

4. előadás - Többváltozós statisztikai alapok

Sztochasztikus rendszerek matematikája

2016. szeptember 26.

Alapfogalmak: minta és adatmátrix

- Legyen $\underline{x} = (x_1, \dots, x_p)^\top$ p -dimenziós valószínűségi vektorváltozó, azaz olyan véletlen vektor, melynek minden koordináta-változója egy-egy 1-dimenziós valószínűségi változó. Tegyük fel, hogy adott n darab $\underline{x}^1, \dots, \underline{x}^n \in \mathbb{R}^p$ független realizáció. Ez a p -dimenziós n elemű i.i.d. minta.
- Azt a $p \times n$ dimenziós mátrixot, melynek oszlopai a mintaelemek, **adatmátrixnak** nevezzük. A pontos jelölés:

$$X = \begin{pmatrix} x_1^1 & x_1^2 & \dots & x_1^n \\ x_2^1 & x_2^2 & \dots & x_2^n \\ \vdots & \vdots & & \vdots \\ x_p^1 & x_p^2 & \dots & x_p^n \end{pmatrix}$$

Alapfogalmak: várható érték vektor

- Tegyük fel, hogy az \underline{X} p -dimenziós valószínűségi vektorváltozó minden komponensének létezik a várható értéke. Ekkor

$$\underline{\mu} = (\mu_1, \dots, \mu_p)^\top = E\underline{X} = (EX_1, \dots, EX_p)^\top$$

a v.v.v. **várható érték vektora**.

- n -elemű statisztikai minta esetén $\underline{\mu}$ mintából való becslése az **átlagvektor**, mely a komponensek átlagainak vektora. Azaz

$$\overline{\underline{X}} = \frac{1}{n} \sum_{i=1}^n \underline{X}_i$$

A becslés torzítatlan és erősen konzisztens.

Alapfogalmak: kovariancia mátrix

- Legyen az \underline{X} p -dimenziós valószínűségi vektorváltozó olyan, mely minden komponensének létezik a második momentuma. A Cauchy-Schwarz egyenlőtlenség alapján ekkor bármely két komponense szorzatának is létezik a várható értéke, így a kovarianciájuk is. Az ezen értékekből felépített mátrix lesz \underline{X} **kovariancia-mátrixa**, azaz

$$\Sigma = (\sigma_{ij})_{i,j=1}^p = E[(\underline{X} - E\underline{X})(\underline{X} - E\underline{X})^\top] = (\text{cov}(X_i, X_j))_{i,j=1}^p$$

- Σ n -elemű mintából való becslése a **tapasztalati kovariancia-mátrix**:

$$S_n = \frac{1}{n} \sum_{i=1}^n (\underline{X}_i - \bar{\underline{X}})(\underline{X}_i - \bar{\underline{X}})^\top$$

A korrigált változat:

$$S_n^* = \frac{n}{n-1} S_n$$

Alapfogalmak: szimmetria és definitység

Mind S_n , mind S_n^* szimmetrikus és pozitív szemidefinit, azaz

- $S_n^T = S_n$ és $S_n^{*T} = S_n^*$
- bármely $\underline{a} \in \mathbb{R}^p$ esetén $\underline{a}^T S_n \underline{a} = \sum_{i=1}^p \sum_{j=1}^p a_i a_j (S_n)_{i,j} \geq 0$ (S_n^* -ra hasonlóan)

Ebből következik, hogy létezik ún. **spektrálfelbontásuk**, azaz

$$S_n = V \Lambda V^T = \sum_{i=1}^p \lambda_i v_i v_i^T$$

ahol $\Lambda = \text{diag}(\lambda_1, \dots, \lambda_p)$ a sajátértékek diagonális mátrixa, $V = (v_1, \dots, v_p)$ a normált sajátvektorok alkotta ortogonális mátrix (azaz $VV^T = V^T V = I$). A sajátértékek a szimmetria miatt valósak, a pozitív szemidefinittség miatt pedig nemnegatívak. Ugyanez igaz S_n^* esetén is.

Többdimenziós standard normális eloszlás

Definíció

Legyenek ξ_1, \dots, ξ_p független $N(0, 1)$ eloszlású valószínűségi változók. Ekkor a $\xi = (\xi_1, \dots, \xi_p)^\top$ valószínűségi vektorváltozót **p -dimenziós standard normális eloszlású v.v.v.-nak** nevezzük. Jelölés:

$$\xi \sim \mathcal{N}_p(\underline{0}, I_{p \times p}).$$

- $E\xi = \underline{0}$, hiszen $E\xi_i = 0$ minden $i = 1, \dots, p$ esetén.
- $\Sigma_\xi = I_{p \times p}$, hiszen $D^2(\xi_i) = 1$ minden $i = 1, \dots, p$ esetén és $\text{cov}(\xi_i, \xi_j) = 0$ minden $i \neq j$ esetén.
- Sűrűségfüggvény:

$$f_\xi(\underline{x}) = \frac{1}{(\sqrt{2\pi})^p} \exp \left\{ -\frac{1}{2} \underline{x}^\top \underline{x} \right\}$$

ahol $\underline{x} = (x_1, \dots, x_p)^\top \in \mathbb{R}^p$.

Többdimenziós normális eloszlás

Definíció

Legyenek $\underline{m} \in \mathbb{R}^p$, $A \in \mathbb{R}^{p \times p}$ és $\xi \sim \mathcal{N}_p(\underline{0}, I_{p \times p})$. Ekkor az $\eta = A\xi + m$ valószínűségi vektorváltozót **p -dimenziós normális eloszlású** v.v.v.-nak nevezzük. Jelölés: $\eta \sim \mathcal{N}_p(\underline{m}, \Sigma_\eta)$.

- $E\eta = \underline{m}$.
- $\Sigma_\eta = AA^\top$ szimmetrikus pozitív szemidefinit mátrix.
- Ha Σ_η invertálható, akkor létezik sűrűségfüggvény:

$$f_\eta(\underline{y}) = \frac{1}{(\sqrt{2\pi})^p \cdot (\det \Sigma_\eta)^{1/2}} \exp \left\{ -\frac{1}{2} (\underline{y} - \underline{m})^\top \Sigma_\eta^{-1} (\underline{y} - \underline{m}) \right\}$$

ahol $\underline{y} = (y_1, \dots, y_p)^\top \in \mathbb{R}^p$.

Fordított irány

A dolog visszafelé is működik, azaz ha $\eta \sim \mathcal{N}_p(\underline{m}, \Sigma_\eta)$ adott és Σ_η invertálható, akkor vegyük a

$$\Sigma_\eta = AA^\top$$

felbontást. Ez létezik, hiszen a spektrálfelbontásból $A = V\Lambda^{1/2}$ például jó választás lenne. A baj az, hogy ez még nem lesz egyértelmű felírás.


Viszont, mivel Σ_η szimmetrikus és pozitív definit (hiszen feltettük, hogy invertálható), így az $A = V\Lambda^{1/2}V^\top$ felírás már egyértelmű. Ezt szokás $\Sigma_\eta^{1/2}$ jelöléssel is használni. Ekkor könnyen látszik, hogy a

$$\xi = A^{-1}(\eta - \underline{m})$$

lineáris transzformáció **standard normális eloszlású** valószínűségi vektorváltozót eredményez.


Szemléltetés: 2-dimenzió

A kétdimenziós standard normális eloszlás sűrűségfüggvényének képe egy harang alakú felület, mely tulajdonképpen a haranggörbe saját tengelye körüli megforgatottja. A szintvonalak körök lesznek. (Azaz függetlenek a komponensek és azonos szórásúak.)




Szemléltetés: 2-dimenzió

Nem standard esetben ennek eltorzítottját kapjuk, melynek szintvonalai ekkor ellipszisek lesznek, \underline{m} középponttal és $\sqrt{\lambda_1}, \sqrt{\lambda_2}$ hosszúsággal arányos, $\underline{v}_1, \underline{v}_2$ irányú tengelyekkel. Ezek az ún. koncentráció ellipszisek, melyek azt mutatják meg, hogy belülről kifelé haladva egyre kisebb valószínűséggel esnek a pontok az ellipszisekbe.



Szemléltetés: 3-dimenzió

Ebben az esetben a felületet már nem tudjuk felrajzolni, csak a szintvonalakat: azon pontok, melyeken a sűrűségfüggvény azonos értéket vesz fel, egy-egy ellipszoidon helyezkednek el. Ezek a koncentráció ellipszoidok, \underline{m} középponttal és $\sqrt{\lambda_1}, \sqrt{\lambda_2}, \sqrt{\lambda_3}$ hosszúsággal arányos, $\underline{v}_1, \underline{v}_2, \underline{v}_3$ irányú tengelyekkel. Olyan, mint egy héjszerkezet, középen a leg­sűrűbb az anyag, kifelé pedig folyamatosan ritkul.



Paraméterbecslés: ML-módszer

Legyen $\underline{X}_1, \dots, \underline{X}_n$ független minta az $\underline{X} \in \mathcal{N}_p(\underline{m}, C)$ vektorra, és tegyük fel, hogy $n \geq p$.

Feladat: a paraméterek, azaz \underline{m} és C becslése, feltéve, hogy C pozitív definit.

Eszköz: maximum-likelihood (ML) becslés

Likelihood függvény:

$$\begin{aligned}
 L_{\underline{m}, C}(\underline{X}_1, \dots, \underline{X}_n) &= \\
 &= \prod_{k=1}^n \frac{1}{(\sqrt{2\pi})^p \cdot (\det C)^{1/2}} \exp \left\{ -\frac{1}{2} (\underline{X}_k - \underline{m})^\top C^{-1} (\underline{X}_k - \underline{m}) \right\} = \\
 &= \frac{1}{(2\pi)^{\frac{np}{2}} (\det C)^{\frac{n}{2}}} \cdot \exp \left\{ -\frac{1}{2} \sum_{k=1}^n (\underline{X}_k - \underline{m})^\top C^{-1} (\underline{X}_k - \underline{m}) \right\}
 \end{aligned}$$

Az ML-becslés tulajdonságai

- A várható érték becslése torzítatlan, míg a kovariancia-mátrix becslése aszimptotikusan torzítatlan, a korrigált változat persze torzítatlan lesz.
- A becsléseink konzisztensek és hatásosak.
- Alsó korlát adható az

$$I_n(\theta_0) = \frac{1}{n} E_{\theta} \left[\left(\frac{\partial}{\partial \theta} \ln L_{\theta_0}(\underline{X}) \right) \left(\frac{\partial}{\partial \theta} \ln L_{\theta_0}(\underline{X}) \right)^{\top} \right]$$

Fisher-információs mátrix segítségével, a

$$D_{\theta}^2(T) \geq I_n(\theta_0)^{-1}, \quad \theta \in \Theta$$

Cramér-Rao egyenlőtlenség alapján, ahol θ_0 és θ az igazi és a futó paramétervektorokat jelölik.

Főkomponens-analízis

Azt vizsgáljuk, hogyan lehet nagy dimenziós megfigyelésekből kisebb dimenziókat készíteni úgy, hogy ne veszítsünk sok információt. Mivel Σ szimmetrikus és pozitív definit,

$$\Gamma^T \Sigma \Gamma = \Lambda = \begin{pmatrix} \lambda_1 & & 0 \\ & \ddots & \\ 0 & & \lambda_p \end{pmatrix},$$

ahol $\lambda_1 \geq \lambda_2 \geq \dots \geq \lambda_p$ Σ sajátértékei. Legyen $\underline{\gamma}_{(i)}$ a Γ i -edik oszlopa.

Definíció

Az $\underline{Y} = \Gamma^T (\underline{X} - \underline{\mu})$ vektort főkomponensvektornak, $Y_{(i)} = \underline{\gamma}_{(i)}^T (\underline{X} - \underline{\mu})$ i -edik főkomponensnek nevezzük.

Tulajdonságok

- $EY_{(i)} = 0$
- $D^2Y_{(i)} = \lambda_i$
- $cov(Y_{(i)}, Y_{(j)}) = 0$, ha $i \neq j$
- $\sum_{i=1}^p D^2Y_{(i)} = tr(\Sigma)$
- $\prod_{i=1}^p D^2Y_{(i)} = |\Sigma|$

Állítás

$$D^2Y_{(1)} = \max_{\underline{a}^T \underline{a}=1} D^2(\underline{a}^T \underline{X}) = \max_{\underline{a}^T \underline{a}=1} \underline{a}^T \Sigma \underline{a}$$

$$D^2Y_{(k+1)} = \max_{\substack{\underline{a}^T \underline{a}=1, \\ cov(\underline{a}^T \underline{X}, Y_{(i)})=0 \quad (i=1, \dots, k)}} D^2(\underline{a}^T \underline{X})$$

Következmény

Tehát ha adott egy 100 dimenziós vektorunk, és csak 5 dimenziósat szeretnénk használni, abból az eredeti a legjobban akkor állítható vissza, ha ez az 5-dim magyarázóvektor az első 5 főkomponensből áll :

Tétel

Legyen $\sigma_i^2 = \min_{\alpha, \underline{\beta}} E \left(X_i - \alpha - \sum_{j=1}^k \beta_j \underline{b}_j^T \underline{X} \right)^2$. Ekkor a $\sum_{i=1}^p \sigma_i^2$ hibát minimalizáló k -dimenziós $(\underline{b}_1^T \underline{X}, \dots, \underline{b}_k^T \underline{X})^T$ vektor az első k főkomponensből áll.

Végrehajtás a gyakorlatban

- A $\frac{\lambda_1 + \dots + \lambda_k}{\lambda_1 + \dots + \lambda_p}$ hányadost variancia-hányadrésznek nevezzük, általában k -t úgy választjuk, hogy ez nagy legyen (szokásos értéke 0,9).
- A főkomponensanalízis nem skalárinvariáns, ezért szokás a kovarianciamátrix helyett a korrelációs mátrixszal elvégezni.
- Ha Σ sajátértékei különbözőek, akkor ML-becslésük S sajátértékeivel és sajátvektoraival (V oszlopaival ...)

Faktormodell

Definíció

X leírható a k -faktormodellel, ha

$$\underline{X} = A\underline{F} + \underline{W} + \underline{\mu},$$

ahol A egy $p \times k$ -as rögzített mátrix, F k -dim. v.v.v. és W p -dim v.v.v. 0 várható érték vektorral, a vektorok komponensei korrelálatlanok, F komponenseinek szórása 1, formálisan

$$E\underline{F} = \underline{0},$$

$$E\underline{F}\underline{F}^\top = I_k$$

$$E\underline{W} = \underline{0},$$

$$E\underline{W}\underline{W}^\top = D$$

$$E\underline{F}\underline{W}^\top = 0.$$

F a közös faktorok, W az egyedi faktorok.

Koordinátánként

$$X_i = \sum_{j=1}^k A_{ij} F_j + W_i + \mu_i.$$

Ekkor X_i varianciájára

$$\begin{aligned}\Sigma_{ii} &= \sigma_i^2 = \sum_{j=1}^k A_{ij}^2 + D_{ii}, \\ \Sigma &= AA^T + D.\end{aligned}$$

Tehát X_i varianciájából a $\sum_{j=1}^k A_{ij}^2$ részt magyarázzák a közös faktorok (kommunalitás), D_{ii} pedig az egyedi variancia.