

FAKULTETA ZA MATEMATIKO IN FIZIKO

ODDELEK ZA MATEMATIKO

STATISTIKA

PISNI IZPIT

10. JUNIJ 2014

IME IN PRIIMEK: _____

VPISNA ST:

NAVODILA

Pazljivo preberite besedilo naloge, preden se lotite reševanja. Nalog je 6, 5 rešenih nalog pa je že 100%. Na razpolago imate 2 uri.

Naloga	a.	b.	c.	d.	
1.			•	•	
2.					
3.			•		
4.		•	•		
5.					
6.		•	•		
Skupaj					

1. (20) Naj bosta \mathbf{X} in \mathbf{Y} slučajna vektorja dimenzije p in taka, da je

$$\begin{pmatrix} \mathbf{X} \\ \mathbf{Y} \end{pmatrix} \sim N \left(\begin{pmatrix} \mathbf{0} \\ \mathbf{0} \end{pmatrix}, \begin{pmatrix} \mathbf{I} & \rho \mathbf{1} \mathbf{1}^T \\ \rho \mathbf{1} \mathbf{1}^T & \mathbf{I} \end{pmatrix} \right).$$

Pri tem je $\rho \in (-1, 1)$ in $\mathbf{1}^T = (1, 1, \dots, 1)$.

a. (10) Utemeljite, da velja

$$E(\mathbf{Y}^T \mathbf{Y} | \mathbf{X}) = E(\text{Sl}(\mathbf{Y} \mathbf{Y}^T) | \mathbf{X}) = \text{Sl} \left(\text{var}(\mathbf{Y} | \mathbf{X}) + E(\mathbf{Y} | \mathbf{X}) E(\mathbf{Y} | \mathbf{X})^T \right).$$

Rešitev: Vemo, da velja

$$\mathbf{Y}^T \mathbf{Y} = \text{Sl}(\mathbf{Y} \mathbf{Y}^T).$$

Zaradi linearnosti lahko zamenjamo E in Sl . Po definiciji je

$$\text{var}(\mathbf{Y} | \mathbf{X}) = E(\mathbf{Y} \mathbf{Y}^T | \mathbf{X}) + E(\mathbf{Y} | \mathbf{X}) E(\mathbf{Y} | \mathbf{X})^T$$

b. (10) Izračunajte

$$E(\mathbf{Y}^T \mathbf{Y} | \mathbf{X}).$$

Rešitev: Poznamo pogojno porazdelitev \mathbf{Y} glede ne \mathbf{X} , ki je

$$\mathbf{Y} | \mathbf{x} = \mathbf{x} \sim N(\rho \mathbf{1} \mathbf{1}^T \mathbf{x}, \mathbf{I} - p\rho^2 \mathbf{1} \mathbf{1}^T).$$

Računamo

$$\begin{aligned} E(\mathbf{Y}^T \mathbf{Y} | \mathbf{X}) &= E(\text{Sl}(\mathbf{Y} \mathbf{Y}^T) | \mathbf{X}) \\ &= \text{Sl} \left(E(\mathbf{Y} \mathbf{Y}^T | \mathbf{X}) \right) \\ &= \text{Sl} \left(\text{var}(\mathbf{Y} | \mathbf{X}) + E(\mathbf{Y} | \mathbf{X}) E(\mathbf{Y} | \mathbf{X})^T \right) \\ &= \text{Sl} \left(\mathbf{I} - p\rho^2 \mathbf{1} \mathbf{1}^T + \rho^2 \mathbf{1} \mathbf{1}^T \mathbf{X} \mathbf{X}^T \mathbf{1} \mathbf{1}^T \right) \\ &= p - p^2 \rho^2 + p \rho^2 \left(\sum_{k=1}^p X_k \right)^2. \end{aligned}$$

2. (20) Privzemite, da je populacija velikosti N razdeljena na K stratumov velikosti N_1, N_2, \dots, N_K . Enostavni slučajni vzorci so velikosti n_1, n_2, \dots, n_K . Z μ označite populacijsko povprečje in z σ^2 populacijsko varianco za celotno populacijo, z μ_k in σ_k^2 označite populacijsko povprečje in populacijsko varianco za k -ti stratum.

a. (5) Pokažite, da je

$$\sigma^2 = \sum_{k=1}^K w_k \sigma_k^2 + \sum_{k=1}^K w_k (\mu_k - \mu)^2$$

kjer je $w_k = \frac{N_k}{N}$ za $k = 1, 2, \dots, K$.

Rešitev: Po definiciji je

$$\sigma^2 = \frac{1}{N} \left(\sum_{k=1}^K \sum_{i=1}^{N_k} (y_{ki} - \mu)^2 \right)$$

kjer je y_{ki} vrednost i -te enote v k -tem stratumu. Opazimo, da

$$\begin{aligned} & \sum_{i=1}^{N_k} (y_{ki} - \mu)^2 = \\ &= \sum_{i=1}^{N_k} (y_{ki} - \mu_k + \mu_k - \mu)^2 \\ &= \sum_{i=1}^{N_k} (y_{ki} - \mu_k)^2 + \sum_{i=1}^{N_k} (\mu_k - \mu)^2 + 2(\mu_k - \mu) \sum_{i=1}^{N_k} (y_{ki} - \mu) \\ &= \sum_{i=1}^{N_k} (y_{ki} - \mu_k)^2 + \sum_{i=1}^{N_k} (\mu_k - \mu)^2 \\ &= N_k \sigma_k^2 + N_k (\mu_k - \mu)^2. \end{aligned}$$

Z uporabo tega v zgornji vsoti dobimo ustrezni rezultat.

b. (10) Naj bo \bar{Y}_k vzorčno povprečje v k -tem stratumu za $k = 1, 2, \dots, K$ in $\bar{Y} = \sum_{k=1}^K w_k \bar{Y}_k$ nepristranska cenilka za populacijsko povprečje. Privzemite, da so $\bar{Y}_1, \dots, \bar{Y}_n$ neodvisne cenilke. Za oceno σ^2 moramo oceniti

$$\sigma_b^2 = \sum_{k=1}^K w_k (\mu_k - \mu)^2 = \sum_{k=1}^K w_k \mu_k^2 - \mu^2.$$

Predlagana je cenilka

$$\hat{\sigma}_b^2 = \sum_{k=1}^K w_k \bar{Y}_k^2 - \bar{Y}^2.$$

Pokažite, da je

$$E(\hat{\sigma}_b^2) = \sum_{k=1}^K w_k(1-w_k)\text{var}(\bar{Y}_k) + \sum_{k=1}^K w_k\mu_k^2 - \mu^2.$$

Rešitev: Vemo, da

$$E(\bar{Y}_k^2) = \text{var}(\bar{Y}_k^2) + \mu_k^2$$

in

$$E(\bar{Y}^2) = \text{var}(\bar{Y}) + \mu^2.$$

Imamo

$$E(\hat{\sigma}_b^2) = \sum_{k=1}^K w_k (\text{var}(\bar{Y}_k^2) + \mu_k^2) - \text{var}(\bar{Y}) - \mu^2.$$

Z upoštevanjem

$$\text{var}(\bar{Y}) = \sum_{k=1}^K w_k^2 \text{var}(\bar{Y}_k)$$

rezultat sledi.

- c. (5) Ali obstaja nepristranska cenilka za σ^2 ? Utemeljite svoj odgovor.

Rešitev: Vemo, da

$$\sigma^2 = \sum_{k=1}^K w_k \sigma_k^2 + \sum_{k=1}^K w_k(\mu_k - \mu)^2$$

Nepristransko cenilko za σ_b^2 imamo. Torej nam manjka še nepristranska cenilka za drugi člen, torej za $\sum_{k=1}^K w_k(\mu_k - \mu)^2$. Malo popravimo cenilko iz b. dela naloge. In sicer tako, da bo veljalo $E(\tilde{\sigma}_b^2) = \sigma_b^2$. Za cenilko vzamemo

$$\tilde{\sigma}_b^2 = \sum_{k=1}^K w_k \bar{Y}_k^2 - \bar{Y}^2 - \sum_{k=1}^K w_k(1-w_k)\text{var}(\bar{Y}_k).$$

Ker znotraj stratuma vzorčimo enostavno, lahko $\text{var}(\bar{Y}_k)$ nadomestimo z $\frac{\hat{\sigma}_k^2}{n_k}$. $\frac{N_k-n_k}{N_k-1}$. Dobljena cenilka bo nepristranska za parameter σ_b^2 . Torej nepristranska cenilka za σ^2 obstaja.

3. (20) Predpostavite, da opazovane vrednosti x_1, x_2, \dots, x_n nastanejo kot neodvisne, enako porazdeljene slučajne spremenljivke X_1, X_2, \dots, X_n s porazdelitvijo

$$P(X_1 = x) = \frac{(\theta - 1)^{x-1}}{\theta^x}$$

za $x = 1, 2, 3, \dots$ in $\theta > 1$.

- a. (10) Poišcite cenilko parametra θ po metodi največjega verjetja na podlagi opazovanih vrednosti.

Rešitev: Zapišemo logaritemsko funkcijo verjetja

$$\ell(\theta, \mathbf{x}) = \left(\sum_{k=1}^n x_k - n \right) \log(\theta - 1) - \left(\sum_{k=1}^n x_k \right) \log \theta .$$

Odvajamo in dobimo

$$\ell'(\theta, \mathbf{x}) = \frac{\sum_{k=1}^n x_k - n}{\theta - 1} - \frac{\sum_{k=1}^n x_k}{\theta} = 0 .$$

Sledi

$$\hat{\theta} = \frac{1}{n} \sum_{k=1}^n x_k = \bar{x} .$$

- b. (10) Zapišite aproksimativni 99% interval zaupanja za parameter θ na podlagi opazovanih vrednosti. Kot znano privzemite

$$\sum_{x=1}^{\infty} x a^{x-1} = \frac{1}{(1-a)^2}$$

za $|a| < 1$.

Rešitev: Imamo

$$\ell''(\theta, x) = -\frac{x-1}{(\theta-1)^2} + \frac{x}{\theta^2} .$$

Za Fisherjevo informacijo rabimo

$$E(X_1) = \sum_{x=1}^{\infty} x \frac{(\theta-1)^{x-1}}{\theta^x} .$$

Z uporabo namiga dobimo

$$E(X_1) = \frac{1}{\theta} \cdot \left(1 - \frac{\theta-1}{\theta} \right)^{-2} = \theta .$$

Torej

$$I(\theta) = \frac{1}{\theta(\theta - 1)}.$$

Aproksimativni 99% interval zaupanja je

$$\hat{\theta} \pm 2.56 \cdot \sqrt{\frac{\hat{\theta}(\hat{\theta} - 1)}{n}}.$$

4. (20) Na razpolago imamo opazovane vrednosti X_1, X_2, \dots, X_n iz normalne porazdelitve $N(\mu, \sigma^2)$. Predpostavljamo, da so opazovane vrednosti med sabo neodvisne, enako porazdeljene slučajne spremenljivke. Preizkusiti želimo domnevo $H_0 : \mu = 0$ proti $H_1 : \mu \neq 0$. **Privzemite, da je parameter σ^2 znan.**

a. (10) Domnevo H_0 lahko preizkusimo pri dani stopnji tveganja α na dva načina:

- H_0 zavrnemo, če je $|\bar{X}| > c$ za primerno izbran c , tako da bo tveganje ravno α .
- Iz opazovanih vrednosti ocenimo μ in izračunamo zgornjo in spodnjo mejo intervala zaupanja pri stopnji tveganja α . Če interval ne pokriva 0, domnevo H_0 zavrzemo.

Ali sta zgornja testa popolnoma enaka? Komentirajte.

Rešitev: Ker je σ^2 znan, je širina intervala zaupanja fiksna in enaka c . Testa sta popolnoma enaka.

b. (10) Izračunajte še testno statistiko za zgornjo situacijo po metodi kvocienta verjetij.

Rešitev: Ko izračunamo Λ , se konstanti $(1/\sqrt{2\pi\sigma^2})^n$ pokrajšata, tako da je

$$\Lambda = \exp \left(- \sum_{i=1}^n \frac{(x_i - \bar{x})^2 - x_i^2}{2\sigma^2} \right).$$

Izraz nekoliko preoblikujemo in dobimo

$$\Lambda = \exp \left(\frac{n\bar{x}^2}{2\sigma^2} \right).$$

Ker je σ^2 znan, bomo ničelno domnevo zavrnili, ko bo $|\bar{x}| > c$ za primerno izbran c .

5. (20) Dana imamo dva kompleta regresijskih enačb

$$Y_i = \alpha_1 + \beta x_i + \epsilon_i$$

za $i = 1, 2, \dots, m$ in

$$Z_j = \alpha_2 + \beta w_j + \eta_j$$

za $j = 1, 2, \dots, n$. Predpostavljamo, da vsak model zase ustreza standardnim predpostavkam regresijskega modela, torej, da za vse i, j velja $E(\epsilon_i) = E(\eta_j) = 0$, $\text{var}(\epsilon_i) = \text{var}(\eta_j) = \sigma^2$ in so ϵ_i in η_j med sabo nekorelirani. Predpostavljamo tudi, da so vsi ϵ_i in η_j nekorelirani.

a. (5) Utemeljite, da lahko modela združimo v

$$\begin{pmatrix} Y_1 \\ Y_2 \\ \vdots \\ Y_m \\ Z_1 \\ Z_2 \\ \vdots \\ Z_n \end{pmatrix} = \begin{pmatrix} 1 & 0 & x_1 \\ 1 & 0 & x_2 \\ \vdots & \vdots & \vdots \\ 1 & 0 & x_m \\ 1 & 1 & w_1 \\ 1 & 1 & w_2 \\ \vdots & \vdots & \vdots \\ 1 & 1 & w_n \end{pmatrix} \begin{pmatrix} \alpha_1 \\ \alpha_2 - \alpha_1 \\ \beta \end{pmatrix} + \begin{pmatrix} \epsilon_1 \\ \epsilon_2 \\ \vdots \\ \epsilon_m \\ \eta_1 \\ \eta_2 \\ \vdots \\ \eta_n \end{pmatrix}.$$

Utemeljite, da ta model ustreza standardnim predpostavkam modela linearne regresije.

Rešitev: Z množenjem matrik ugotovimo, da dobimo povsem iste enačbe. Da ta novi model ustreza vsem predpostavkam standardnega modela sledi iz navedenih predpostavk.

b. (5) Predpostavite, da je

$$\sum_{i=1}^m x_i = 0 \quad \text{in} \quad \sum_{j=1}^n w_j = 0$$

ter

$$\sum_{i=1}^m x_i^2 = 1 \quad \text{in} \quad \sum_{j=1}^n w_j^2 = 1.$$

Podajte najboljšo nepristransko cenilko parametra β . Izračunajte njeno standardno napako.

Rešitev: Ugotovimo, da je

$$\mathbf{X}^T \mathbf{X} = \begin{pmatrix} m+n & n & 0 \\ n & n & 0 \\ 0 & 0 & 2 \end{pmatrix}.$$

Matriko obrnemo in dobimo

$$(\mathbf{X}^T \mathbf{X})^{-1} = \begin{pmatrix} 1/m & -1/m & 0 \\ -1/m & (m+n)/mn & 0 \\ 0 & 0 & 1/2 \end{pmatrix}.$$

Ugotovimo še

$$\mathbf{X}^T \mathbf{Y} = \begin{pmatrix} \sum_{i=1}^m Y_i + \sum_{j=1}^n Z_j \\ \sum_{j=1}^n Z_j \\ \sum_{i=1}^m x_i Y_i + \sum_{j=1}^n w_j Z_j \end{pmatrix}.$$

Sledi

$$\hat{\beta} = \frac{1}{2} \left(\sum_{i=1}^m x_i Y_i + \sum_{j=1}^n w_j Z_j \right).$$

Za standardno napako dobimo po formuli

$$\text{se}(\hat{\beta}) = \sigma \sqrt{c_{ii}} = \frac{\sigma}{\sqrt{2}}.$$

- c. (10) Podajte najboljšo nepristransko cenilko parametra α_2 . Podajte njeno standardno napako.

Rešitev: Če imamo najboljšo cenilko $\alpha_2 - \alpha_1$ in najboljšo cenilko α_1 , je po izreku Gauss-Markova njuna vsota najboljša linearna cenilka α_2 . Z množenjem matrik dobimo, da je $\hat{\alpha}_1 = \bar{Y}$ in $\hat{\alpha}_2 - \hat{\alpha}_1 = \bar{Z} - \bar{Y}$. Torej je $\hat{\alpha}_2 = \bar{Z}$. Standardna napaka je σ/\sqrt{n} .

6. (20) Hazarder Marko obišče 100 igralnih avtomatov. Pred vsakim vrže pošten kovanec. Če pade cifra, na tem avtomatu igra, sicer pa ne. Na vsakem avtomatu ima, če igra, pričakovano izgubo 1 evro, standardni odklon pa je 3 evre. Privzamemo, da so posamezne igre in meti kovanca med seboj neodvisni.

- a. (10) Izračunajte pričakovano vrednost in varianco Markovega izkupička po obisku vseh igralnih avtomatov.

Rešitev: Če z S označimo Markov izkupiček, potem ko obrede vse avtome, lahko pišemo:

$$S = I_1 X_1 + I_2 X_2 + \cdots + I_{100} X_{100},$$

kjer je $I_k = 1$, če je Marko igrал na k -tem avtomatu, sicer pa je $I_k = 0$; X_k je Markov izkupiček na k -tem avtomatu (namišljen, če Marko tam ni igrал). Računamo:

$$\begin{aligned} E(I_k X_k) &= E(I_k)E(X_k) = -\frac{1}{2}, \\ E(X_k^2) &= \text{var}(X_k) + (E(X_k))^2 = 10, \\ E((I_k X_k)^2) &= E(I_k)E(X_k^2) = 5, \\ \text{var}(I_k X_k) &= E((I_k X_k)^2) - (E(I_k X_k))^2 = \frac{19}{4}. \end{aligned}$$

Torej je $E(S) = -100/2 = -50$ in $\text{var}(S) = 100 \cdot 19/4 = 475$.

- b. (10) Približno izračunajte verjetnost, da bo imel Marko na koncu dobiček.

Rešitev: Po centralnem limitnem izreku je:

$$P(S > 0) \approx 1 - \Phi\left(\frac{50}{\sqrt{475}}\right) \doteq 0,011.$$