

Sveučilište u Zagrebu
PMF-Matematički odjel
Poslijediplomski stručni studij aktuarske matematike

ISPIT

VJEROJATNOST I MATEMATIČKA STATISTIKA

4. 10. 2004.

Vrijeme trajanja ispita: 120 minuta

Ukupan broj bodova: 100

Broj zadataka: 6

Naznačeno je koliko bodova donosi svaki točan odgovor.

Odgovore i rješenja zadataka pišite na dobivenim papirima. Na svakom korištenom papiru naznačite na koji se zadatak odnosi i čitko se potpišite.

Dozvoljeno je korištenje džepnog kalkulatora, statističkih tablica, vlastitih formula ili *Formulae and Tables for Actuarial Examinations* (Institute of Actuaries).

1. Portfelj se sastoji od 2000 istovrsnih polica osiguranja. Poznato je da se šteta po jednoj polici pojavljuje s vjerojatnosti 0.015 neovisno o ostalim policama. Po jednoj polici osiguranja moguća je najviše jedna šteta. Izračunajte (približno) vjerojatnost da će po tom portfelju biti više od 40 šteta. (15 bodova)

2. Neka je X binomna slučajna varijabla s parametrima (n, θ) .

(a) Pokažite da je funkcija izvodnica vjerojatnosti od X jednaka

$$G_X(t) = (1 - \theta + t\theta)^n. \quad (7 \text{ bodova})$$

(b) Izvedite pripadnu funkciju izvodnicu momenata. (8 bodova)

(ukupno 15 bodova)

3. Podaci o opaženim brojevima šteta po 4000 polica osiguranja koje su bile pod rizikom točno godinu dana, prikazani su u frekvencijskoj tablici:

broj šteta i	frekvencija f_i
0	3288
1	642
2	66
≥ 3	4
ukupno	4000

Redak u tablici označen sa " ≥ 3 " odnosi se na police po kojima je bilo 3 i više šteta. Pretpostavlja se da se slučajan broj šteta X po polici osiguranja ponaša po Poissonovom zakonu razdiobe $P(\lambda)$, pri čemu je parametar λ nepoznat.

(a) Odredite vjerodostojnost parametra λ na osnovi navedenog uzorka. (5 bodova)

(b) Provjerite da je $\hat{\lambda} = 0.196551$ procjena od λ maksimalne vjerodostojnosti na osnovi navedenog uzorka. (6 bodova)

(c) Sprovedite χ^2 -test prilagodbe Poissonovog modela navedenim podacima. Procijenite p -vrijednost i na osnovi nje ocijenite prihvatljivost nul-hipoteze. (9 bodova)

(ukupno 20 bodova)

4. Broj odlazaka aktuaru s posla nakon redovnog radnog vremena tijekom radnog tjedna modelira se kao binomna slučajna varijabla X s parametrima (n, θ) gdje je $n = 5$, a $\theta = \frac{4}{5}$. Za uvjetnu razdiobu ukupnog vremena Y koje je aktuar proveo na poslu tijekom tjedna (u satima) ako je taj tjedan morao na poslu ostati dulje x dana, vrijedi:

$$\mathbb{E}[Y|X = x] = 4(x + 10), \quad \text{Var}[Y|X = x] = x.$$

- (a) Koliko iznosi matematičko očekivanje $\mathbb{E}[Y]$ ukupnog vremena koje aktuar provodi na poslu tijekom tjedna? (7 bodova)
- (b) Izračunajte bezuvjetnu varijancu od Y (tj. varijancu $\text{Var}[Y]$ marginalne razdiobe od Y). (8 bodova)

(ukupno 15 bodova)

5. Poduzeće želi procijeniti postotak (proporciju) svojih klijenata koji su voljni kupovati preko interneta. Preciznije, treba procijeniti 95% pouzdani interval za taj parametar.

- (a) Pokažite da na osnovi slučajnog uzorka duljine 200 klijenata tog poduzeća, taj interval neće biti veći od 13.9% (tj. njegova duljina nije veća od 0.139). (8 bodova)
- (b) Izračunajte kolika bi trebala biti duljina slučajnog uzorka da bi 95% pouzdani interval za navedeni parametar bio najviše 10%. (7 bodova)

Uputa: Izraz $p(1 - p)$ za $p \in [0, 1]$ ocijenite odozgo sa $1/4$. (15 bodova)

6. Za zadanih 12 vrijednosti x_1, x_2, \dots, x_{12} (nezavisne) varijable poticaja X izmjerene su pripadne vrijednosti y_1, y_2, \dots, y_{12} (zavisne) varijable odziva Y . Na taj način dobiven je uzorak $(x_i, y_i), i = 1, 2, \dots, 12$ za koji vrijedi

$$\begin{aligned} \sum_{i=1}^{12} x_i &= 516.4, & \sum_{i=1}^{12} x_i^2 &= 22741.34 \\ \sum_{i=1}^{12} y_i &= 14821, & \sum_{i=1}^{12} y_i^2 &= 18695125 \end{aligned}$$

$$\sum_{i=1}^{12} x_i y_i = 650264.8.$$

- (a) Uz pretpostavku da je model za vezu varijabli poticaja X i odziva Y jednostavni linearni regresijski model, procijenite pravac regresije. (7 bodova)
- (b) Konstruirajte i procijenite 95%-pouzdan interval za koeficijent smjera regresijskog pravca. (5 bodova)
- (c) Testirajte nulhipotezu da je koeficijent smjera jednak nuli u odnosu na alternativu da to nije tako, uz razinu značajnosti od 5%. (3 boda)
- (d) Konstruirajte i procijenite 95%-pouzdan interval za očekivanu (srednju) vrijednost varijable Y ako je $X = 50$. (2 boda)
- (e) Opišite linearni regresijski model i navedite koje ste sve pretpostavke na njega koristili u zadacima (a – d). (3 boda)

(ukupno 20 bodova)

Sveučilište u Zagrebu
PMF-Matematički odjel
Poslijediplomski stručni studij aktuarske matematike

ISPIT

VJEROJATNOST I MATEMATIČKA STATISTIKA

4. 10. 2004.

RJEŠENJA ZADATAKA

1. Neka je X ukupan broj šteta u portfelju. Tada X ima binomnu razdiobu s parametrima $n = 2000$ i $\theta = 0.015$. (4)

Vjerojatnost da će biti više od 40 šteta:

$$\begin{aligned} \mathbb{P}(X > 40) &= & (3) \\ &= \mathbb{P}(X > 40.5) = & \text{(korekcija zbog neprekidnosti)} & (2) \\ &= \mathbb{P}\left(\frac{X-30}{\sqrt{29.55}} > \frac{10.5}{\sqrt{29.55}} = 1.93\right) = & (2) \\ &\approx 1 - \Phi(1.93) = & \text{(CGT)} & (2) \\ &= 1 - 0.973 = & \text{(tablice)} & (1) \\ &= 0.027. & (1) \end{aligned}$$

(15)

2. (a) Funkcija izvodnica vjerojatnosti od X :

$$\begin{aligned} G_X(t) &= \mathbb{E}[t^X] = & (3) \\ &= \sum_{k=0}^n t^k \cdot \binom{n}{k} \theta^k (1 - \theta)^{n-k} & (2) \\ &= \sum_{k=0}^n \binom{n}{k} (t\theta)^k (1 - \theta)^{n-k} = \text{(binomni teorem)} = (1 - \theta + t\theta)^n. & (2) \end{aligned}$$

- (b) Funkcija izvodnica momenata od X :

$$\begin{aligned} M_X(t) &= \mathbb{E}[e^{tX}] = & (3) \\ &= G_X(e^t) = & (3) \\ &= (1 - \theta + \theta \cdot e^t)^n \quad \text{(prema(a)).} & (2) \end{aligned}$$

(15)

3. (a) Vjerodostojnost od λ (do na konstantu):

$$L(\lambda) = (e^{-\lambda})^{3288} \cdot (\lambda e^{-\lambda})^{642} \cdot \left(\frac{\lambda^2}{2} e^{-\lambda}\right)^{66} \cdot \left(1 - e^{-\lambda} \left(1 + \lambda + \frac{\lambda^2}{2}\right)\right)^4. \quad (5)$$

(b) Log-vjerodostojnost:

$$\ell(\lambda) = -4000\lambda + 774 \log \lambda + 4 \log \left(e^\lambda - \left(1 + \lambda + \frac{\lambda^2}{2}\right)\right). \quad (2)$$

Budući da je MLE rješenje stacionarne jednadžbe:

$$\ell'(\lambda) = 0 \Leftrightarrow -4000 + \frac{774}{\lambda} + 4 \cdot \frac{e^\lambda - (1 + \lambda)}{e^\lambda - \left(1 + \lambda + \frac{\lambda^2}{2}\right)} = 0, \quad (2)$$

dovoljno je provjeriti da ju $\hat{\lambda} = 0.196551$ zadovoljava:

$$\ell'(0.196551) = -0.008 \approx 0, \quad (1)$$

što je zadovoljeno (do na zadovoljavajuću numeričku točnost). (1)

(c) Testitamo nulhipotezu $H_0 : X \sim P(\lambda)$ u odnosu na alternativu da to nije tako. (1)

Tablica:

i	f_i	p_i	e_i	$\frac{(f_i - e_i)^2}{e_i}$	
0	3288	0.8216	3286.2	0.0009	
1	642	0.1615	645.9	0.0237	
2	66	70	63.5	0.0682	(2 + 1)
≥ 3	4		4.4		
Σ	4000	1.0001	4000.0	0.0928	

Broj stupnjeva slobode: $3 - 1 - 1 = 1$. (1)

Testna statistika: $H \stackrel{H_0}{\sim} \chi^2(1)$, opažena vrijednost: $h = 0.0928$. (2)

p -vrijednost: $\mathbb{P}(H > 0.0928 | H_0) = 0.76$. (1)

Nemamo dokaza u korist odbacivanja H_0 , dakle, model je vrlo dobro prilagođen. (1)

(20)

Napomena: U ovom primjeru moguće je test sprovesti i bez združivanja zadnja dva razreda. U tom slučaju imamo ukupno dva stupnja slobode i sličan zaključak testa.

$$4. \quad \mathbb{E}[X] = 5 \cdot \frac{4}{5} = 4, \quad \text{Var}[X] = 5 \cdot \frac{4}{5} \cdot \frac{1}{5} = \frac{4}{5} \quad (2+2)$$

(a) Očekivanje od Y :

$$\mathbb{E}[Y] = \mathbb{E}[\mathbb{E}[Y|X]] = \quad (2)$$

$$= \mathbb{E}[4(X + 10)] = 4(\mathbb{E}[X] + 10) = \quad (2)$$

$$= 4 \cdot (4 + 10) = 56. \quad (1)$$

(b) Varijanca od Y :

$$\text{Var}[Y] = \mathbb{E}[\text{Var}[Y|X]] + \text{Var}[\mathbb{E}[Y|X]] = \quad (3)$$

$$= \mathbb{E}[X] + \text{Var}[4(X + 10)] = \mathbb{E}[X] + 16\text{Var}[X] = \quad (2)$$

$$= 4 + 16 \cdot \frac{4}{5} = \frac{84}{5} = 16.8. \quad (1)$$

(15)

5. (a) Budući da se radi o Bernoullijevom modelu, aproks. 95% pouzdani interval za parametar proporcije p je $\hat{p} \pm 1.96\sqrt{p(1-p)/200}$. (4)

Duljina tog intervala je $2 \cdot 1.96\sqrt{p(1-p)/200}$ (2)

što je najviše (ocjena iz upute) $1.96\sqrt{1/200} = 0.139 = 13.9\%$. (2)

(b) Traži se takav n da je $2 \cdot 1.96\sqrt{0.25/200} \leq 0.1$. (3)

Oдавде slijedi da je $n \geq 385$. (4)

(15)

6. (a) Opažene vrijednosti pomoćnih statistika:

$$\begin{aligned}\bar{x} &= \frac{516.4}{12} = 43.3 & \bar{y} &= \frac{1481}{12} = 1235.083 & (\frac{1}{2} + \frac{1}{2}) \\ S_{xx} &= \sum_{i=1}^{12} x_i^2 - 12 \cdot \bar{x}^2 = & S_{yy} &= \sum_{i=1}^{12} y_i^2 - 12 \cdot \bar{y}^2 = & (\frac{1}{2}) \\ &= 522.37 & &= 389965 & (\frac{1}{2}) \\ S_{xy} &= \sum_{i=1}^{12} x_i y_i - 12 \cdot \bar{x} \bar{y} = & & & (\frac{1}{2}) \\ &= 12517.35 & & & (\frac{1}{2})\end{aligned}$$

Parametri pravca:

$$\begin{aligned}\hat{\alpha} &= \frac{S_{xy}}{S_{xx}} = & \hat{\beta} &= \bar{y} - \hat{\alpha} \bar{x} = & (1 + 1) \\ &= 23.962612 & &= 203.9719 & (\frac{1}{2} + \frac{1}{2})\end{aligned}$$

$$\text{Regresijski pravac: } y = 23.963x + 203.97 \quad (1)$$

$$(b) \text{ 95\% pouzdani interval za } \alpha: \hat{\alpha} \pm t_{0.025}(10) \hat{\sigma} \sqrt{\frac{1}{S_{xx}}}. \quad (1)$$

$$\text{Iz tablice za } t\text{-razdiobu: } t_{0.025}(10) = 2.228. \quad (1)$$

$$\text{SSE} = S_{yy} - \hat{\alpha}^2 S_{xx} = 90016.61 \quad (\frac{1}{2} + \frac{1}{2})$$

$$\hat{\sigma}^2 = \frac{\text{SSE}}{n-2} = \frac{90016.61}{10} = 9001.661 \Rightarrow \hat{\sigma} = 94.877 \quad (\frac{1}{2} + \frac{1}{2})$$

Dakle, opaženi 95% pouzdani interval je:

$$23.963 \pm 2.228 \cdot 94.88 \cdot \sqrt{\frac{1}{522.37}} = 23.963 \pm 9.249. \quad (1)$$

(c) Budući da se nula ne nalazi u 95% pouzdanom intervalu za α , odbacujemo nulhipotezu $H_0 : \alpha = 0$ u odnosu na dvostranu alternativu uz razinu značajnosti od 5%. (3)

(d) Procjena za $\mathbb{E}[Y|50]$: $\hat{\mathbb{E}}[Y|50] = 23.963 \cdot 50 + 203.97 = 1402.10$.

$$\text{95\% pouzdani interval: } \hat{\mathbb{E}}[Y|50] \pm t_{0.025}(10) \hat{\sigma} \sqrt{\frac{1}{12} + \frac{(50-\bar{x})^2}{S_{xx}}}. \quad (1)$$

$$\text{Opaženi 95\% pouzdani interval: } 1402.10 \pm 88.77. \quad (1)$$

(e) Model je

$$Y_i = \alpha x_i + \beta + \varepsilon_i, \quad i = 1, 2, \dots, n,$$

gdje su α, β parametri modela, a $\varepsilon_i, i = 1, 2, \dots, n$, su slučajne varijable (slučajne greške) (1)

za koje smo pretpostavili da su:

- (i) centrirane ($\mathbb{E}[\varepsilon_i] = 0$ za sve i) (1/2)
 - (ii) jednake varijance ($\text{Var}[\varepsilon_i] = \sigma^2$ za sve i) (1/2)
 - (iii) nekorelirane ($\text{cov}[\varepsilon_i, \varepsilon_j] = 0$ za sve $i \neq j$) (1/2)
 - (iv) normalno distribuirane. (1/2)
-
- (20)