

Ústav matematiky a statistiky
Přírodovědecká fakulta
Masarykova univerzita

Štatistická inferencia II

Zadania domácich úloh

Stanislav Katina

katina@math.muni.cz

6. mája 2015

Inštrukcie k DÚ: Odovzdáva sa jeden pdf súbor nazvaný priezvisko-meno-text-statinf-II-2015.pdf (obsahuje riešenia príkladov, obrázky, \mathbb{R} -kód napísaný v $\text{T}_{\text{E}}\text{X}$ u), jeden zdrojový súbor naprogramovaných funkcií priezvisko-meno-source-statinf-II-2015.r a jeden súbor \mathbb{R} -kódu konkrétnych zadaní z DÚ priezvisko-meno-priklady-statinf-II-2015.r, ktorý používa tento zdrojový kód. Na písanie \mathbb{R} -kódu odporúčam $\text{T}_{\text{E}}\text{X}$ balíček listings a vytvoreniu prostredia v hlavičke dokumentu ako

```

1 \lstset{language=R, % nastavenie jazyka R
2 basicstyle=\footnotesize\ttfamily, % typ pisma R-kodu
3 commentstyle=\ttfamily\color{farba1}, % farba komentara k funkciam
4 numberstyle=\color{farba2}\footnotesize, % farba a velkost cislovania
5 numbers=left, % cislovanie vľavo
6 stepnumber=1, % cislovanie po krokoch jedna
7 frame=leftline, % vytvorenie ľavej hranicnej ciary
8 breaklines=true} % zalomenie riadkov

```

a potom v texte medzi begin a end.

DÚ je potrebné odovzdať 7 dní pred termínom skúšky, na ktorý sa prihlásite.

Príklad 1 (odvodenie testovacích štatistík) Nech $X \sim N(\mu, \sigma^2)$, kde σ^2 je naznáma. Majme $H_{01} : \mu = \mu_0$ vs. $H_{11} : \mu \neq \mu_0$. Odvodte testovacie štatistiky
(1) U_W použitím $U_W = (\hat{\theta} - \theta_0)^T \mathcal{I}(\hat{\theta}) (\hat{\theta} - \theta_0)$ a
(2) U_S použitím $U_S = (S(\theta_0))^T (\mathcal{I}(\theta_0))^{-1} S(\theta_0)$.

Za platnosti H_0 je pravdepodobnosť teoretickej CHPD rovná

$$\alpha_W = \Pr(U_W \geq \chi_{n-1}^2(\alpha)) = \Pr\left(F_{1,n-1} \geq \frac{n-1}{n} \chi_{n-1}^2(\alpha)\right),$$

$$\alpha_{LR} = \Pr(U_{LR} \geq \chi_{n-1}^2(\alpha)) = \Pr\left(F_{1,n-1} \geq (n-1) \left[\exp\left(\frac{\chi_{n-1}^2(\alpha)}{n}\right) - 1\right]\right)$$

a

$$\alpha_S = \Pr(U_S \geq \chi_{n-1}^2(\alpha)) = \Pr\left(F_{1,n-1} \geq \frac{n-1}{n - \chi_{n-1}^2(\alpha)} \chi_{n-1}^2(\alpha)\right),$$

Príklad 2 (pravdepodobnosť teoretickej CHPD pri danom n) Odvodte pravdepodobnosti
(1) α_W , (2) α_{LR} a (3) α_S .

Príklad 3 (Fisherova miera informácie) Vypočítajte Fisherovu mieru informácie $\mathcal{I}(g(\hat{p}))$, kde
(a) $g(p) = \ln \frac{p}{1-p}$ a (b) $g(p) = \arcsin(\sqrt{p})$.

Príklad 4 (Fisherova miera informácie) Porovnajte DIS pre p použitím (a) Waldovho DIS, (b) vierohodnostného DIS, (c) skóre DIS, (d) transformovaného Waldovho DIS pre $g(p) = \frac{p}{1-p}$, (f) transformovaného Waldovho DIS pre $g(p) = \ln \frac{p}{1-p}$, (g) transformovaného Waldovho DIS pre $g(p) = \arcsin(\sqrt{p})$, kde (1) $N = 1400$ a $p = 0.05$, (2) $N = 40$ a $p = 0.05$, (3) $N = 1400$ a $p = 0.25$, (4) $N = 40$ a $p = 0.25$, (5) $N = 1400$ a $p = 0.5$, (6) $N = 40$ a $p = 0.5$.

Príklad 5 (Fisherova miera informácie) Majme dvojrozmerné normálne rozdelenie. Odvodte pozorovanú Fisherovu informačnú maticu $\mathcal{I}(\hat{\boldsymbol{\theta}})$, kde $\hat{\boldsymbol{\theta}} = (\hat{\mu}_1, \hat{\mu}_2, \hat{\sigma}_1^2, \hat{\sigma}_2^2, \hat{\rho})^T$. Pomocou nej vypočítajte rozptyly jednotlivých elementov $\hat{\boldsymbol{\theta}}$.

Príklad 6 (pravdepodobnosť pokrytia) Nech $X_i \sim \text{Bin}(N, p_i)$. Vypočítajte pravdepodobnosti pokrytia:

(a) vierohodnostného 95% DIS a (b) spätne transformovaného Waldovho 95% DIS pre $g(p_i)$ s hranicami $(d_g^{(i)}, h_g^{(i)})$ na Waldov 95% DIS pre p_i s hranicami $((g(d_g^{(i)}))^{-1}, (g(h_g^{(i)}))^{-1})$, kde (1) $g(p_i) = \frac{p_i}{1-p_i}$, (2) $g(p_i) = \ln \frac{p_i}{1-p_i}$ a (3) $g(p_i) = \arcsin(\sqrt{p_i})$ pre každé p_i , kde p_i patria množine $\mathcal{M}_I = \langle \frac{1}{N}, 1 - \frac{1}{N} \rangle$, sú ekvidistantne vzdialené medzi $\frac{1}{N}$ a $1 - \frac{1}{N}$ a ich počet $M = 5000$. Nakreslite obrázok, kde na x-ovej osi budú p_i a na y-ovej osi pravdepodobnosť pokrytia $\text{Pr}_i(\text{pokrytie})$. Zvoľte (a) $N = 30$, (b) $N = 100$ a (c) $N = 1000$. Pozn.: pravdepodobnosti pokrytia 95% DIS pre p_i vypočítame nasledovne

$$\text{Pr}_i(\text{pokrytie}) = \sum_j \text{Pr}(X = Np_j : p_i \in 95\% \text{ DIS pre } p_j),$$

kde $p_j \in \mathcal{M}_J = \{\frac{1}{N}, \frac{2}{N}, \dots, 1 - \frac{1}{N}\}$, t.j. ide o súčet takých funkčných hodnôt pravdepodobnostnej funkcie v bodoch Np_j , kde $p_i \in 95\% \text{ DIS pre } p_j$. Pre tie DIS, ktoré majú pre $p = 0$ a $p = 1$ nenulovú šírku, môžeme použiť $\mathcal{M}_I = \langle \frac{0}{N}, \frac{N}{N} \rangle$.

Príklad 7 (test o pomere šancí) Majme dáta *two-samples-probabilities-sexratio.txt*, premennú počet starších súrodencov *o.sib.N* a pohlavie *sex*. Predpokladáme, že početnosť chlapcov, ak nemajú staršieho súrodenca, $X_{m,0} \sim \text{Bin}(N_{m,0}, p_{m,0})$; početnosť chlapcov, ak ho majú, $X_{m,1} \sim \text{Bin}(N_{m,1}, p_{m,1})$; početnosť dievčat, ak nemajú staršieho súrodenca, $X_{f,0} \sim \text{Bin}(N_{f,0}, p_{f,0})$; početnosť dievčat, ak ho majú, $X_{f,1} \sim \text{Bin}(N_{f,1}, p_{f,1})$. (a) Otestujte hypotézu o pomere šancí narodenia chlapca (ak nemá staršieho súrodenca voči situácii, že ho má) použitím testu pomerom vierohodnosti na hladine významnosti $\alpha = 0.05$. (b) Vypočítajte $100 \times (1 - \alpha)\%$ empirický DIS pre tento pomer šancí pomocou metodiky 15% cut-off štandardizovanej (profilovej) funkcie vierohodnosti, kde koeficient spoľahlivosti $1 - \alpha = 0.95$. (c) Nakreslite funkciu vierohodnosti ako aj profilovú funkciu vierohodnosti a DIS.

Aproximácia binomického rozdelenia Poissonovým rozdelením. Nech $X_j \sim \text{Bin}(N_j, p_j)$, $j = 1, 2$, kde p_j sú veľmi malé čísla a N_j sú veľké čísla. Parametrom záujmu je relatívne riziko $\theta = p_1/p_2$. Preto môžeme predpokladať, že $X_1 \sim \text{Poiss}(\lambda_1)$, $\lambda_1 = N_1 p_1$ a $X_2 \sim \text{Poiss}(\lambda_2)$, $\lambda_2 = N_2 p_2$. Tiež môžeme situáciu zjednodušiť použitím $N_1 \approx N_2$. Potom funkcia vierohodnosti bude mať tvar

$$L(\boldsymbol{\theta} | \mathbf{x}_1, \mathbf{x}_2) = e^{-(N_1 p_1 + N_2 p_2)} (N_1 p_1)^{n_1} (N_2 p_2)^{n_2} = c e^{-p_2(N_1 \theta + N_2)} \theta^{n_1} p_2^{n_1 + n_2}$$

kde $\boldsymbol{\theta} = (\theta, p_2)^T$, $c = N_1^{n_1} N_2^{n_2}$ (maximalizácia $L(\boldsymbol{\theta} | \mathbf{x}_1, \mathbf{x}_2)$ nezávisí na c) a profilova funkcia vierohodnosti

$$L(\theta | \mathbf{x}_1, \mathbf{x}_2) = \left(\frac{N_1 \theta}{N_1 \theta + N_2} \right)^{n_1} \left(1 - \frac{N_1 \theta}{N_1 \theta + N_2} \right)^{n_2}.$$

Príklad 8 (maximálne vierohodné odhady; nové liek vs. placebo) Predpokladajme, že početnosť subjektov s infarktomyokardu (IM) X_1 v skupine A (nový liek) má binomické rozdelenie s parametrami N_1 a p_1 , t.j. $X_1 \sim \text{Bin}(N_1, p_1)$, a počet subjektov s IM v skupine B (placebo) má tiež binomické rozdelenie s parametrami N_2 a p_2 , t.j. $X_2 \sim \text{Bin}(N_2, p_2)$. Pozorovali sme $n_1 = 139$ z celkového

počtu $N_1 = 11037$ subjektov a $n_2 = 239$ z celkového počtu $N_2 = 11034$ subjektov. Keďže N_1 a N_2 sú vysoké čísla a pravdepodobnosti IM malé čísla, môžeme predpokladať, že $X_1 \sim \text{Poiss}(\lambda_1)$, $\lambda_1 = N_1 p_1$ a $X_2 \sim \text{Poiss}(\lambda_2)$, $\lambda_2 = N_2 p_2$. Zjednodušíme situáciu použitím $N_1 \approx N_2$. (a) Aplikujte funkciu vierohodnosti $L(\boldsymbol{\theta} | \mathbf{x}_1, \mathbf{x}_2)$, kde $\boldsymbol{\theta} = (\theta, p_2)^T$ a relatívne riziko $\theta = p_1/p_2$ na dáta v tabuľke – pre (1) IM ako aj (2) pre mozgovú mŕtvicu (MM). (b) Nakreslite profilové funkcie vierohodnosti pre každú skupinu. (c) Vypočítajte vierohodnostný 95% DIS pre (1) θ_{IM} a (2) θ_{MM} pomocou metodiky 15% cut-off štandardizovanej funkcie vierohodnosti.

Tabuľka 1: Početnosti subjektov s infarktomyokardu a mozgovou mŕtvicou v skupine A a B

skupina	IM	MM	spolu
skupina A	139	119	11037
skupina B	239	98	11034