polinomokkal, azaz a polinomok alterének torlódási pontjai éppen a folytonos függvények halmaza, azaz az egész tér.

A következő tételt nem bizonyítjuk, viszont sokszor használjuk. A lényeg, hogy három dimenzióban értsük, hogy mi történik.

**2.14. Tétel.** *Merőleges vetítés.* Legyen  $\mathcal{M} \subset \mathcal{H}$  zárt altér, és legyen  $x \in \mathcal{H}$ . Ekkor létezik egy egyértelmű  $\hat{x} \in \mathcal{M}$ , hogy  $\|x - \hat{x}\| = \inf_{y \in \mathcal{M}} \|x - y\|$ . Továbbá

$$\left( \hat{x} \in \mathcal{M}, \|x - \hat{x}\| = \inf_{y \in \mathcal{M}} \|x - y\| \right) \Leftrightarrow \left( \hat{x} \in \mathcal{M}, x - \hat{x} \in \mathcal{M}^\perp \right).$$

A második állítás mondja meg, hogy hogyan kell választani az  $\hat{x}$  vektort: a különbség vektor merőleges az alterre.

Tetszőleges  $\mathcal{M}$  zárt altér esetén legyen  $P_{\mathcal{M}} : \mathcal{H} \rightarrow \mathcal{M}; x \mapsto \hat{x}$ , az  $\mathcal{M}$  alterre való merőleges vetítés. A merőleges vetítés néhány fontos tulajdonságait tartalmazza az alábbi állítás.

**2.15. Állítás.** *Legyen  $\mathcal{M}$  zárt altér, és  $P = P_{\mathcal{M}}$ . Ekkor*

- (i)  $P(\alpha x + \beta y) = \alpha P(x) + \beta P(y)$ ;
- (ii) *Pitagorasz-tétel:*  $\|x\|^2 = \|Px\|^2 + \|(I - P)x\|^2$ ;
- (iii)  $\exists! u \in \mathcal{M}, v \in \mathcal{M}^\perp, x = u + v$ , és  $u = Px, v = (I - P)x$ ;
- (iv)  $Px_n \rightarrow Px$  valahányszor  $x_n \rightarrow x$ ;
- (v)  $Px = x$  pontosan akkor, ha  $x \in \mathcal{M}$ ;
- (vi)  $Px = 0$  pontosan akkor, ha  $x \in \mathcal{M}^\perp$ .

### 2.3. Lineáris regresszió véletlen regresszorral

Legyenek  $Y, X_1, X_2, \dots, X_k, k \geq 1$ , véletlen változók. Keressük az  $Y$  független változó legjobb lineáris közelítését az  $\mathbf{X} = (X_1, \dots, X_k)^\top$  függő változókkal. Pontosabban keressük az  $a_1, \dots, a_k, b$  valós számokat, melyekre a

$$\mathbf{E} \left( \left( Y - \sum_{i=1}^k a_i X_i - b \right)^2 \right)$$

minimális. Mivel  $\mathbf{E}(Z - b)^2$  minimuma a  $b = \mathbf{E}Z$  helyen van, ezért  $b = \mathbf{E}Y - \sum_i a_i \mathbf{E}X_i$ . Vagyis az általánosság megszorítása nélkül feltehetjük, és fel is tesszük, hogy  $\mathbf{E}Y = \mathbf{E}X_i = 0$  minden  $i$ -re.

Tekintsük az  $L^2$  teret a szokásos  $\mathbf{E}(UV)$  belső szorzattal, és legyen

$$\mathcal{M} = \left\{ \sum_{i=1}^k \alpha_i X_i : \alpha_i \in \mathbb{R} \right\} = \text{span}(X_1, \dots, X_k).$$

Ekkor  $\mathcal{M}$  zárt, hiszen véges dimenziós altér. A merőleges vetítés tétele szerint a legjobban közelítő vektor  $PY$ , az  $Y$  merőleges vetítése az  $\mathcal{M}$  altérre. Tehát a feladatunk a  $PY$  meghatározása. A merőleges vetítés tétele szerint  $Y - PY \perp \mathcal{M}$ , ami azt jelenti, hogy

$$\mathbf{E}(Y - PY)X_j = 0, \quad \text{minden } j = 1, 2, \dots, k \text{ esetén.}$$

Mivel  $PY = \sum_{i=1}^k a_i X_i$  valamilyen  $\mathbf{a}^\top = (a_1, \dots, a_k)$  vektorra, ezért azt kapjuk, hogy

$$0 = \mathbf{E} \left[ \left( Y - \sum_{i=1}^k a_i X_i \right) X_j \right] = \text{Cov}(Y, X_j) - \mathbf{a}^\top \Sigma, \quad j = 1, 2, \dots, k,$$

ahol  $\Sigma = \text{Cov}(\mathbf{X})$  az  $\mathbf{X} = (X_1, \dots, X_k)^\top$  kovarianciamátrix.

A  $\mathbf{d} = (\text{Cov}(Y, X_i))_{i=1}^k \in \mathbb{R}^k$  jelöléssel azt kapjuk, hogy  $\mathbf{d} = \Sigma \mathbf{a}$ , azaz, amennyiben  $\Sigma$  nonszinguláris,

$$\mathbf{a} = \Sigma^{-1} \mathbf{d}.$$

Ezzel beláttuk a következőt.

**2.16. Tétel.** *Legkisebb négyzetek módszere.* Az  $\mathbf{E} \left( \left( Y - \sum_{i=1}^k a_i X_i - b \right)^2 \right)$  négyzetes hiba pontosan akkor minimális, ha  $\mathbf{a} = \Sigma^{-1} \mathbf{d}$  és  $b = \mathbf{E}Y - \mathbf{a}^\top \mathbf{E}\mathbf{X}$ .

A vetítés miatt a közelítés hibája, az  $\ell(\mathbf{X}) = \sum_i a_i X_i + b$  jelöléssel

$$\varepsilon = Y - \left( \sum_{i=1}^k a_i X_i + b \right) = Y - \ell(\mathbf{X}),$$

merőleges az  $X_1, \dots, X_k$  változókra, azaz  $\mathbf{Cov}(\varepsilon, X_i) = 0, i = 1, \dots, k$ . Vagyis az  $Y = \ell(\mathbf{X}) + \varepsilon$  előállításban a tagok korrelálatlanok, és így

$$\mathbf{D}^2(Y) = \mathbf{D}^2(\ell(\mathbf{X})) + \mathbf{D}^2(\varepsilon).$$

Ebből következik, hogy

$$\mathbf{Cov}(\ell(\mathbf{X}), Y) = \mathbf{D}^2(\ell(\mathbf{X})).$$

**2.17. Definíció.** A  $Y$  független és az  $\mathbf{X}^\top = (X_1, \dots, X_k)$  függő változók többszörös korrelációs együtthatója

$$r_{Y(X_1, \dots, X_k)} = \rho(Y, \ell(\mathbf{X})) = \frac{\mathbf{Cov}(Y, \ell(\mathbf{X}))}{\sqrt{\mathbf{D}(Y)\mathbf{D}(\ell(\mathbf{X}))}}.$$

A  $k = 1$  esetben ez éppen a két változó hagyományos korrelációja.

Némi számolással adódik, hogy

$$\mathbf{D}^2(\varepsilon) = \mathbf{D}^2(Y) (1 - r^2).$$

Ez megmagyarázza az  $r$  jelentését. Ha  $r = 1$ , akkor  $\varepsilon \equiv 0$ , azaz lineáris függvénykapcsolat van  $Y$  és  $\mathbf{X}$  között. Ha pedig  $r = 0$ , akkor az  $\mathbf{X}$  semmit nem magyaráz meg az  $Y$ -ből, a két változó között nincs kapcsolat. Ekkor  $\mathbf{a} = (0, \dots, 0)$ .

A következő állítás szerint a legkisebb négyzetes közelítés maximalizálja a korrelációt.

**2.18. Állítás.** Az  $X_1, \dots, X_k$  változók tetszőleges  $h(\mathbf{X})$  lineáris kombinációjára

$$|r_{Y(X_1, \dots, X_k)}| = \rho(Y, \ell(\mathbf{X})) \geq |\rho(Y, h(\mathbf{X}))|.$$

## 2.4. Determinisztikus változók

Vetítés. Gauss-féle normálegyenlet. Gauss–Markov tétel. Hipotézisvizsgálat.

## 2.5. Varianciaanalízis

Egyszempontos. Vetítés explicit formában. Kétszempontos, interakció. Hipotézisvizsgálat.

## Hivatkozások

- [1] Bolla Marianna, Krámli András: Statisztikai következtetések elmélete. Typotex, 2005.
- [2] Csörgő Sándor: Fejezetek a valószínűségelméletből. Polygon, 2010.
- [3] Richard A. Johnson, Dean W. Wichern: Applied Multivariate Statistical Analysis. Prentice-Hall, 1988.