

IME IN PRIIMEK: \_\_\_\_\_

VPISNA ŠT: 

--	--	--	--	--	--	--	--	--	--

FAKULTETA ZA MATEMATIKO IN FIZIKO

ODDELEK ZA MATEMATIKO

STATISTIKA

PISNI IZPIT

2. JULIJ 2020

NAVODILA

Pazljivo preberite besedilo naloge, preden se lotite reševanja.

Naloga	a.	b.	c.	d.	
1.					
2.				•	
3.			•	•	
4.			•	•	
Skupaj	•	•	•	•	

1. (25) Naj bo dvorazsežni slučajni vektor  $(X_0, Y_0) \sim N(0, \Sigma)$  neodvisen od dvorazsežnih slučajnih vektorjev  $\epsilon_1, \epsilon_2, \dots, \epsilon_n$ , ti pa naj bodo neodvisni med sabo in naj velja  $\epsilon_k \sim N(0, \Lambda)$ . Definirajte rekurzivno

$$\begin{pmatrix} X_{k+1} \\ Y_{k+1} \end{pmatrix} = \begin{pmatrix} 1 & 1 \\ 1 & 1 \end{pmatrix} \begin{pmatrix} X_k \\ Y_k \end{pmatrix} + \epsilon_{k+1}$$

za  $k = 1, 2, \dots, n - 1$ . Označite

$$\mathbf{Z}_k = \begin{pmatrix} X_k \\ Y_k \end{pmatrix}$$

za  $k = 0, 1, \dots, n$ . Kot znano privzemite, da za večrazsežen normalni vektor  $(X, Y, \mathbf{Z})^T$  velja

$$E(Y|X, \mathbf{Z}) = E(Y|\mathbf{Z}) + \text{cov}(X, Y|\mathbf{Z})\text{var}(X|\mathbf{Z})^{-1}(X - E(X|\mathbf{Z})) .$$

a. (5) Izračunajte  $E(Y_{n+1}|\mathbf{Z}_0, \dots, \mathbf{Z}_n)$ .

*Rešitev: Iz enačbe*

$$\mathbf{Z}_{n+1} = \begin{pmatrix} 1 & 1 \\ 1 & 1 \end{pmatrix} \mathbf{Z}_n + \epsilon_{n+1} ,$$

*linearnosti in predpostavk o neodvisnosti takoj sledi*

$$E(Y_{n+1}|\mathbf{Z}_0, \dots, \mathbf{Z}_n) = X_n + Y_n .$$

b. (5) Izračunajte

$$\text{cov}(X_{n+1}, Y_{n+1}|\mathbf{Z}_0, \dots, \mathbf{Z}_n) .$$

*Rešitev: Iz predpostavk o neodvisnosti sledi*

$$\text{cov}(X_{n+1}, Y_{n+1}|\mathbf{Z}_0, \dots, \mathbf{Z}_n) = \lambda_{12} .$$

c. (5) Izračunajte

$$\text{var}(X_{n+1}|\mathbf{Z}_0, \dots, \mathbf{Z}_n) .$$

*Rešitev: Iz predpostavk o neodvisnosti sledi*

$$\text{var}(X_{n+1}|\mathbf{Z}_0, \dots, \mathbf{Z}_n) = \lambda_{11}^2 .$$

d. (10) Izračunajte

$$E(Y_{n+1}|X_{n+1}, \mathbf{Z}_0, \dots, \mathbf{Z}_n) .$$

*Rešitev: Vektor  $(X_{n+1}, Y_{n+1}, \mathbf{Z}_0^T, \dots, \mathbf{Z}_n^T)$  je večrazsežen normalen. Uporabimo lahko formulo iz besedila naloge in dobimo*

$$E(Y_{n+1}|X_{n+1}, \mathbf{Z}_0, \dots, \mathbf{Z}_n) = X_n + Y_n + \frac{\lambda_{12}}{\lambda_{11}}(X_{n+1} - X_n - Y_n) .$$

2. (25) Dana je populacija velikosti  $N$ , na njej pa statistična spremenljivka. Označimo z  $\mu$  in  $\sigma^2$  povprečje in varianco te spremenljivke na celotni populaciji.

- a. (5) Recimo, da iz dane populacije izberemo enostavni slučajni vzorec velikosti  $n$ . Najdite nepristransko cenilko za kvadrat populacijskega povprečja  $\mu^2$  in utemeljite nepristranskost.

*Namig: ali lahko nepristransko ocenite količino*

$$\gamma = \frac{1}{N} \sum_{k=1}^N x_k^2 \text{ ?}$$

*Rešitev: Količino  $\gamma$  lahko ocenimo nepristransko z vzorčnim povprečjem kvadratov vzorčnih vrednosti. Velja tudi*

$$\sigma^2 = \frac{1}{N} \sum_{k=1}^N x_k^2 - \mu^2 = \gamma - \mu^2 .$$

*Vemo, da je*

$$\hat{\sigma}^2 = \frac{N-1}{N(n-1)} \sum_{i=1}^n (X_i - \bar{X})^2$$

*nepristranska cenilka za  $\sigma^2$ , kjer z  $X_1, \dots, X_n$  označimo vzorčne vrednosti. V zgornji enačbi torej znamo nepristransko oceniti dve od treh količin, zato znamo nepristransko oceniti tudi tretjo, torej  $\mu^2$ .*

- b. (10) Zdaj pa populacijo razdelimo na  $K$  skupinic velikosti  $M$ , tako da je  $N = KM$ , ter vzorčimo tako, da izberemo enostavni slučajni vzorec velikosti  $k$  skupinic in vključimo v vzorec vse enote iz izbranih skupinic. Označimo z  $\mu_r$  in  $\sigma_r^2$  povprečje in varianco dane spremenljivke na  $r$ -ti skupinici,  $r = 1, 2, \dots, K$ . Za cenilko populacijskega povprečja  $\mu$  vzemimo povprečje na tako dobljenem vzorcu. Utemeljite, da je ta cenilka nepristranska, in navedite njeno standardno napako.

*Rešitev: Ker so vse skupinice enako velike, je  $\mu = \frac{1}{K} \sum_{k=1}^K \mu_k$ . Če si mislimo, da vzorčimo iz populacije skupnic, potem z enostavnim slučajnim vzorčenjem ocenjujemo populacijsko povprečje. Cenilka je zato nepristranska, varianca pa je enaka*

$$\text{var}(\bar{X}) = \frac{\tau^2}{k} \cdot \frac{K-k}{K-1},$$

*kjer je*

$$\tau^2 = \frac{1}{K} \sum_{r=1}^K (\mu_r - \mu)^2 .$$

- c. (10) Recimo, da želimo z vzorcem, opisanem v prejšnji točki, oceniti populacijsko varianco  $\sigma^2$ . Predlagajte nepristransko cenilko in utemeljite nepristranskost.

Namig: oglejte si točko a.

Rešitev:

Prvi način. Če razmišljamo o skupinicah kot primarnih enotah, lahko na podlagi prvega dela naloge sklepamo, da znamo nepristransko oceniti  $\mu^2$ . Če se potem vrnemo k opisanemu vzorčenju, pa vemo, da lahko nepristransko ocenimo vsoto

$$\frac{1}{N} \sum_{k=1}^N x_k^2.$$

Ker je

$$\sigma^2 = \frac{1}{N} \sum_{k=1}^N x_k^2 - \mu^2$$

in znamo nepristransko oceniti obe količini na desni, znamo nepristransko oceniti tudi  $\sigma^2$ .

Za eksplicitno izražavo cenilke označimo z  $X_{ij}$  vrednost spremenljivke na  $j$ -ti enoti v  $i$ -ti skupinici, izbrani v vzorec, z  $A_i$  povprečje na tej skupinici, z  $\bar{A}$  pa povprečje teh povprečij po izbranih skupinicah (to je torej iskana cenilka v točki b.). Tedaj velja

$$\begin{aligned} \hat{\sigma}^2 &= \frac{1}{kM} \sum_{i=1}^k \sum_{j=1}^M X_{ij}^2 - \frac{1}{k} \sum_{i=1}^k A_i^2 + \frac{K-1}{K(k-1)} \sum_{i=1}^k (A_i - \bar{A})^2 \\ &= \frac{1}{kM} \sum_{i=1}^k \sum_{j=1}^M (X_{ij} - A_i)^2 + \frac{K-1}{K(k-1)} \sum_{i=1}^k (A_i - \bar{A})^2. \end{aligned}$$

Drugi način. Upoštevamo, da populacijska varianca razpade na varianco znotraj skupinic in varianco med skupinicami: velja  $\sigma^2 = \sigma_B^2 + \sigma_W^2$ , kjer je

$$\sigma_B^2 = \frac{1}{K} \sum_{r=1}^k (\mu_r - \mu)^2 \quad \text{in} \quad \sigma_W^2 = \frac{1}{KM} \sum_{r=1}^k \sum_{s=1}^M (x_{rs} - \mu_r)^2,$$

$x_{rs}$  pa je vrednost spremenljivke na  $s$ -ti enoti v  $r$ -ti skupinici. Vemo, da je

$$\hat{\sigma}_B^2 = \frac{K-1}{K(k-1)} \sum_{i=1}^k (A_i - \bar{A})^2$$

nepristranska cenilka za  $\sigma_B^2$ . Zdaj pa opazimo, da je  $\sigma_W^2$  populacijsko povprečje statistične spremenljivke, ki je na  $s$ -ti enoti v  $r$ -ti skupinici enaka  $y_{rs} := (x_{rs} - \mu_r)^2$ . Točka b., uporabljena na tej spremenljivki, pove, da je

$$\frac{1}{kM} \sum_{i=1}^k \sum_{j=1}^M (X_{ij} - A_i)^2$$

nepristranska cenilka za  $\hat{\sigma}_B^2$ . Ko seštejemo, dobimo isto cenilko kot pri prvem načinu.

3. (25) Opazovane vrednosti naj bodo pari  $(x_1, y_1), \dots, (x_n, y_n)$ ,  $n \geq 2$ , za katere predpostavljamo, da so vzorec iz dvorazsežne normalne porazdelitve

$$N\left(\begin{pmatrix} 0 \\ 0 \end{pmatrix}, \begin{pmatrix} \sigma_{11} & \sigma_{12} \\ \sigma_{21} & \sigma_{22} \end{pmatrix}\right).$$

a. (10) Poiščite cenilke za parametre po metodi največjega verjetja. Kot znano privzemite, da za dano pozitivno definitno matriko  $\mathbf{A}$  med vsemi pozitivno definitnimi matrikami  $\mathbf{X}$  izraz

$$\frac{1}{(\det \mathbf{X})^{n/2}} \exp\left(-\frac{1}{2} \text{Sl}(\mathbf{X}^{-1} \mathbf{A})\right)$$

maksimizira matrika  $\mathbf{X} = \frac{1}{n} \mathbf{A}$ .

Rešitev: Označimo  $\mathbf{x}_k = (x_k, y_k)$ . Funkcijo verjetja tako lahko zapišemo kot

$$L(\boldsymbol{\Sigma} | \mathbf{x}_1, \dots, \mathbf{x}_n) = \frac{1}{(2\pi)^{n/2} (\det \boldsymbol{\Sigma})^{n/2}} \exp\left(-\frac{1}{2} \sum_{k=1}^n \mathbf{x}_k^T \boldsymbol{\Sigma}^{-1} \mathbf{x}_k\right).$$

Če želimo upoštevati namig, pišemo:

$$\mathbf{x}_k^T \boldsymbol{\Sigma}^{-1} \mathbf{x}_k = \text{Sl}(\mathbf{x}_k^T \boldsymbol{\Sigma}^{-1} \mathbf{x}_k) = \text{Sl}(\boldsymbol{\Sigma}^{-1} \mathbf{x}_k \mathbf{x}_k^T).$$

Iz namiga zdaj razberemo, da maksimum dobimo pri matriki

$$\hat{\boldsymbol{\Sigma}} = \frac{1}{n} \sum_{k=1}^n \mathbf{x}_k \mathbf{x}_k^T = \frac{1}{n} \begin{bmatrix} \sum_{k=1}^n x_k^2 & \sum_{k=1}^n x_k y_k \\ \sum_{k=1}^n x_k y_k & \sum_{k=1}^n y_k^2 \end{bmatrix}.$$

b. (15) Želimo preizkusiti domnevo

$$H_0: \sigma_{12} = 0 \quad \text{proti} \quad H_1: \sigma_{12} \neq 0.$$

Poiščite testno statistiko po metodi kvocienta verjetij in navedite njeno aproksimativno porazdelitev pri velikem vzorcu.

Rešitev: Najprej moramo oceniti parametre pri domnevi  $H_0$ . Če je  $\sigma_{12} = 0$ , funkcija verjetja razpade na faktor, ki je odvisen samo od  $x$ -ov in faktor, ki je odvisen samo od  $y$ -ov. Maksimum dobimo, če maksimiziramo vsak faktor posebej, kar pa je iskanje ocen po metodi največjega verjetja za normalno porazdelitev. Maksimum pri stranskem pogoju torej dobimo za

$$\hat{\sigma}_{11} = \frac{1}{n} \sum_{k=1}^n x_k^2 \quad \text{in} \quad \hat{\sigma}_{22} = \frac{1}{n} \sum_{k=1}^n y_k^2.$$

Iz prvega dela naloge sledi, da je maksimum brez stranskih pogojev enak

$$L(\hat{\boldsymbol{\Sigma}} | \mathbf{x}_1, \dots, \mathbf{x}_n) = \frac{1}{(2\pi)^{n/2} (\det \hat{\boldsymbol{\Sigma}})^{n/2}} e^{-n},$$

maksimum s stranskimi pogoji pa

$$\frac{1}{(2\pi)^{n/2}(\hat{\sigma}_{11}\hat{\sigma}_{22})^{n/2}} e^{-n}.$$

Sledi

$$\Lambda = \left[ \frac{\sum_{k=1}^n x_k^2 \sum_{k=1}^n y_k^2}{\sum_{k=1}^n x_k^2 \sum_{k=1}^n y_k^2 - \left(\sum_{k=1}^n x_k y_k\right)^2} \right]^{n/2} = \left[ 1 - \frac{\left(\sum_{k=1}^n x_k y_k\right)^2}{\sum_{k=1}^n x_k^2 \sum_{k=1}^n y_k^2} \right]^{-n/2}.$$

Statistika  $\lambda = 2 \log \Lambda$  ima približno porazdelitev  $\chi^2(1)$ , t. j. hi kvadrat z eno prostostno stopnjo.

4. (25) Privzemite regresijski model

$$\mathbf{Y} = \mathbf{X}\boldsymbol{\beta} + \mathbf{Z}\mathbf{u}$$

kjer je  $\mathbf{Z}$  matrika velikosti  $r \times n$  ranga  $r$  in velja  $n \geq r$ , za  $\mathbf{u}$  pa velja  $E(\mathbf{u}) = 0$  in  $\text{var}(\mathbf{u}) = \sigma^2\mathbf{I}$ .

a. (10) Pokažite, da je

$$\hat{\boldsymbol{\beta}} = (\mathbf{X}^T(\mathbf{Z}\mathbf{Z}^T)^{-1}\mathbf{X})^{-1}\mathbf{X}^T(\mathbf{Z}\mathbf{Z}^T)^{-1}\mathbf{Y}$$

najboljša nepristranska linearna cenilka za  $\boldsymbol{\beta}$ .

*Rešitev:*

Prvi način: neposredno. Nepristranskost lahko takoj preverimo. Naj bo  $\tilde{\boldsymbol{\beta}} = \mathbf{L}\mathbf{Y}$  alternativna linearna nepristranska cenilka. Iz

$$E(\tilde{\boldsymbol{\beta}}) = \mathbf{L}\mathbf{X}\boldsymbol{\beta}$$

za vse  $\boldsymbol{\beta}$  sledi  $\mathbf{L}\mathbf{X} = \mathbf{I}$ . Računamo

$$\begin{aligned} \text{var}(\tilde{\boldsymbol{\beta}}) &= \text{var}(\tilde{\boldsymbol{\beta}} - \hat{\boldsymbol{\beta}} + \hat{\boldsymbol{\beta}}) \\ &= \text{var}(\hat{\boldsymbol{\beta}}) + \text{var}(\tilde{\boldsymbol{\beta}} - \hat{\boldsymbol{\beta}}) + 2\text{cov}(\tilde{\boldsymbol{\beta}} - \hat{\boldsymbol{\beta}}, \hat{\boldsymbol{\beta}}). \end{aligned}$$

Cenilka  $\tilde{\boldsymbol{\beta}}$  bo najboljša, brž ko bo kovarianca na desni enaka 0. Upoštevajoč

$$\text{cov}(\mathbf{Y}, \mathbf{Y}) = \sigma^2\mathbf{Z}\mathbf{Z}^T.$$

izračunamo, da je to res:

$$\begin{aligned} \text{cov}(\tilde{\boldsymbol{\beta}} - \hat{\boldsymbol{\beta}}, \hat{\boldsymbol{\beta}}) &= \\ &= \left( \mathbf{L} - (\mathbf{X}^T(\mathbf{Z}\mathbf{Z}^T)^{-1}\mathbf{X})^{-1}\mathbf{X}^T(\mathbf{Z}\mathbf{Z}^T)^{-1} \right) \text{cov}(\mathbf{Y}, \mathbf{Y}) \cdot \\ &\quad \cdot \left( (\mathbf{X}^T(\mathbf{Z}\mathbf{Z}^T)^{-1}\mathbf{X})^{-1}\mathbf{X}^T(\mathbf{Z}\mathbf{Z}^T)^{-1} \right)^T \\ &= \sigma^2 \left( \mathbf{L} - (\mathbf{X}^T(\mathbf{Z}\mathbf{Z}^T)^{-1}\mathbf{X})^{-1}\mathbf{X}^T(\mathbf{Z}\mathbf{Z}^T)^{-1} \right) \mathbf{Z}\mathbf{Z}^T \\ &\quad \cdot (\mathbf{Z}\mathbf{Z}^T)^{-1}\mathbf{X}(\mathbf{X}^T(\mathbf{Z}\mathbf{Z}^T)^{-1}\mathbf{X})^{-1} \\ &= \sigma^2 \left( \mathbf{L} - (\mathbf{X}^T(\mathbf{Z}\mathbf{Z}^T)^{-1}\mathbf{X})^{-1}\mathbf{X}^T(\mathbf{Z}\mathbf{Z}^T)^{-1} \right) \mathbf{X}(\mathbf{X}^T(\mathbf{Z}\mathbf{Z}^T)^{-1}\mathbf{X})^{-1} \\ &= \sigma^2 \left( \mathbf{L}\mathbf{X} - (\mathbf{X}^T(\mathbf{Z}\mathbf{Z}^T)^{-1}\mathbf{X})^{-1}\mathbf{X}^T(\mathbf{Z}\mathbf{Z}^T)^{-1}\mathbf{X} \right) (\mathbf{X}^T(\mathbf{Z}\mathbf{Z}^T)^{-1}\mathbf{X})^{-1} \\ &= \sigma^2(\mathbf{I} - \mathbf{I}) (\mathbf{X}^T(\mathbf{Z}\mathbf{Z}^T)^{-1}\mathbf{X})^{-1} \\ &= 0. \end{aligned}$$

Drugi način: prevedemo na standardno linearno regresijo. Razlika je namreč le v tem, da šum  $\mathbf{Z}\mathbf{u}$  nima kovariančne matrike  $\sigma^2\mathbf{I}$ , temveč  $\sigma^2\mathbf{Z}\mathbf{Z}^T$ . Če definiramo

$\mathbf{Y}' = (\mathbf{Z}\mathbf{Z}^T)^{-1/2}\mathbf{Y}$ ,  $\mathbf{X}' = (\mathbf{Z}\mathbf{Z}^T)^{-1/2}\mathbf{X}$  in  $\boldsymbol{\varepsilon} = (\mathbf{Z}\mathbf{Z}^T)^{-1/2}\mathbf{Z}\mathbf{u}$ , velja  $\mathbf{Y}' = \mathbf{X}'\boldsymbol{\beta} + \boldsymbol{\varepsilon}$ , kar je standardni linearni regresijski model, saj je:

$$\begin{aligned}\text{var}(\boldsymbol{\varepsilon}) &= (\mathbf{Z}\mathbf{Z}^T)^{-1/2}\mathbf{Z}\text{var}(\mathbf{u})\mathbf{Z}^T(\mathbf{Z}\mathbf{Z}^T)^{-1/2} \\ &= \sigma^2(\mathbf{Z}\mathbf{Z}^T)^{-1/2}\mathbf{Z}\mathbf{I}\mathbf{Z}^T(\mathbf{Z}\mathbf{Z}^T)^{-1/2} \\ &= \sigma^2\mathbf{I}.\end{aligned}$$

Seveda se linearne cenilke v podanem nestandardnem modelu ujemajo z linearnimi cenilkami v prirejenem standardnem modelu, nepristranskost in standardna napaka pa sta tako ali tako univerzalna pojma. Zato je iskana cenilka tudi najboljša nepristranska linearna cenilka v prirejenem standardnem modelu, to pa je:

$$\begin{aligned}\hat{\boldsymbol{\beta}} &= (\mathbf{X}'^T\mathbf{X}')^{-1}\mathbf{X}'^T\mathbf{Y}' \\ &= (\mathbf{X}^T(\mathbf{Z}\mathbf{Z}^T)^{-1/2}(\mathbf{Z}\mathbf{Z}^T)^{-1/2}\mathbf{X})^{-1}\mathbf{X}^T(\mathbf{Z}\mathbf{Z}^T)^{-1/2}(\mathbf{Z}\mathbf{Z}^T)^{-1/2}\mathbf{Y} \\ &= (\mathbf{X}^T(\mathbf{Z}\mathbf{Z}^T)^{-1}\mathbf{X})^{-1}\mathbf{X}^T(\mathbf{Z}\mathbf{Z}^T)^{-1}\mathbf{Y}.\end{aligned}$$

b. (15) Naj bo

$$\hat{\mathbf{u}} = \mathbf{Z}^T(\mathbf{Z}\mathbf{Z}^T)^{-1}(\mathbf{Y} - \mathbf{X}\hat{\boldsymbol{\beta}})$$

cenilka za  $\mathbf{u}$ . Izračunajte

$$\text{cov}(\hat{\mathbf{u}}, \hat{\boldsymbol{\beta}}).$$

Rešitev: Računamo

$$\begin{aligned}\text{cov}(\hat{\mathbf{u}}, \hat{\boldsymbol{\beta}}) &= \\ &= \mathbf{Z}^T(\mathbf{Z}\mathbf{Z}^T)^{-1}\left(\mathbf{I} - \mathbf{X}(\mathbf{X}^T(\mathbf{Z}\mathbf{Z}^T)^{-1}\mathbf{X})^{-1}\mathbf{X}^T(\mathbf{Z}\mathbf{Z}^T)^{-1}\right)\text{cov}(\mathbf{Y}, \mathbf{Y}) \cdot \\ &\quad \cdot (\mathbf{Z}\mathbf{Z}^T)^{-1}\mathbf{X}(\mathbf{X}^T(\mathbf{Z}\mathbf{Z}^T)^{-1}\mathbf{X})^{-1} \\ &= \mathbf{Z}^T(\mathbf{Z}\mathbf{Z}^T)^{-1}\left(\mathbf{I} - \mathbf{X}(\mathbf{X}^T(\mathbf{Z}\mathbf{Z}^T)^{-1}\mathbf{X})^{-1}\mathbf{X}^T(\mathbf{Z}\mathbf{Z}^T)^{-1}\right) \cdot \\ &\quad \cdot \mathbf{Z}\mathbf{Z}^T(\mathbf{Z}\mathbf{Z}^T)^{-1}\mathbf{X}(\mathbf{X}^T(\mathbf{Z}\mathbf{Z}^T)^{-1}\mathbf{X})^{-1} \\ &= \mathbf{0}.\end{aligned}$$