

Analýza prežívania

Zlyhávanie a cenzúrovanie, funkcia vierohodnosti, základné charakteristiky a ich odhady, intervale a pásy spoloahlivosti

Stanislav Katina¹

¹Ústav matematiky a statistiky
Přírodovědecká fakulta
Masarykova univerzita

ZS 2013



Stanislav Katina

Analýza prežívania

Aké otázky v analýze prežívania riešime?

Príklady z praxe

- Odhadujeme a interpretujeme funkciu prežívania a riziko
- Porovnávame funkcie prežívania a riziká
- Modelujeme vzťah medzi vysvetľujúcimi premennými a časom prežívania

Poděkování

Tento učební text vznikl za přispění Evropského sociálního fondu a státního rozpočtu ČR prostřednictvím Operačního programu Vzdělávání pro konkurenceschopnost v rámci projektu Univerzitní výuka matematiky v měnícím se světě

(CZ.1.07/2.2.00/15.0203)

Stanislav Katina

Analýza prežívania

Otázky v analýze prežívania v aplikáciách

Príklady z praxe

Prežívanie pacientov po infarkte myokardu (IM) v rámci sekundárnej prevencie závažných kardiovaskulárnych problémov u pacientov s polymorfizmom glykoproteínu IV (GP VI 13254C/T) v membráne krvných doštičiek. [Thrombosis Research 125, 2: 61–4, 2009]

105 pacientov sledovaných v priemere 19(± 10.8) mesiacov

Stanislav Katina

Analýza prežívania

Stanislav Katina

Analýza prežívania

Otázky v analýze prežívania v aplikáciách

Príklady z praxe

Zlyhania: smrť, ďalší IM, ďalšia selektívna koronarografia (SKG: percutaneous coronary intervention (PCI, coronary angioplasty), coronary artery bypass graft (CABG)), ďalšia cievna mozgová príhoda (CMP; stroke), ďalšia hospitalizácia (re-intervencia); sledované kombinácie: smrť/IM/re-intervencia a smrť/IM/re-intervencia/CMP [MACE; Major Adverse Cardiac Events, hlavné nepriaznivé srdcové udalosti]

Adjustujúce (rizikové) premenné:


- ① pohlavie (žena=0, muž=1)
- ② hypertenzia (nie=0, áno=1)
- ③ hyperlipidémia (nie=0, áno=1)
- ④ fajčenie (nefajčiar=0, fajčiar a bývalý fajčiar=1)
- ⑤ diabetes (nie=0, áno=1)
- ⑥ srdcové zlyhanie (NYHA; New York Heart Association; Classes: I = 0; II, III, IV = 1)

Stanislav Katina

Analýza prežívania

Otázky v analýze prežívania v aplikáciách

Príklady z praxe



Stanislav Katina

Analýza prežívania

Otázky v analýze prežívania v aplikáciách

Príklady z praxe

Analýza prežívania implantátov bedra a kolena na Slovensku v rokoch 2003–2011. [Acta Chir. Orthop. Traum. Čech. 80: 1–85, 2013]

49 668 operácií (primárnych operácií a revízií) zo všetkých slovenských ortopedických kliník za roky 2003–2011:

- 38 485 THA (Total Hip Arthroplasty)
- 11 183 TKA (Total Knee Arthroplasty)

Stanislav Katina

Analýza prežívania

Otázky v analýze prežívania v aplikáciách

Príklady z praxe

Zlyhania: zlyhanie komponentu implantátu

Adjustujúce (rizikové, prognostické) premenné:

- ① typ komponentu (acetabulárny=0, femorálny=1)
- ② fixácia komponentu (necementovaný=0, cementovaný=0)
- ③ pohlavie (žena=0, muž=1)
- ④ cementovacia technika (necementovaný=0, generácia cementu I = 1, generácia cementu II = 2, generácia cementu III = 3)
- ⑤ diagnóza pri primárnej operácii (primárna coxarthroza = 1, dysplastická coxarthroza = 2, poúrazová coxarthroza = 3, aseptická nekróza hlavy = 4, M.Perthes = 5, reumatoïdná artritída = 6, zlomenina krčku = 7)
- ⑥ dôvod revízie (spolu 18 dôvodov)
- ⑦ revidované časti (spolu 19 častí) a pod.

Stanislav Katina

Analýza prežívania

Prežívanie pacientov s chronickou myeloidnou leukémiou (CML). [Neoplasma, 92, 5: 381–7, 2005]

589 pacientov s CML, z ktorých 78 absolvovalo transplantáciu krvotvorných kmeňových buniek kostnej drene (allogeneic transplantation; *transplantácia od HLA-identického súrodenca alebo nepríbuzného darcu*; HLA znamená human leukocyte antigen) a zároveň majú odobrané vzorky periférnej krvi a kostnej drene pred a po transplantácii na Katedre genetiky Národného onkologického ústavu v Bratislave v rokoch 1990 až 2002

Stanislav Katina

Analýza prežívania

Klasický prístup vs. analýza prežívania

Príklady

Example

Akútnej myelogénnej leukémii (acute myelogenous leukemia, AML). Po absolvovaní chemoterapie a zmiernení príznakov, boli pacienti náhodne rozdelení do dvoch skupín. Prvá skupina (skupina A) dostala udržujúcu chemoterapiu a druhá (kontrolná; skupina B) nie. Cieľom bolo zistiť, či udržujúca chemoterapia predĺžuje čas do remisie (opäťovného zhoršenia stavu).

Stanislav Katina

Analýza prežívania

Zlyhania: úmrtie pacienta

Adjustujúce (prognostické, rizikové) premenné:

- ① vek pacienta v čase transplantácie (skupina 1: <20 rokov, skupina 2: [20,40), skupina 3: ≥ 40)
- ② fáza CML (spolu dve fázy; prvá chronická fáza = 1, ďalšie chronické fázy = 2)
- ③ pohlavie darcu a príjemcu (m–m, m–ž, ž–m, ž–ž)
- ④ čas od diagnózy po transplantácii (< 1 rok, ≥ 1 rok)

Stanislav Katina

Analýza prežívania

Klasický prístup vs. analýza prežívania

Príklady

| Sk | čas po kompletnej remisiu (v týždňoch) | n | udalosti | cenzúr |
|----|--|----|----------|--------|
| A | 9, 13, 13+, 18, 23, 28+, 31, 34, 45+, 48, 161+ | 11 | 7 | 4 |
| B | 5, 5, 8, 8, 12, 16+, 23, 27, 30, 33, 43, 45 | 12 | 11 | 1 |

(číslo = čas do zlyhania, číslo a plus (+) = čas do cenzúry)

Stanislav Katina

Analýza prežívania

Klasický prístup vs. analýza prežívania

Tri náhľady na problém analýzy AML dát

- ① **problém 1:** po odstránení cenzúrovaných pozorovaní
- ② **problém 2:** po ošetrení cenzúrovaných pozorovaní, ktoré zoberieme do úvahy akoby boli udalosťami (zlyhaniami)
- ③ **problém 3:** berúc do úvahy cenzúrované pozorovania

Stanislav Katina

Analýza prežívania

Klasický prístup vs. analýza prežívania

Príklady

Example

Cystická fibróza (CF) je autozomálna genetická choroba spôsobená mutáciou génu pre CFTR (cystic fibrosis transmembrane conductance regulator). Postihuje prevažne pluca, ale aj pankreas, pečeň a črevo. V celoslovenskej databáze pacientov CF rozlišujeme pacientov s **jasnou klinickou formou (typická forma,** 259 živých, 112 zomrelých) a pacientov s **atypickou formu** (188 živých). Spolu teda 559 pacientov, 447 živých a 112 zomrelých. Aký je priemerný vek (prežívania) a medián (prežívania) v rokoch?

Klasický prístup vs. analýza prežívania

Príklady

| | problém 1 | | problém 2 | | problém 3 | |
|-------------|-----------|------|-----------|------|-----------|------|
| | A | B | A | B | A | B |
| \bar{x} | 25.1 | 21.7 | 38.5 | 21.3 | 52.6 | 22.7 |
| \tilde{x} | 23.0 | 23.0 | 28.0 | 19.5 | 31.0 | 23.0 |

(čísla sú v týždňoch)

Stanislav Katina

Analýza prežívania

Klasický prístup vs. analýza prežívania

Príklady

| skupina/počty | typická forma CF | atypická forma CF | spolu |
|---------------|------------------|-------------------|-------|
| živí | 259 | 188 | 447 |
| zomrelí | 112 | 0 | 112 |
| spolu | 371 | 188 | 559 |

Stanislav Katina

Analýza prežívania

Stanislav Katina

Analýza prežívania

Klasický prístup vs. analýza prežívania

Príklady

| | problém 1 | problém 3 |
|-------------|------------|------------|
| | typická CF | typická CF |
| \bar{x} | 9.22 | 45.05 |
| \tilde{x} | 4.90 | 52.26 |

(čísla sú v rokoch)

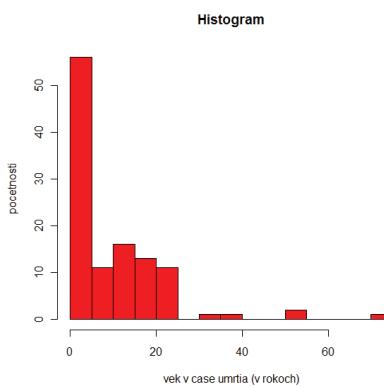
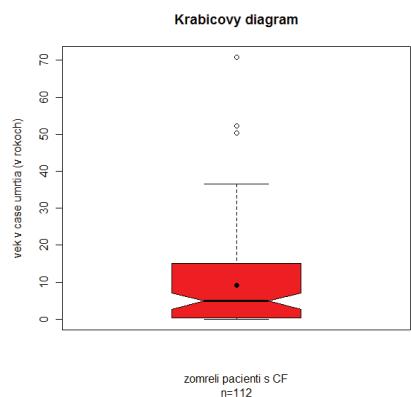
- Rozdiel medzi priemerným vekom prežívania pacientov s typickou formou CF a priemerným vekom zomrelých je **35.83** roka (podobne pre medián je tento rozdiel **47.36** roka)
- 95% IS pre strednú hodnotu je (7.02, 11.41) a pre medián (2.72, 7.08)

Stanislav Katina

Analýza prežívania

Klasický prístup vs. analýza prežívania

Príklady



Stanislav Katina

Analýza prežívania

Klasický prístup vs. analýza prežívania

Príklady

- priemerný vek prežívania pre všetkých pacientov bez rozdielu typu CF je 53.94 ± 2.10 rokov, kde 95% IS je rovný (49.82, 58.06)
- medián prežívania pre všetkých pacientov bez rozdielu typu CF je 70.82 roka; **95% IS pre medián zatiaľ nie je možné vypočítať**
- Priemerný vek prežívania pre pacientov s typickou formou CF je 45.05 ± 2.47 rokov, kde 95% IS je (40.21, 49.89)
- Median prežívania je 52.26 roka, dolna hranica 95% IS pre medián je 36.43 roka; **Hornú hranicu IS pre medián zatiaľ nie je možné vypočítať**

Stanislav Katina

Analýza prežívania

Klasický prístup vs. analýza prežívania


Príklady

Tabuľka: Početnosti zomrelých v päťročných vekových intervaloch ($n = 112$). Označenia: vekové intervale (zdola je interval otvorený a zhora uzavretý, okrem prvého, ktorý je aj zdola uzavretý): $I_1 = \langle 0, 5 \rangle$, $I_2 = (5, 10]$, $I_3 = (10, 15]$, $I_4 = (15, 20)$, $I_5 = (20, 25)$, $I_6 = 25, \max(\text{vek})$.

| vekové intervale | I_1 | I_2 | I_3 | I_4 | I_5 | I_6 |
|------------------|-------|-------|--------|--------|-------|-------|
| početnosti | 56 | 11 | 16 | 13 | 11 | 5 |
| percentá | 50% | 9.82% | 14.29% | 11.61% | 9.82% | 4.46% |

Stanislav Katina

Analýza prežívania



Stanislav Katina

Analýza prežívania

Udalosť

Úvodné definície

Udalosť: ukončenie pozorovania z dôvodu zlyhania alebo smrti pacienta – do konca sledovaného obdobia

Príklady udalostí:

- **overall survival** – smrť z akéhokoľvek dôvodu
- **progression-free survival** – prvé znaky progresie choroby alebo smrť
- **disease-free survival** – prvé znovaobjavenie sa choroby alebo smrť
- **event-free survival** – prvé znovaobjavenie sa choroby, objavenie sa inej špecifikovej choroby alebo smrť
- **disease-specific survival (cause-specific survival)** – smrť ako dôsledok špecifikovej choroby
- **relapse-free survival (recurrence-free survival)** – prvé znaky recidívy (opakovania sa) chodoby
- **time-to-progression** – prvé znaky progresie choroby

Stanislav Katina

Analýza prežívania

Ďalšie možné otázky

Zlyhanie: smrť

Adjustujúce (prognostické) premenné: antropologické ukazovatele, funkčné charakteristiky plúc a pod.

Stanislav Katina

Analýza prežívania

Cenúrovanie

Úvodné definície

Cenzúra: ukončenie pozorovania z dôvodu iného ako je zlyhanie alebo smrť pacienta – do konca sledovaného obdobia dôjde k úmrtiu len niektorých pacientov, zatiaľ čo u ostatných k úmrtiu do konca sledovaného obdobia buď nedôjde alebo sa tito pacienti z pozorovania stratia

Príklady cenúr:

- **ukončenie štúdie (termination of the study):** pacient prežije časový interval experimentu
- **konkurenčné riziko (competing risk):** pacient zomrie z iného dôvodu, ako v dôsledku sledovanej choroby
- **prerušenie/vysadenie liečby (drop-out):** pacient preruší liečbu a odíde z kliniky predčasne, napr. z dôvodu zlých vedľajších účinkov liečby, pacient sa sám rozhodne nepokračovať v liečbe
- **strata z ďalšieho sledovania (loss to follow-up):** pacient sa rozhodne prestahovať a nemáme o ňom už žiadne informácie

Stanislav Katina

Analýza prežívania

Cenúrovanie

Cenzúrovanie I. typu

Základné princípy:

- ① predpoklad – všetkých n jedincov vstupuje do experimentu súčasne
- ② príčina cenzúrovania – plánované ukončenie experimentu
- ③ ide o **cenzúrovanie časom** – zvolíme pevné číslo t_c , ktoré nazveme *fixovaný cenzurujúci čas*
- ④ $T^{(1)} < T^{(2)} < \dots < T^{(d)}$, kde $T^{(d)} < t_c < T^{(d+1)}$
- ⑤ **náhodná veličina** – počet skutočne pozorovaných zlyhaní
 $d \in \{0, 1, \dots, n\}$
- ⑥ pozorujeme X_1, X_2, \dots, X_n , kde

$$X_i = \min(T_i, t_c) = \begin{cases} T_i, T_i \leq t_c, & \text{pre necenzúrované } X_i \\ t_c, T_i > t_c, & \text{pre cenzúrované } X_i \end{cases}$$

- ⑦ skutočnému pozorovaniu potom zodpovedá náhodný vektor (X_i, δ_i) , kde

$$\delta_i = \begin{cases} 1, T_i \leq t_c, & \text{pre necenzúrované } X_i \\ 0, T_i > t_c, & \text{pre cenzúrované } X_i \end{cases}$$

Stanislav Katina

Analýza prežívania

Cenúrovanie

Progresívne (zrýchlené) cenzúrovanie I. typu

Základné princípy:

- ① predpoklad – všetkých n jedincov vstupuje do experimentu súčasne
- ② príčina cenzúrovania – plánované ukončenie experimentu
- ③ ide o **cenzúrovanie zlyhaním** – zvolíme čísla t_{ci} , $i = 1, 2, \dots, k$, ktoré nazveme *fixované cenzurujúce časy*, v čase t_{ci} vyradíme m_i subjektov
- ④ $t_{c1} < t_{c2} < \dots < t_{ck}$
- ⑤ v čase t_{c1} vyradíme m_1 subjektov, v čase t_{c2} vyradíme m_2 subjektov, ..., v čase t_{ck} vyradíme m_k subjektov
- ⑥ po k -tom kroku máme vyradených $m_1 + m_2 + \dots + m_k$ subjektov
- ⑦ **náhodná veličina** – počet skutočne pozorovaných zlyhaní
 $d \in \{0, 1, \dots, n\}$

Stanislav Katina

Analýza prežívania

Cenúrovanie

Cenzúrovanie II. typu

Základné princípy:

- ① predpoklad – všetkých n jedincov vstupuje do experimentu súčasne
- ② príčina cenzúrovania – plánované ukončenie experimentu
- ③ ide o **cenzúrovanie zlyhaním** – zvolíme si pevné číslo d , ktoré nazveme *fixovaný počet zlyhaní*; ukončenie teda nastáva po vopred zvolenom počte d zlyhaní, kde $d = [np] + 1$, $p \in (0, 1)$
- ④ $X_1 = T^{(1)}, X_2 = T^{(2)}, \dots, X_d = T^{(d)}, X_{d+1} = T^{(d)}, \dots, X_n = T^{(d)}$
- ⑤ **náhodná veličina** – čas trvania experimentu
- ⑥ pozorujeme X_1, X_2, \dots, X_n , kde

$$X_i = \min(T_i, T^{(d)}) = \begin{cases} T_i, T_i \leq T^{(d)}, & \text{pre necenzúrované } X_i \\ T^{(d)}, T_i > T^{(d)}, & \text{pre cenzúrované } X_i \end{cases}$$

- ⑦ skutočnému pozorovaniu potom zodpovedá náhodný vektor (X_i, δ_i) , kde

$$\delta_i = \begin{cases} 1, T_i \leq T^{(d)}, & \text{pre necenzúrované } X_i \\ 0, T_i > T^{(d)}, & \text{pre cenzúrované } X_i \end{cases}$$

Stanislav Katina

Analýza prežívania

Cenúrovanie

Progresívne (zrýchlené) cenzúrovanie II. typu

Základné princípy:

- ① predpoklad – všetkých n jedincov vstupuje do experimentu súčasne
- ② príčina cenzúrovania – plánované ukončenie experimentu
- ③ ide o **cenzúrovanie časom** – zvolíme čísla d_i , ktoré nazveme *fixované počty zlyhaní*; vyradenie teda nastáva po vopred zvolenom počte d_i zlyhaní, kde $d_i = [np_i] + 1$, $p_i \in (0, 1)$
- ④ po d_1 zlyhaniach vyradíme m_1 subjektov, po d_2 zlyhaniach vyradíme m_2 subjektov, ..., po d_k zlyhaniach vyradíme m_k subjektov
- ⑤ po k -tom kroku máme vyradených $m_1 + m_2 + \dots + m_k$ subjektov
- ⑥ **náhodná veličina** – čas trvania experimentu

Stanislav Katina

Analýza prežívania

Cenúrovanie

Náhodné a ľubovoľné cenzúrovanie

Základné princípy:

- 1 predpoklad – n jedincov nevstupuje do experimentu súčasne
- 2 čas do zlyhania T_1, T_2, \dots, T_n sú nezávislé, rovnako rozdelené náhodné premenné, kde náhodná veličina T_i ($i = 1, \dots, n$) má hustotu $f(t)$ a distribučnú funkciu $F(t)$
- 3 čas do cenzúrovania C_1, C_2, \dots, C_n sú nezávislé, rovnako rozdelené náhodné premenné, kde náhodná veličina C_i ($i = 1, \dots, n$) má hustotu $g(t)$ a distribučnú funkciu $G(t)$
- 4 pozorujeme X_1, X_2, \dots, X_n , kde

$$X_i = \min(T_i, C_i) = \begin{cases} T_i, & T_i \leq C_i, \text{ pre necenzúrované } X_i \\ C_i, & T_i > C_i, \text{ pre cenzúrované } X_i \end{cases}$$

- 5 skutočnému pozorovaniu potom zodpovedá náhodný vektor (X, δ) , kde $X_i = \min(T_i, C_i)$ a

$$\delta_i = \begin{cases} 1, & T_i \leq C_i, \text{ pre necenzúrované } X \\ 0, & T_i > C_i, \text{ pre cenzúrované } X \end{cases}$$

- 6 náhodná veličina – čas trvania experimentu a čas do cenzúry (ak $C_i = c$, ide o ľubovoľné cenzúrovanie)

Stanislav Katina

Analýza prežívania

Cenúrovanie

Intervalové cenzúrovanie II. typu

Základné princípy:

Majme opäť n subjektov. Označme $T_i, i = 1, 2, \dots, n$, nepozorovateľné časy zlyhania. Vieme len, že T_i nastalo buď vnútri nejakého náhodného časového intervalu, pred jeho ľavou hranicou alebo po jeho pravej hranici. Označme C_{1i} a C_{2i} časy dvoch vyšetrení a indikačné funkcie definujeme nasledovne

$$\delta_{1i} = I(T_i \leq C_{1i}), \quad \delta_{2i} = I(C_{1i} < T_i \leq C_{2i}) \text{ a } \delta_{3i} = I(T_i > C_{2i}), \text{ t.j.}$$

$$\delta_{1i} = \begin{cases} 1, & T_i \leq C_{1i}, \text{ pre necenzúrované } X_i \\ 0, & T_i > C_{1i}, \text{ pre cenzúrované } X_i \end{cases},$$

$$\delta_{2i} = \begin{cases} 1, & C_{1i} < T_i \leq C_{2i}, \text{ pre necenzúrované } X_i \\ 0, & T_i > C_{2i}, \text{ pre cenzúrované } X_i \end{cases}$$

a nakoniec $\delta_{3i} = 0$.

Example (nádor plúc, pacienti)

Pacienti navštevovali kliniku opakovane každých 4 až 6 mesiacov, kde pozorovania sú buď intervaly (C_{1i}, C_{2i}) ak sa retrakcia prsníka vyskytla medzi poslednými dvoma návštuvami alebo (C_{2i}, ∞) , ak sa do C_{2i} retrakcia nevyskytla.

Stanislav Katina

Analýza prežívania

Cenúrovanie

Intervalové cenzúrovanie I. typu

Základné princípy:

Majme n subjektov. Označme $T_i, i = 1, 2, \dots, n$, nepozorovateľné časy zlyhania. Skutočnému pozorovaniu potom zopovedá náhodný vektor (C_i, δ_i) , kde C_i sú časy cenzúr a $\delta_i = I(T_i \leq C_i)$, t.j.

$$\delta_i = \begin{cases} 1, & T_i \leq C_i, \text{ pre necenzúrované } X_i \\ 0, & T_i > C_i, \text{ pre cenzúrované } X_i \end{cases}$$

Example (nádor plúc, animálny model)

Laboratórne myši sú injektované látkou, ktorá spôsobuje nádor. Kedže tento druh nádoru nie je smreťný, je potrebné myš najprv zabíti, aby sme zistili, či bol nádor indukovaný, t.j. po časovom úseku náhodnej dĺžky C je myš zabítá, aby sme zistili, či sa nádor vyvinul alebo nie. **Endpoint záujmu** je čas T do objavenia sa nádoru.

Stanislav Katina

Analýza prežívania

Cenúrovanie

Intervalové cenzúrovanie II. typu

Základné princípy:

Máme nasledovné tri možnosti:

- 1 udalosť mohla nastať niekedy pred prvým vyšetrením C_{1i} , kde $\delta_{1i} = 1$ a $\delta_{2i} = \delta_{3i} = 0$,
- 2 udalosť mohla nastať niekedy medzi prvým a druhým vyšetrením, t.j. v intervale (C_{1i}, C_{2i}) , kde $\delta_{1i} = 0$, $\delta_{2i} = 1$ a $\delta_{3i} = 0$,
- 3 udalosť sa do druhého vyšetrenia nevyskytla, t.j. mohla nastať niekedy po C_{2i} (ale nevieme kedy), kde $\delta_{1i} = 0$, $\delta_{2i} = 0$ a $\delta_{3i} = 0$.

Nech $X_{1i} = C_{1i}$ a $X_{2i} = C_{2i}$. Skutočnému pozorovaniu potom zopovedá náhodný vektor

$$(X_{1i}, X_{2i}, \delta_{1i}, \delta_{2i}).$$

Všimnime si, že δ_{3i} nie je potrebné použiť, pretože nemáme ďalšie vyšetrenie po C_{2i} . Keby sme mali C_{3i} alebo aj ďalšie (po ňom nasledujúce) vyšetrenia, hovorili by sme **zovšeobecnenom intervalovom cenzúrovaní**.

Stanislav Katina

Analýza prežívania

Cenúrovanie

Funkcia vierochnosti – pravé typy cenúrovania

1 cenzúrovanie I. typu

$$L = \prod_{i=1}^n f(x_i)^{\delta_i} \times S_f(t_c)^{1-\delta_i}$$

2 cenzúrovanie II. typu

$$L = \frac{n!}{(n-d)!} f(t_{(1)})f(t_{(2)}) \dots f(t_{(d)}) \times S_f(t_{(d)})^{n-d}$$

3 náhodné cenúrovanie

$$L = \prod_{i=1}^n f(x_i)^{\delta_i} S_f(x_i)^{1-\delta_i} = \prod_{i=1}^n \lambda(x_i)^{\delta_i} S_f(x_i)$$

Stanislav Katina

Analýza prežívania

Označenia

Časy do zlyhania

Definition

Majme neusporiadane časy t_1, t_2, \dots, t_n . Zoradené časy zapíšeme ako $t_{(1)}, t_{(2)}, \dots, t_{(n)}$. Pokiaľ predpokladáme, že t_1, t_2, \dots, t_n sú už zoradené, t.j. $t_1 < t_2 < \dots < t_n$, označenia v ďalšom teste sa týmto preznačením zjednodušia. Potom $t_n = t_{\max}$. Ak $t_{\max} < c_{\max}$, potom bez straty na všeobecnosti bude $t_n = c_{\max}$ (pozri aj výpočet strednej hodnoty času prežívania, kde je potrebné situáciu $t_{\max} < c_{\max}$ zohľadniť). V časoch cenzúr c sú hodnoty $S(c)$ a $\Lambda(c)$ – ako aj ostatných charakteristik – identické ich hodnotám v najbližšom čase zlyhania t , ktorý predchádza c . Preto, bez straty na všeobecnosti, uvažujeme n zoradených časov, v ktorých sa charakteristiky prežívania počítajú. Tieto časy označujeme t_1, t_2, \dots, t_n . Ak máme v časoch t_i zhody, t.j. $t_1 \leq t_2 \leq \dots \leq t_n$, potom počet rôznych časov bude $l \leq n$ a $t_l = t_{\max}$.

Stanislav Katina

Analýza prežívania

Cenúrovanie

Funkcia vierochnosti – intervalové cenúrovanie

1 intervalové cenúrovanie I. typu

$$L = \prod_{i=1}^n [S_f(x_i)]^{1-\delta_i} [F(x_i)]^{\delta_i}$$

2 intervalové cenúrovanie II. typu

$$L = \prod_{i=1}^n [F(x_{1i})]^{\delta_{1i}} [F(x_{2i}) - F(x_{1i})]^{\delta_{2i}} [S_f(x_{2i})]^{\delta_{3i}},$$

kde $\delta_{3i} = 1 - \delta_{1i} - \delta_{2i}$

Stanislav Katina

Analýza prežívania

Riziko

Príklady

Example (zadanie z prednášky)

Závislosť hodnoty rizika na jednotkách času.

$$\lambda(t) = \lim_{\Delta t \rightarrow 0^+} \frac{\Pr(t \leq T < t + \Delta t | T \geq t)}{\Delta t}$$

$$\Pr(t \leq T < t + \Delta t | T \geq t) = \frac{1}{4}$$

$$\text{Ak } \Delta t = \frac{1}{3} \text{ dňa, potom } \lambda(t) = \frac{\frac{1}{4}}{\frac{1}{3}} = 0.75 \text{ na deň}$$

$$\text{Ak } \Delta t = \frac{1}{21} \text{ týždňa, potom } \lambda(t) = \frac{\frac{1}{4}}{\frac{1}{21}} = 5.25 \text{ na týždeň}$$

Stanislav Katina

Analýza prežívania

Example (zadanie z prednášky)

Majme náhodný vektor (X_i, δ_i) , definovaný nasledovne (pre nejaku fiktívnu i -tu štatistickú jednotku, t.j. subjekt)

- ① $(X_i, \delta_i) = (3, 0)$, t.j. v čase $X_i = 3$ je cenzúra,
 $N_i(t) = N_i(3) = 0$, $Y_i(3) = Y_i(3) = 1$
 $\rightarrow (N_i(3), Y_i(3)) = (0, 1)$
- ② $(X_i, \delta_i) = (4, 1)$, t.j. v čase $X_i = 4$ je udalosť (zlyhanie),
 $N_i(4) = 1$, $Y_i(4) = 1$, t.j. $(N_i(4), Y_i(4)) = (1, 1)$
- ③ Ak máme viac udalostí: $(N_i(0.5), Y_i(0.5)) = (1, 1)$,
 $(N_i(2), Y_i(2)) = (2, 1)$

Stanislav Katina

Analýza prežívania

Zoznam zadaní príkladov

Example (zadanie z cvičenia)

AML (pokrač.) Vypočítajte empirickú funkciu prežívania pre skupinu A.

| Skupina | čas po kompletnej remisiu (v týždňoch) | n | udalosti | cenzúr |
|-----------|--|----|----------|--------|
| skupina A | 9, 13, 13+, 18, 23, 28+, 31, 34, 45+, 48, 161+ | 11 | 7 | 4 |

Example (zadanie z cvičenia)

AML (pokrač.) Naprogramujte v algoritmus na výpočet empirickej funkcie prežívania a aplikujte ho na skupinu A.

Example (zadanie z cvičenia)

AML (pokrač.) Naprogramujte v algoritmus na výpočet empirickej funkcie prežívania len pre zlyhania (cenzúry nemeberime do úvahy) a aplikujte ho na skupinu A.

Stanislav Katina

Analýza prežívania

Example (domáca úloha)

Nech nezáporná náhodná veličina T je charakterizovaná funkciou prežívania $S(T)$. Nech je k -ty moment, $\mathbb{E}(T^k)$, konečný, $\mathbb{E}(T^k) < \infty$, $k \in \mathbb{N}$. (a) Ukážte, že platí

$$\mathbb{E}(T) = \sum_{t \in \mathbb{N}_0} \Pr(T > t) = \sum_{t \in \mathbb{N}_0} 1 - F(t) = \sum_{t \in \mathbb{N}_0} S(t).$$

Použite pri tom definíciu strednej hodnoty $\mathbb{E}(T) = \sum_{t \in \mathbb{N}_0} t \Pr(t)$ a pomocné tvrdenie

$$\underbrace{1 + 1 + \dots + 1}_{t\text{-krát}} = \sum_{\xi=1}^t 1 = \sum_{\xi=0}^{t-1} 1 = \sum_{\xi < t, \xi \in \mathbb{N}_0} 1.$$

(b) Ukážte, že platí $\mathbb{E}(T) = \int_0^\infty S(t) dt$. Použite pri tom definíciu strednej hodnoty $\mathbb{E}(T) = \int_0^\infty t f(t) dt$, aplikujte vlastnosti súm z DÚ 1A ako aj $\int_0^\infty S(t) dt = \int_0^\infty (\int_0^t 1 dx) S(t) dt$. Výpočet Vám uľahčí metóda per-partes.

(c) Pomocou metódy per-partes ukážte, že $\mathbb{E}(T^k) = k \int_0^\infty t^{k-1} S(t) dt$.

Stanislav Katina

Analýza prežívania

Zoznam zadaní príkladov

Example (zadanie z prednášky)

Odroďte maximálne vierochný odhad funkcie prežívania $\hat{S}_{KM}(t)$.

Example (zadanie z cvičenia)

AML (pokrač.) Naprogramujte v algoritmus na výpočet KM odhadu funkcie prežívania a aplikujte ho na skupinu A.

Example (zadanie z cvičenia)

AML (pokrač.). Výpočtom a graficky porovnajte empirickú funkciu prežívania $S_n(t)$ s KM odhadom funkcie prežívania $\hat{S}_{KM}(t)$ pre skupinu A.

Stanislav Katina

Analýza prežívania

Zoznam zadaní príkladov

Príklady

Example (zadanie z cvičenie)

AML (pokrač.). Výpočtom a graficky porovnajte empirickú funkciu prežívania $S_n(t)$ len pre časy zlyhania (cenzúry nemeberime do úvahy) s KM odhadom funkcie prežívania $\hat{S}_{KM}(t)$ pre skupinu A.

Example (domáca úloha)

Použitím funkcie viero hodnosti $L = \prod_{i=1}^I \lambda_i^{d_i} (1 - \lambda_i)^{n_i - d_i}$ odvoďte maximálne viero hodný odhad $\widehat{\text{Var}}[\widehat{\lambda}_i]$, $i = 1, 2, \dots, I$ a $\widehat{\text{Var}}[\widehat{\Lambda}(t)]$.

Stanislav Katina

Analýza prežívania

Zoznam zadaní príkladov

Príklady

Example (zadanie z cvičenie)

AML (pokrač.). Vypočítajte KM odhad funkcie prežívania $\hat{S}_{KM}(t)$ a 95% IS pre $S(t)$ vo všetkých bodoch t v 1) plain škále, 2) log-škále a 3) log-log škále (pre skupinu A).

Example (domáca úloha)

Ak v náhodnom výbere nie sú cenzúry, skóre testovacia štatistika Z_S má za platnosti H_0 štandardizované normálne rozdelenie $Z_S = \frac{\hat{S}(t) - S(t)}{\sqrt{\frac{S(t)(1-S(t))}{n}}} \sim N(0, 1)$, kde platí $\{S(t) : |z| \leq z_{\alpha/2}\}$. Potom riešením kvadratickej rovnice $\{S(t) : (1 + \frac{z_{\alpha/2}^2}{n})S^2(t) - (2\hat{S}(t) + \frac{z_{\alpha/2}^2}{n})S(t) + \hat{S}(t) \leq 0\}$ bude $100 \times (1 - \alpha)\%$ IS pre $S(t)$. Odvoďte tento interval a upravte ho do podoby: vzorec pre stred IS $\pm z_{\alpha/2} \sqrt{\text{vzorec}}$.

Stanislav Katina

Analýza prežívania

Zoznam zadaní príkladov

Príklady

Example (zadanie z cvičenie)

AML (pokrač.). Vypočítajte rozptyl KM odhadu funkcie prežívania v čase 13 (pre skupinu A). Využite Greenwoodovu formulu.

Example (zadanie z cvičenie)

AML (pokrač.). Vypočítajte odhad rizika $\widehat{\lambda}$, odhad rizika v intervale $t_i \leq t < t_{i+1}$, odhad kumulatívneho rizika $\widehat{\Lambda}_{KM}$ a $\widehat{\Lambda}_{NA}$ spolu s ich rozptylmi $\widehat{\text{Var}}[\widehat{\Lambda}_{KM}]$ a $\widehat{\text{Var}}[\widehat{\Lambda}_{NA}]$ v čase 26 (pre skupinu A).

Example (zadanie z cvičenie)

AML (pokrač.). Nakreslite a porovnajte odhady kriviek prežívania $\hat{S}_{KM}(t)$, $\hat{S}_B(t)$ a $\hat{S}_{FHmodB}(t)$ pre skupinu A.

Stanislav Katina

Analýza prežívania

Zoznam zadaní príkladov

Príklady

Example (zadanie z cvičenie)

AML (pokrač.). Naprogramujte v R algoritmus na výpočet obsahu pod $\hat{S}_{KM}(t)$ krivkou. Aplikujte ho na skupinu A. Porovnajte s aritmetickým priemerom časov do zlyhania a aritmetickým priemerom časov do zlyhania a časov cenzúr.

Example (zadanie z cvičenie)

AML (pokrač.). Vypočítajte priemerný čas prežívania $\widehat{\mu}$ a jeho rozptyl $\widehat{\text{Var}}(\widehat{\mu})$, medián času prežívania $\widetilde{\mu}$ a jeho rozptyl $\widehat{\text{Var}}(\widetilde{\mu})$ (pre skupinu A). Porovnajte s necenzurovaným mediánom.

Example (zadanie z cvičenie)

Naprogramujte v R funkciu na výpočet kvantilov času prežívania t_p a ich $100 \times (1 - \alpha)\%$ intervalov spoľahlivosti.

Stanislav Katina

Analýza prežívania

Zoznam zadaní príkladov

Príklady

Example (zadanie z cvičenie)

(a) Naprogramujte v R funkcie na výpočet nasledovných odhadov funkcií prežívania $\hat{S}_{KM}(t)$, $\hat{S}_{KMmod}(t)$, $\hat{S}_B(t)$ a $\hat{S}_{FHmodB}(t)$, kde

- ① $\hat{S}_{KMmod}(t) = \prod_{i:t_i \leq t} \left(1 - \frac{1}{n_i}\right)$ [pre nerozsekané a aj rozsekané zhody]
- ② $\text{Var}[\hat{S}_{KM}(t)]$, dolnú (DH) a hornú (HH) hranicu 95% IS v log-škále,
- ③ $\hat{S}_B(t) = \exp(-\hat{\lambda}_{NA}(t))$ [pre nerozsekané zhody]
- ④ $\hat{S}_{FHmodB}(t) = \exp(-\hat{\lambda}_{FHmodB}(t))$ [pre rozsekané zhody]

(b) Vypočítajte tieto odhady pre dátá (pozri tabuľku)

Stanislav Katina

Analýza prežívania

Zoznam zadaní príkladov

Príklady

Example (zadanie z cvičenie)

AML (pokrač.) Naprogramujte v R algoritmus na výpočet $100 \times (1 - \alpha)\%$ pásov spoľahlivosti pre funkciu prežívania v škále $S(t)$ – (a) Nairov a (b) Hall-Walnerov. Aplikujte na skupinu A. Výsledok porovnajte s IS pre $S(t)$ v škále $S(t)$. Na obrázku zobrazte IS bodovo (zobrazenie, ktoré je prednastavené v R je nesprávne).

Example (domáca úloha)

AML (pokrač.) Naprogramujte v R algoritmus na výpočet $100 \times (1 - \alpha)\%$ pásov spoľahlivosti pre funkciu prežívania v log-log škále – (a) Nairov a (b) Hall-Walnerov. Aplikujte na skupinu A. Výsledok porovnajte s IS pre $S(t)$ v log-log škále. Na obrázku zobrazte IS bodovo (zobrazenie, ktoré je prednastavené v R je nesprávne).

Stanislav Katina

Analýza prežívania

Zoznam zadaní príkladov

Príklady

Example (zadanie z cvičenie; pokrač.)

(c) Naprogramujte v R výpočet počtu cenzúr v čase t_i , ak poznáte d_i a n_i (pozri tabuľku).
(d) Naprogramujte v R funkciu na výpočet odhadu rozptylu funkcie prežívania $\widehat{\text{Var}}[\hat{S}_{KM}(t)]$, dolnú a hornú hranicu 95% IS pre $S(t)$ v log-škále.
(e) Vypočítajte tento odhad a IS pre $S(t)$ pre dátá (pozri tabuľku).

| t | d_i | n_i |
|------|-------|-------|
| 4.5 | 1 | 70 |
| 11.5 | 2 | 68 |
| 16.0 | 1 | 65 |
| 20.7 | 2 | 55 |
| 20.8 | 1 | 53 |
| 31.0 | 1 | 47 |
| 34.5 | 1 | 45 |
| 46.0 | 1 | 34 |
| 61.0 | 1 | 25 |
| 87.5 | 5 | 15 |

Stanislav Katina

Analýza prežívania

Zoznam zadaní príkladov

Príklady

Example (domáca úloha)

AML (pokrač.) Naprogramujte v R algoritmus na výpočet $100 \times (1 - \alpha)\%$ pásov spoľahlivosti pre kumulatívne riziko v log-log škále – (a) Nairov a (b) Hall-Walnerov. Aplikujte na skupinu A. Výsledok porovnajte s IS pre kumulatívne riziko v log-log škále. Na obrázku zobrazte IS bodovo.

Example (domáca úloha)

AML (pokrač.) Naprogramujte v R algoritmus na výpočet odhadu strednej hodnoty zostatkového života a jej rozptylu a aplikujte ho na skupinu A v čase $t = 30$ týždňov.

Stanislav Katina

Analýza prežívania

Empirická funkcia prežívania

Príklady

Example

AML (pokrač.) Vypočítajte empirickú funkciu prežívania pre skupinu A.

| | čas po kompletnej remisiu (v týždňoch) | n | udalostí | cenzúr |
|---|--|----|----------|--------|
| A | 9, 13, 13+, 18, 23, 28+, 31, 34, 45+, 48, 161+ | 11 | 7 | 4 |

$$S_n(t) = \frac{\#\text{pozorovaní} > t}{n} = \frac{\#\{t_i > t\}}{n} = \frac{\sum_{i=1}^n I(t_i > t)}{n}$$

| t | 0 | 9 | 13 | 18 | 23 | 28 | 31 | 34 | 45 | 48 | 161 |
|--------------------|-------|-------|------|------|------|------|------|------|------|------|------|
| S _n (t) | 11/11 | 10/11 | 8/11 | 7/11 | 6/11 | 5/11 | 4/11 | 3/11 | 2/11 | 1/11 | 0/11 |

Stanislav Katina

Analýza prežívania

Empirická funkcia prežívania a KM odhad

Príklady

Example

AML (pokrač.). Porovnajte empirickú funkciu prežívania S_n(t) s KM odhadom funkcie prežívania $\hat{S}_{KM}(t)$ pre skupinu A.

| | čas po kompletnej remisiu (v týždňoch) | n | udalostí | cenzúr |
|---|--|----|----------|--------|
| A | 9, 13, 13+, 18, 23, 28+, 31, 34, 45+, 48, 161+ | 11 | 7 | 4 |

$$\hat{S}_{KM}(t) = \prod_{i:t_i \leq t} \left[1 - \hat{\lambda}_i \right], \text{ kde } \hat{\lambda}_i = \frac{d_i}{n_i}$$

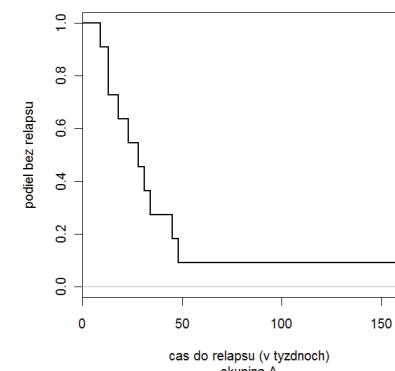
Stanislav Katina

Analýza prežívania

Empirická funkcia prežívania

Príklady

Empirická funkcia prežívania pre AML data



Stanislav Katina

Analýza prežívania

Empirická funkcia prežívania a KM odhad

Príklady

$$\begin{aligned}\hat{S}_{KM}(0) &= 1 \\ \hat{S}_{KM}(9) &= \hat{S}_{KM}(0) \times \frac{11-1}{11} \\ \hat{S}_{KM}(13) &= \hat{S}_{KM}(9) \times \frac{10-1}{10} \\ \hat{S}_{KM}(13+) &= \hat{S}_{KM}(13) \times \frac{9-0}{9} = \hat{S}_{KM}(13) \\ \hat{S}_{KM}(18) &= \hat{S}_{KM}(13) \times \frac{8-1}{8} \\ \hat{S}_{KM}(23) &= \hat{S}_{KM}(18) \times \frac{7-1}{7} \\ \hat{S}_{KM}(28+) &= \hat{S}_{KM}(23) \times \frac{6-0}{6} = \hat{S}_{KM}(23) \\ \hat{S}_{KM}(31) &= \hat{S}_{KM}(23) \times \frac{5-1}{5} \\ \hat{S}_{KM}(34) &= \hat{S}_{KM}(31) \times \frac{4-1}{4} \\ \hat{S}_{KM}(45+) &= \hat{S}_{KM}(34) \times \frac{3-0}{3} = \hat{S}_{KM}(34) \\ \hat{S}_{KM}(48) &= \hat{S}_{KM}(34) \times \frac{2-1}{2} \\ \hat{S}_{KM}(161+) &= \hat{S}_{KM}(48) \times \frac{1-0}{1} = \hat{S}_{KM}(48)\end{aligned}$$


Stanislav Katina

Analýza prežívania

Empirická funkcia prežívania a KM odhad

Príklady

| | | | | | | | | | | | | |
|-----------------------|-----------------|-----------------|----------------|------|----------------|----------------|----------------|----------------|----------------|----------------|----------------|----------------|
| t | 0 | 9 | 13 | 13+ | 18 | 23 | 28+ | 31 | 34 | 45+ | 48 | 161+ |
| $S_n(t)$ | $\frac{11}{11}$ | $\frac{10}{11}$ | $\frac{8}{11}$ | - | $\frac{7}{11}$ | $\frac{6}{11}$ | $\frac{5}{11}$ | $\frac{4}{11}$ | $\frac{3}{11}$ | $\frac{2}{11}$ | $\frac{1}{11}$ | $\frac{0}{11}$ |
| $\widehat{S}_{KM}(t)$ | 1 | 0.91 | 0.82 | 0.82 | 0.72 | 0.61 | 0.61 | 0.49 | 0.37 | 0.37 | 0.18 | 0.18 |



Stanislav Katina

Analýza prežívania

Odhady

Príklady

Example

AML (pokrač.). Vypočítajte riziko $\widehat{\lambda}$ a kumulatívne riziko $\widehat{\Lambda}_{KM}$ a $\widehat{\Lambda}_{NA}$ spolu s ich rozptylmi $\widehat{Var}[\widehat{\Lambda}_{KM}]$ a $\widehat{Var}[\widehat{\Lambda}_{NA}]$ v čase 26 (pre skupinu A) [vidí [kód v prílohe, Príklad 2](#)].

$$\widehat{\lambda}(t_i) = \frac{d_i}{n_i}$$

Odhad rizika v intervale $t_i \leq t < t_{i+1}$ je rovný $\widehat{\lambda}(t) = \frac{d_i}{n_i(t_{i+1}-t_i)}$; hovoríme mu aj KM typ odhadu; odhad rizika zlyhania na jednotku času v intervale (t_i, t_{i+1})

$$\widehat{\Lambda}_{KM}(t) = -\ln(\widehat{S}_{KM}(t)) = -\ln\left(\prod_{i:t_i \leq t} \frac{n_i - d_i}{n_i}\right)$$

$$\widehat{Var}[\widehat{\Lambda}_{KM}(t)] = \sum_{i:t_i \leq t} \frac{d_i}{n_i(n_i - d_i)}$$

$$\widehat{\Lambda}_{NA}(t) = \sum_{i:t_i \leq t} \frac{d_i}{n_i}, \quad \widehat{Var}[\widehat{\Lambda}_{NA}(t)] = \sum_{i:t_i \leq t} \frac{d_i}{n_i^2}$$

Stanislav Katina

Analýza prežívania

Odhady

Príklady

Example

AML (pokrač.). Vypočítajte rozptyl KM odhadu funkcie prežívania v čase 13 (pre skupinu A). Využite Greenwoodovu formulu.

$$\widehat{Var}_G[\widehat{S}_{KM}(t)] = \widehat{S}_{KM}^2(t) \widehat{Var}[\ln \widehat{S}_{KM}(t)] = \widehat{S}_{KM}^2(t) \sum_{i:t_i \leq t} \frac{d_i}{n_i(n_i - d_i)}$$

$$\widehat{Var}_G[\widehat{S}_{KM}(t)] = \widehat{S}_{KM}^2(t) \sum_{i:t_i \leq t} \frac{d_i}{n_i(n_i - d_i)}$$

$$\widehat{Var}_G[\widehat{S}_{KM}(13)] = 0.82^2 \left(\frac{1}{11(11-1)} + \frac{1}{10(10-1)} \right) = 0.0136$$

$$SE_G[\widehat{S}_{KM}(13)] = 0.1166$$

Stanislav Katina

Analýza prežívania

Odhady

Príklady

$$\widehat{\lambda}(23) = \frac{1}{7} = 0.143$$


$$\widehat{\lambda}(26) = \widehat{\lambda}(23) = \frac{1}{7(31-23)} = 0.018$$

$$\widehat{\Lambda}_{KM}(26) = -\ln(\widehat{S}_{KM}(26)) = -\ln(0.61) = 0.49,$$

$$\widehat{\Lambda}_{NA}(26) = \frac{1}{11} + \frac{1}{10} + \frac{1}{8} + \frac{1}{7} = 0.4588$$

$$\widehat{Var}[\widehat{\Lambda}_{KM}(t)] = \frac{1}{11(11-1)} + \frac{1}{10(10-1)} + \frac{1}{8(8-1)} + \frac{1}{7(7-1)} = 0.0619$$

$$\widehat{Var}[\widehat{\Lambda}_{NA}(t)] = \frac{1}{11^2} + \frac{1}{10^2} + \frac{1}{8^2} + \frac{1}{7^2} = 0.0543$$

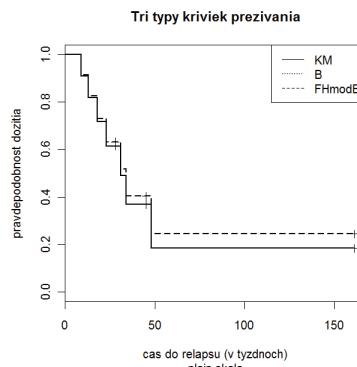


Stanislav Katina

Analýza prežívania

Example

AML (pokrač.). Nakreslite a porovnajte odhady krviek prežívania $\hat{S}_{KM}(t)$, $\hat{S}_B(t)$ a $\hat{S}_{FHmodB}(t)$ [viď  kód v prílohe, Príklad 1].



Stanislav Katina

Analýza prežívania

Medián a priemerný čas prežívania

$$\hat{t}_{(n)} = 161$$

$$\hat{\mu} = 52.6 \text{ týždňa}$$

$$\widehat{Var}[\hat{\mu}] = 19.8^2$$

$$95\% \text{ IS} = (13.792, 91.408) \text{ týždňa}$$

$$\hat{t}_{0.5} = 31 \text{ týždňov}$$

$$\hat{u}_{0.5} = \max\{t_i : \hat{S}(t_i) \geq 0.55\} = 23$$

$$\hat{l}_{0.5} = \min\{t_i : \hat{S}(t_i) \leq 0.45\} = 34$$

$$\hat{f}(31) = \frac{\hat{S}(\hat{u}_{0.5}) - \hat{S}(\hat{l}_{0.5})}{\hat{l}_{0.5} - \hat{u}_{0.5}} = \frac{\hat{S}(23) - \hat{S}(34)}{34 - 23} = \frac{0.6136364 - 0.3681818}{11} = 0.022$$

$$\widehat{Var}[31] = \left(\frac{0.16419327}{0.02231405} \right)^2 = 54.144$$

$$\sqrt{\widehat{Var}[31]} = 7.358$$

$$95\% \text{ IS} = (16.578, 45.422) \text{ týždňa}$$

Stanislav Katina

Analýza prežívania

Medián a priemerný čas prežívania

Example

AML (pokrač.). Vypočítajte priemerný čas prežívania $\hat{\mu}$ a jeho rozptyl $\widehat{Var}[\hat{\mu}]$, medián času prežívania $\tilde{\mu}$ a jeho rozptyl $\widehat{Var}[\tilde{\mu}]$ (pre skupinu A). Porovnajte s necenzurovaným mediánom.

$$\hat{\mu} = \sum_{i=1}^I (t_i - t_{i-1}) \hat{S}(t_{i-1}) = \sum_{i=0}^I \Delta t_i \hat{S}(t_i), \text{ kde } \Delta t_i = t_{i+1} - t_i,$$

$I \leq n$ je počet rôznych zlyhaní, $t_0 = 0$, $\hat{S}(t_0) = 1$ a $\hat{S}(t_{i-1})$ je výška funkcie v bode t_{i-1} .

$$\widehat{Var}[\hat{\mu}] = \sum_{i=1}^I \left[\sum_{t_i \leq t_j \leq t_n} \hat{S}(t_j) \right]^2 \frac{d_j}{n_i(n_i - d_i)}$$


$$\tilde{\mu} = \hat{t}_{0.5}, \quad \widehat{Var}[\tilde{\mu}] = \frac{\widehat{Var}_G[\hat{S}(t_{0.5})]}{\hat{f}(\hat{t}_{0.5})^2}$$

Stanislav Katina

Analýza prežívania

Prežívanie pacientov po infarkte myokardu

Príklad: MACE (rôzne kombinácie; s a bez adjustácie) [funkcia prežívania]




Stanislav Katina

Analýza prežívania

Chronická myeloidná leukémia

Príklad: zmeny po transplantácii (typické a netypické) [funkcia prežívania]

- typické zmeny: $\hat{\mu} = 58.08 (\pm 6.70)$ mesiaca ($\tilde{\mu} = 38.00$) a pravdepodobnosť úmrtia 49/72
- netypické zmeny: $\hat{\mu} = 5.17 (\pm 0.98)$ mesiaca ($\tilde{\mu} = 5.50$) pravdepodobnosť úmrtia 6/6



Stanislav Katina

Analýza prežívania

Odhady

Príklady

Pre 2 zhody v čase 12 platí:

- $\hat{S}_{KM}(12) = (69/70)(66/68) = 0.9567$
- $\hat{S}_{KMmod}(12) = (69/70)(67/68)(66/67) = (69/70)(66/68) = 0.9567$

Druhý prípad predstavuje úpravu $\hat{S}_{KM}(t)$ pri zlome zhôd rozdelením času 11.5 na 11.48 a 11.52

- $\hat{S}_B(12) = \exp[-(1/70 + 2/68)] = 0.9572$
- $\hat{S}_{FHmodB}(12) = \exp[-(1/70 + 1/68 + 1/67)] = 0.9570$

Pre 5 zhôd v čase 88 platí:

- $\hat{S}_{KM}(88) = 0.5294$
- $\hat{S}_{FHmodB}(88) = 0.5395$
- $\hat{S}_B(88) = 0.5709$

$\hat{S}_{FHmodB}(t)$ dáva vo všeobecnosti odhad bližšie ku $\hat{S}_{KM}(t)$ a je menší ako $\hat{S}_B(t)$ pri zhodách

Stanislav Katina

Analýza prežívania

Odhady

Príklady

Example

Vypočítajte odhady nasledovné odhady funkcií prežívania $\hat{S}_{KM}(t)$, $\hat{S}_{KMmod}(t)$, $\hat{S}_B(t)$ a $\hat{S}_{FHmodB}(t)$ pre dátá (pozri tabuľku).

| t | d_i | n_i |
|------|-------|-------|
| 4.5 | 1 | 70 |
| 11.5 | 2 | 68 |
| 16.0 | 1 | 65 |
| 20.7 | 2 | 55 |
| 20.8 | 1 | 53 |
| 31.0 | 1 | 47 |
| 34.5 | 1 | 45 |
| 46.0 | 1 | 34 |
| 61.0 | 1 | 25 |
| 87.5 | 5 | 15 |


Stanislav Katina

Analýza prežívania


Odhady

Príklady


Tri typy kriviek prežívania




B krivka prežívania



KM krivka prežívania



FHmodB krivka prežívania

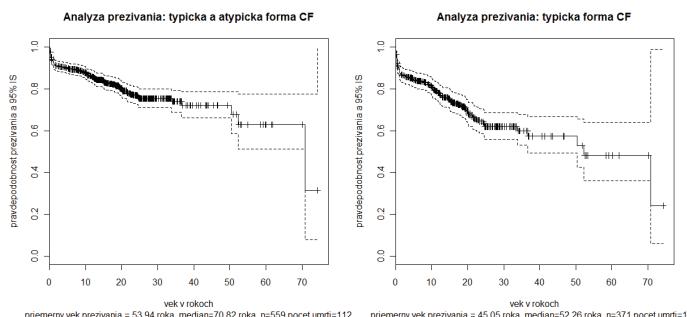


Stanislav Katina

Analýza prežívania

Example

CF (pokrač.) Nakreslite KM odhad funkcie prežívania $\hat{S}_{KM}(t)$ a 95% IS pre $S(t)$ vo všetkých bodoch t pre pacientov s CF (všetci pacienti a typická forma).



Stanislav Katina

Analýza prežívania

Prehľad vzorcov

Odhady kumulatívneho rizika

- Nelson-Aalenov (NA) odhad kumulatívneho rizika

$$\hat{\lambda}_{NA}(t) = \int_0^t \frac{d\bar{N}(s)}{\bar{Y}(s)} ds \approx \sum_{i:t_i \leq t} \frac{\Delta\bar{N}(t_i)}{\bar{Y}(t_i)}$$

- Flemingom a Harringtonom (FH) modifikovaný NA odhad kumulatívneho rizika


$$\begin{aligned}\hat{\lambda}_{FHmodNA}(t) &= \int_0^t \left[\sum_{j=0}^{\Delta\bar{N}(s)-1} \frac{1}{\bar{Y}(s)-j} \right] ds \\ &\approx \sum_{i:t_i \leq t} \left[\sum_{j=0}^{\Delta\bar{N}(t_i)-1} \frac{1}{\bar{Y}(t_i)-j} \right]\end{aligned}$$

Stanislav Katina

Analýza prežívania

Example

AML (pokrač.) Vypočítajte KM odhad funkcie prežívania $\hat{S}_{KM}(t)$ a 95% IS pre $S(t)$ vo všetkých bodoch t v 1) plain škále, 2) log-škále a 3) log-log škále (pre skupinu A).



Stanislav Katina

Analýza prežívania

Prehľad vzorcov

Odhady kumulatívneho rizika

- Nelson-Aalenov (NA) odhad kumulatívneho rizika

$$\hat{\lambda}_{NA}(t) = \sum_{i:t_i \leq t} \hat{\lambda}(t_i) = \sum_{i:t_i \leq t} \frac{d_i}{n_i},$$

- Flemingom a Harringtonom (FH) modifikovaný NA odhad kumulatívneho rizika

$$\hat{\lambda}_{FHmodNA}(t) = \sum_{i:t_i \leq t} \left[\sum_{j=0}^{d_i-1} \frac{1}{n_i-j} \right]$$

Stanislav Katina

Analýza prežívania

- Kamplan-Meierov odhad funkcie prežívania

$$\widehat{S}_{KM}(t) = \prod_{i:t_i \leq t} \left[1 - \Delta \widehat{\lambda}(t_i) \right], \Delta \widehat{\lambda}(t_i) = \frac{\Delta \bar{N}(t_i)}{\bar{Y}(t_i)}$$

- Breslowov odhad funkcie prežívania

$$\widehat{S}_B(t) = \exp(-\widehat{\lambda}(t)) = \prod_{i:t_i \leq t} e^{-\Delta \widehat{\lambda}(t_i)}, \Delta \widehat{\lambda}(t_i) = \frac{\Delta \bar{N}(t_i)}{\bar{Y}(t_i)}$$

- Flemingom a Harringtonom modifikovaný Breslowov odhad funkcie prežívania

$$\widehat{S}_{FHmodB}(t) = \exp(-\widehat{\lambda}_{FHmodNA}(t)) = \prod_{i:t_i \leq t} e^{-\Delta \widehat{\lambda}_{FHmodNA}(t_i)}$$

Stanislav Katina

Analýza prežívania

Prehľad vzorcov

Odhady rozptylu kumulatívneho rizika

- Greenwoodov odhad rozptylu kumulatívneho rizika

$$\widehat{Var}_G[\widehat{\lambda}(t)] = \widehat{Var}_G[-\ln \widehat{S}_{KM}(t)] = \int_0^t \frac{d\bar{N}(s)}{\bar{Y}(s)[\bar{Y}(s) - d\bar{N}(s)]} ds$$

- NA odhad rozptylu kumulatívneho rizika

$$\widehat{Var}[\widehat{\lambda}_{NA}(t)] = \int_0^t \frac{d\bar{N}(s)}{\bar{Y}^2(s)} ds$$

- Flemingom a Harringtonom modifikovaný NA odhad rozptylu kumulatívneho rizika

$$\widehat{Var}[\widehat{\lambda}_{FHmodNA}(t)] = \int_0^t \left[\sum_{j=0}^{\Delta \bar{N}(s)-1} \frac{1}{[\bar{Y}(s) - j]^2} \right] ds$$

Stanislav Katina

Analýza prežívania

- Kamplan-Meierov odhad funkcie prežívania

$$\widehat{S}_{KM}(t) = \prod_{i:t_i \leq t} \left[1 - \frac{d_i}{n_i} \right] = \widehat{S}_{KMmod} = \prod_{i:t_i \leq t} \left[1 - \sum_{j=0}^{d_i-1} \frac{1}{n_i - j} \right]$$

- Breslowov odhad funkcie prežívania

$$\widehat{S}_B(t) = \exp(-\widehat{\lambda}_{NA}(t)) = \prod_{i:t_i \leq t} e^{-\frac{d_i}{n_i}} = e^{-\sum_{i:t_i \leq t} \frac{d_i}{n_i}}$$

- Flemingom a Harringtonom modifikovaný Breslowov odhad funkcie prežívania

$$\widehat{S}_{FHmodB}(t) = \exp(-\widehat{\lambda}_{FHmodNA}(t)) = e^{-\sum_{i:t_i \leq t} [\sum_{j=0}^{d_i-1} \frac{1}{n_i - j}]}$$

Stanislav Katina

Analýza prežívania

Prehľad vzorcov

Odhady rozptylu kumulatívneho rizika

- Greenwoodov odhad rozptylu kumulatívneho rizika

$$\widehat{Var}_G[\widehat{\lambda}(t)] = \sum_{i:t_i \leq t} \frac{\Delta \bar{N}(t_i)}{\bar{Y}(t_i)[\bar{Y}(t_i) - \Delta \bar{N}(t_i)]}$$

- NA odhad rozptylu kumulatívneho rizika

$$\widehat{Var}[\widehat{\lambda}_{NA}(t)] = \sum_{i:t_i \leq t} \frac{\Delta \bar{N}(t_i)}{\bar{Y}^2(t_i)}$$

- Flemingom a Harringtonom modifikovaný NA odhad rozptylu kumulatívneho rizika

$$\widehat{Var}[\widehat{\lambda}_{FHmodNA}(t)] = \sum_{i:t_i \leq t} \left[\sum_{j=0}^{\Delta \bar{N}(t_i)-1} \frac{1}{[\bar{Y}(t_i) - j]^2} \right]$$

Stanislav Katina

Analýza prežívania

Prehľad vzorcov

Odhady rozptylu kumulatívneho rizika

- Greenwoodov odhad rozptylu kumulatívneho rizika

$$\widehat{\text{Var}}_G \left[\widehat{\Lambda}(t) \right] = \sum_{i:t_i \leq t} \frac{\Delta \bar{N}(t_i)}{\bar{Y}(t_i) [\bar{Y}(t_i) - \Delta \bar{N}(t_i)]} = \sum_{i:t_i \leq t} \frac{d_i}{n_i(n_i - d_i)}$$

- NA odhad rozptylu kumulatívneho rizika

$$\text{Var} \left[\widehat{\Lambda}_{NA}(t) \right] = \sum_{i:t_i \leq t} \frac{d_i}{n_i^2}$$

- Flemingom a Harringtonom modifikovaný NA odhad rozptylu kumulatívneho rizika

$$\text{Var} \left[\widehat{\Lambda}_{FHmodNA}(t) \right] = \sum_{i:t_i \leq t} \left[\sum_{j=0}^{d_i-1} \frac{1}{(n_i - j)^2} \right]$$

Stanislav Katina

Analýza prežívania

Prehľad vzorcov

$(1 - \alpha)100\% \text{IS } S(t) \text{ v } t$

$$\text{kde } \text{Var} \left[\ln \widehat{\Lambda}(t) \right] \approx \text{Var} \left[\widehat{\Lambda}(t) \right] / \left[\widehat{\Lambda}(t) \right]^2$$

- log-log škála (log-log (survival) scale; škála log-kumulatívneho rizika)

$$\ln(-\ln \widehat{S}(t)) \pm u_{\alpha/2} \sqrt{\text{Var}[W]},$$

$$\text{kde } W = \ln(-\ln \widehat{S}(t)), \widehat{\text{Var}}[W] = \text{Var} \left[-\ln \widehat{S}(t) \right] / (\ln \widehat{S}(t))^2,$$

$$(\widehat{S}(t))^{\exp(\pm u_{\alpha/2} \sqrt{\text{Var}[W]}),}$$

a

$$\exp \left[-\widehat{\Lambda}(t) \exp \left(\pm u_{\alpha/2} \sqrt{\text{Var} \left[\ln \widehat{\Lambda}(t) \right]} \right) \right]$$

Stanislav Katina

Analýza prežívania

Prehľad vzorcov

$(1 - \alpha)100\% \text{IS } S(t) \text{ v } t$

- škála $S(t)$ (survival (plane) scale)

$$\widehat{S}(t) \pm u_{\alpha/2} \sqrt{\text{Var} \left[\widehat{S}(t) \right]}, \text{ kde } \text{Var} \left[\widehat{S}(t) \right] = \widehat{S}^2(t) \text{Var} \left[\widehat{\Lambda}(t) \right]$$

- škála kumulatívneho rizika (log-survival scale)

$$\ln \widehat{S}(t) \pm u_{\alpha/2} \sqrt{\text{Var} \left[\ln \widehat{S}(t) \right]}, \widehat{S}(t) \exp \left(\pm u_{\alpha/2} \sqrt{\text{Var} \left[\ln \widehat{\Lambda}(t) \right]} \right)$$

$$\widehat{\Lambda}(t) \exp \left(\pm u_{\alpha/2} \sqrt{\text{Var} \left[\ln \widehat{\Lambda}(t) \right]} \right)$$

Stanislav Katina

Analýza prežívania

Prehľad vzorcov

Odhad strednej hodnoty do času prežívania a jej rozptylu

(Urezaný) odhad strednej hodnoty času do zlyhania $E[T]$

$$\widehat{\mu} = \int_0^{t_{\max}} \widehat{S}(t) dt, \widehat{\mu} = \sum_{i=0}^I \Delta t_i \widehat{S}(t_i), \Delta t_i = t_{i+1} - t_i, I \leq n,$$

kde $\widehat{S}(t)$ je KM odhad funkcie prežívania, t_{\max} je maximum pozorovaných časov, I počet rôznych zlyhaní

Odhad rozptylu $\text{Var}[\widehat{\mu}]$

$$\widehat{\text{Var}}[\widehat{\mu}] = \int_0^T \left[\int_t^T \widehat{S}(u) du \right]^2 \frac{d\bar{N}(t)}{\bar{Y}(t) [\bar{Y}(t) - d\bar{N}(t)]} dt$$

$$\widehat{\text{Var}}[\widehat{\mu}] = \sum_{i:t_i \leq t_n} \left[\sum_{t_i \leq t_j \leq t_n} \widehat{S}(t_j) \right]^2 \frac{\Delta \bar{N}(t_i)}{\bar{Y}(t_i) [\bar{Y}(t_i) - \Delta \bar{N}(t_i)]}$$

Stanislav Katina

Analýza prežívania

Prehľad vzorcov

Odhad mediánu do času prežívania a jeho IS

Medián času prežívania je 50-ty percentil $t_{0.5}$

Medián funkcie prežívania je $S(t_{0.5}) = 0.5$

Výberový medián – prvý čas, v ktorom $\widehat{S}(t) \leq 0.5$, t.j. $\widetilde{\mu} = \widehat{S}^{-1}(0.5)$

Niekedy je potrebné použiť lineárnu interpoláciu pre $\widehat{S}(t_{0.5})$ v podobe

$$\widetilde{\mu}_{int} = t_i + (t_{i+1} - t_i) \frac{\widehat{S}(t_i) - 0.5}{\widehat{S}(t_i) - \widehat{S}(t_{i+1})}$$

Horná a dolná hranica IS pre medián – definovaná na základe IS pre $S(t)$ v danom čase, t.j.

- horná hranica IS pre medián je prvý čas, v ktorom je horná hranica IS pre $S(t)$ väčšia alebo rovná 0.5
- dolná hranica IS pre medián je prvý čas, v ktorom je dolná hranica IS pre $S(t)$ menšia alebo rovná 0.5

To korešponduje s narysovaním horizontálnej úsečky na grafe krivky prežívania, t.j. prenutím tejto úsečky s krivkou prežívania, dolnou a hornou hranicou IS pre $S(t)$ v danom čase

Stanislav Katina

Analýza prežívania

Prehľad vzorcov

Odhady strednej hodnoty zostatkového života a jej rozptyl

$$\widehat{mrl}(t) = E(T - \widehat{T} | T > t) = \frac{\int_t^{t_{max}} \widehat{S}(u) du}{\widehat{S}(t)}$$

$$\widehat{mrl}(t) = \frac{(t_{i+1} - t) \widehat{S}(t_i) + \sum_{j \geq i+1} (t_{j+1} - t_j) \widehat{S}(t_j)}{\widehat{S}(t)}, t_i \leq t < t_{i+1}$$

$$\begin{aligned} \widehat{Var}[\widehat{mrl}(t)] &= \frac{1}{\widehat{S}^2(t)} \left(\sum_{i:t \leq t_i \leq t_{max}} \left(\int_{t_i}^{t_{max}} \widehat{S}(u) du \right)^2 \frac{d_i}{n_i(n_i - d_i)} \right. \\ &\quad \left. + \left(\int_t^{t_{max}} \widehat{S}(u) du \right)^2 \sum_{i:t_i \leq t} \frac{d_i}{n_i(n_i - d_i)} \right). \end{aligned}$$

$$\begin{aligned} \widehat{Var}[\widehat{mrl}(t)] &= \frac{1}{\widehat{S}^2(t)} \left(\sum_{i:t \leq t_i \leq t_{max}} \left[\sum_{j:t_i \leq t_j \leq t_{max}} \widehat{S}(t_j) \right]^2 \frac{d_i}{n_i(n_i - d_i)} \right. \\ &\quad \left. + \left(\sum_{i:t \leq t_i \leq t_{max}} \widehat{S}(t_i) \right)^2 \sum_{i:t_i \leq t} \frac{d_i}{n_i(n_i - d_i)} \right) \end{aligned}$$

Stanislav Katina

Analýza prežívania

Prehľad vzorcov

Odhad kvantilov do času prežívania a ich rozptylov

Nech t_p je p -ty kvantil rozdelenia T (100 \times p -ty percentil), teda $F(t_p) = \Pr(T < t_p) = p$, $t_p = F^{-1}(p)$. Potom

$$S(t_p) = \Pr(T \geq t_p) = 1 - p, t_p \leq S^{-1}(1 - p)$$

Kedže KM krivka prežívania je schodovitá funkcia, inverzia $\widehat{S}^{-1}(t_p)$ nie je jednoznačne definovaná; odhad kvantílu bude potom

$$\widehat{t}_p = \min\{t_i : \widehat{S}(t_i) \leq 1 - p\}$$

Aplikovaním delta metódy na $\widehat{Var}_G(\widehat{S}(\widehat{t}_p))$ dostaneme

$$\widehat{Var}[\widehat{t}_p] = \frac{\widehat{Var}_G[\widehat{S}(\widehat{t}_p)]}{[\widehat{f}(\widehat{t}_p)]^2}, \widehat{f}(\widehat{t}_p) = \frac{\widehat{S}(\widehat{u}_p) - \widehat{S}(\widehat{l}_p)}{\widehat{l}_p - \widehat{u}_p},$$

kde $\widehat{u}_p = \max\{t_i : \widehat{S}(t_i) \geq 1 - p + \epsilon\}$ a $\widehat{l}_p = \min\{t_i : \widehat{S}(t_i) \leq 1 - p - \epsilon\}$ pre $i = 1, 2, \dots, I \leq n$, I je počet rozdielnych časov zlyhania, ϵ je veľmi malé číslo; vo všeobecnosti je $\epsilon = 0.05$ akceptovateľné, ale musí byť veľké, ak $|\widehat{l}_p - \widehat{u}_p| \approx 0$

Stanislav Katina

Analýza prežívania



príkazy `[R]` je voľne dostupné na <http://cran.r-project.org/>

Voľby argumentov fcie `Survfit` v knižnici `library(survival)`:

`Survfit(surv(time, status)~1, type="...", error="...", conf.type = "...")`

- 1 $\widehat{S}_{KM}(t)$: type="kaplan-meier" (prednastavené)
- 2 $\widehat{S}_B(t)$: type="fleming-harrington"
- 3 $\widehat{S}_{FHmodB}(t)$: type="fh2"
- 4 $\widehat{Var}_G[\widehat{\Lambda}_{KM}(t)]$: error = "greenwood" (prednastavené)
- 5 $\widehat{Var}[\widehat{\Lambda}_{NA}(t)] = \widehat{\sigma}_T^2$: error = "tsiatis"
- 6 žiadny: conf.type = "none"
- 7 survival (plane) scale: conf.type = "plain"
- 8 log-survival scale: conf.type = "log" (prednastavené)
- 9 log-log (survival) scale: conf.type="log-log"
- 10 koeficient spoľahlivosti conf.int=0.95 (prednastavené)

Stanislav Katina

Analýza prežívania



R príkazy [R je voľne dostupné na <http://cran.r-project.org>]

Označme `surv.obj <- survfit(Surv(cas, status)~1)`. Priemerný vek prežívania a jeho smerodajná odchýlka (medián a jeho smerodajná odchýlka je súčasťou výstupu) sa vypočíta ako

```
1) print(surv.obj, print.rmean=TRUE) alebo
2) print(surv.obj, rmean="individual")
```

Na rozlíšenie typu cenzúrovania je dôležitý počet argumentov funkcie `Surv()`. Ak sú dva, t.j. `Surv(cas, status)`, ide o pravý typ cenzúrovania. Ak sú tri, t.j. `Surv(cas, cas1, status)`, potom ide o intervalové cenzúrovanie. Pomocným argumentom je `type="..."`, kde rozlišujeme `type="right"` (pravý typ), `type="interval"` (intervalový typ cenzúrovania I. typu; kde interval $(-\infty, t_i]$ označujeme `(NA, ti)`), `type="interval2"` (intervalový typ cenzúrovania II. typu; kde interval je typu (t_{1i}, t_{2i}) alebo interval (t_i, ∞) , ktorý označujeme (t_i, NA)). Dolnou hranicou intervalu môže byť aj 0 a hornou hranicou t_{\max} .

Example

Intervalový typ cenzúrovania pre dátá `heart` – intervaly sa nachádzajú v stĺpcoch `heart$start` a `heart$stop`, `status` (udalosť) je v stĺpci `heart$event`. Význam premenných pozri v `help(heart)`.

Stanislav Katina

Analýza prežívania



Implementácia v R

Príklad 2 (poznámky sú uvedené za znakom #):

```
cas <- summary(KM.aml.A)$time # casy zlyhania ti
n.i <- summary(KM.aml.A)$n.risk # pocet jedincov v riziku ni
d.i <- summary(KM.aml.A)$n.event # pocet zlyhaní di
KM <- summary(KM.aml.A)$surv #  $\hat{S}_{KM}(t)$ 
SE.KM <- summary(KM.aml.A)$std.err #  $SE(\hat{S}_{KM}(t))$ 
lambda.KM <- d.i/n.i
DIFF <- diff(cas, lag = 1) # dlzka intervalu napravo od ti
DIFF[length(DIFF) + 1] <- NA # NA su chybajuce hodnoty
lambda.INT <- lambda.KM/DIFF
Lambda.KM <- -log(KM) #  $\hat{\lambda}_{KM}(t)$ 
Lambda.NA <- cumsum(lambda.KM) #  $\hat{\lambda}_{NA}(t)$ 
sumand <- d.i/(n.i*n.i)
se.Lambda.KM <- SE.KM/lambda.KM #  $SE(\hat{\lambda}_{KM}(t))$ 
se.Lambda.NA <- sqrt(cumsum(sumand)) #  $SE(\hat{\lambda}_{NA}(t))$ 
# round(cislo,kolko.des.miest)
# data.frame: datovy ramec
RIZ <- round(data.frame(cas, n.i, d.i, lambda.KM, lambda.INT,
Lambda.KM, se.Lambda.KM, Lambda.NA, se.Lambda.NA), 4)
```

Stanislav Katina

Analýza prežívania



Implementácia v R

Príklad 1 (poznámky sú uvedené za znakom #):

```
library(survival)
attach(aml)
names(aml)
aml.A <- aml[x=="Maintained",1]
status.A <- aml[x=="Maintained",2]
KM.aml.A.KM <- survfit(Surv(aml.A,status.A)~1,conf.type =
"plain",type="kaplan-meier") #  $\hat{S}_{KM}(t)$ 
KM.aml.A.B <- survfit(Surv(aml.A,status.A)~1,conf.type =
"plain",type="fleming-harrington") #  $\hat{S}_B(t)$ 
KM.aml.A.FHmodB <- survfit(Surv(aml.A,status.A)~1,conf.type =
"plain",type="fh2") #  $\hat{S}_{FHmodB}(t)$ 
# obrazok (lwd: hrubka ciary, lty: typ ciary)
plot(KM.aml.A.KM,xlab="cas do relapsu (v tyzdnoch)",
ylab="pravdepodobnosť dozitia",conf.int=FALSE,lwd=2)
lines(KM.aml.A.KM,lty=1,lwd=2)
lines(KM.aml.A.B,lty=3,lwd=2)
lines(KM.aml.A.FHmodB,lty=2,lwd=2)
legend("topright",c("KM","B","FHmodB"),lty=c(1,3,2))
title(main="Tri typy kriviek prezívania",sub="plain skala")
```

Stanislav Katina

Analýza prežívania



Implementácia v R

Príklad 2 (pokrač.):

```
# obrazok
# schodovita funkcia: type="s", prazdny obrazok: type="n"
# $ znamena indexaciu stlpca z datoveho ramca v podobe
# RIZ$nazov.stlpca
plot(RIZ$cas,RIZ$Lambda.KM,xlab="cas do relapsu (v
tyzdnoch)",ylab="kumulativne riziko",type="n")
lines(RIZ$cas,RIZ$Lambda.KM,lty=1,lwd=2,type="s")
lines(RIZ$cas,RIZ$Lambda.NA,lty=2,lwd=2,type="s")
abline(h=0,col="gray")
title(main="KM a NA kumulativne riziko pre AML
data",sub="skupina A")
legend("topleft",c("KM kum.riziko","NA kum.riziko"),lty=c(1,2))
```

Viac sa o R dozviete

- 1) v mojich skriptách na <http://www.iam.fmph.uniba.sk/skripta/katina/>, kde "podtržník _" vo význame priradenia výpočtu nejakému názvu treba nahradíť "`-`" (ide o v minulosti používanú syntax v komerčnej verzii R, programe S-PLUS)
- 2) v knižke **An Introduction to R** na <http://cran.r-project.org> v časti *Manuals*

Inštalácia: R Binaries → windows → base → Download R 3.0.1 for Windows

Stanislav Katina

Analýza prežívania

Vybrané kapitoly z analýzy prežívania

Testovanie hypotéz

Stanislav Katina¹

¹Ústav matematiky a statistiky
Přírodovědecká fakulta
Masarykova univerzita v Brně

ZS 2013



INVESTICE DO ROZVOJE VZDĚLÁVÁNÍ

Stanislav Katina

Vybrané kapitoly z analýzy prežívania

Testy na porovnanie kriviek prežívania

Prehľad testov

Delenie testov na porovnanie kriviek prežívania

- **typ dát:** necenzúrované alebo cenzúrované
- **počet porovávaných kriviek prežívania:** $k = 2$ alebo $k \geq 3$
- **typ pozorovaní:** nepárové alebo párové
- **typ alternatívy:** všeobecná alebo zoradená
- **crossing efekt** (prekrižovanie sa kriviek prežívania): neexistuje alebo existuje
- **časový efekt liečby:** neexistuje alebo existuje

Poděkování

Tento učební text vznikl za přispění Evropského sociálního fondu a státního rozpočtu ČR prostřednictvím Operačního programu Vzdělávání pro konkurenceschopnost v rámci projektu Univerzitní výuka matematiky v měnícím se světě

(CZ.1.07/2.2.00/15.0203)

Stanislav Katina

Vybrané kapitoly z analýzy prežívania

Testy na porovnanie kriviek prežívania

Prehľad testov

Neparametrické testy porovnania kriviek prežívania pre necenzurované dátá

- testy porovnania **dvoch** kriviek prežívania ($k = 2$)
 - Wilcoxonov test (W)
 - Mann-Whitney test (MW)
 - Siegel-Tukey test (ST)
- testy porovnania **viac** kriviek prežívania ($k \geq 3$)
 - Kruskal-Wallis test (KW)
 - Jonckheere test (J)
 - Cuzick test (C)
 - Le test (L)

Stanislav Katina

Vybrané kapitoly z analýzy prežívania

Stanislav Katina

Vybrané kapitoly z analýzy prežívania

Neparametrické testy porovnania kriviek prežívania pre cenzurované dátá

- testy porovnania **dvoch** kriviek prežívania ($k = 2$)
 - Gehan-Wilcoxon test, zovšeobecnený Wilcoxonov test (GB)
 - Cox-Mantel test, log-rank test (CM)
 - Tarone-Ware test (TW)
 - Peto-Peto test (PP)
- testy porovnania **viac** kriviek prežívania ($k \geq 3$)
 - Gehan-Breslow test, zovšeobecnený Wilcoxonov test, zovšeobecnený Kruskal-Wallis test (GB)
 - Cox-Mantel test, log-rank test (CM)
 - Mantel-Haenszel test, log-rank test (MH)
 - Peto-Peto test (PP)

Stanislav Katina

Vybrané kapitoly z analýzy prežívania

Testy na porovnanie dvoch kriviek prežívania

Wilcoxonov test

Predpoklady

- X_1, \dots, X_{n_1} je náhodný výber (NV) z nejakého spojitého rozdelenia
- Y_1, \dots, Y_{n_2} je NV z rovnakého spojitého rozdelenia a je oproti prvému rozdeleniu posunuté o nejakú konštantu δ
- veličiny X_1, \dots, X_{n_1} a $Y_1 - \delta, \dots, Y_{n_2} - \delta$ majú rovnaké rozdelenie
- oba výbery sú nezávislé

Hypotézy

- $H_0 : \delta = 0$ ($S_1(t) = S_2(t), \forall t$)
- $H_1 : \delta \neq 0$ ($S_1(t) \neq S_2(t)$, pre aspoň jedno t)

Stanislav Katina

Vybrané kapitoly z analýzy prežívania

Testované hypotézy

- **nulová hypotéza** $H_0 : S_1(t) = S_2(t) = S(t)$

- **alternatíva hypotéza** $H_1 :$

- $S_1(t) \neq S_2(t)$
- $S_1(t) \stackrel{st}{\prec} S_2(t)$
- $S_1(t) \stackrel{st}{\succ} S_2(t)$

pre $\forall t$

$S(t)$ je funkcia prežívania

$\stackrel{st}{\prec}$ a $\stackrel{st}{\succ}$ stochasticky menší, resp. stochasticky väčší

Stanislav Katina

Vybrané kapitoly z analýzy prežívania

Testy na porovnanie dvoch kriviek prežívania

Wilcoxonov test

Označenia

- n_j je počet pozorovaní v j -tom NV, $j = 1, 2$
- $n_1 + n_2 = n$
- nech R_1, R_2, \dots, R_{n_1} sú poradia prvého NV v rámci usporiadanejho združeného NV

Wilcoxonova štatistika

$$W_X = S_W = \sum_{i=1}^{n_1} R_i$$

Stanislav Katina

Vybrané kapitoly z analýzy prežívania

Testy na porovnanie dvoch kriviek prežívania

Wilcoxonov test

Stredná hodnota a rozptyl S_W :

$$E_0 [S_W] = \frac{n_1(n+1)}{2}$$

$$\text{Var}_0 [S_W] = \frac{n_1 n_2 (n+1)}{12}$$

Wilcoxonov test

Ak $n_1, n_2 \geq 10$

$$Z_W = \frac{S_W - E_0 [S_W]}{\sqrt{\text{Var}_0 [S_W]}} \sim N(0, 1)$$

Stanislav Katina

Vybrané kapitoly z analýzy prežívania

Testy na porovnanie dvoch kriviek prežívania

Mann-Whitney test

Predpoklady

- X_1, \dots, X_{n_1} je NV z nejakého spojitého rozdelenia
- Y_1, \dots, Y_{n_2} je NV z rovnakého spojitého rozdelenia a je oproti prvému rozdeleniu posunuté o nejakú konštantu δ
- oba výbery sú nezávislé
- nech (X_i, Y_j) sú možné páry pozorovaní, pre ktoré môže nastať buď $X_i < Y_j$ alebo $X_i > Y_j$

Hypotézy

- $H_0 : \delta = 0$ ($S_1(t) = S_2(t), \forall t$)
- $H_1 : \delta > 0$ ($S_1(t) \stackrel{st}{\prec} S_2(t)$, pre aspoň jedno t)

Stanislav Katina

Vybrané kapitoly z analýzy prežívania

Testy na porovnanie dvoch kriviek prežívania

Wilcoxonov test

Stredná hodnota a rozptyl S_W :

$$E_0 [S_W] = \frac{n_1(n+1)}{2}$$

$$\text{Var}_0 [S_W | \mathbf{t}] = \frac{n_1 n_2 (n+1)}{12} \left[1 - \frac{1}{n(n^2-1)} \sum_{j=1}^L t_j (t_j^2 - 1) \right]$$

Wilcoxonov test

Ak $n_1, n_2 \geq 10$

$$Z_{W,kor} = \frac{S_W - E_0 [S_W]}{\sqrt{\text{Var}_0 [S_W] - \frac{n_1 n_2 \sum_j (t_j^3 - t_j)}{12(n_1+n_2)(n_1+n_2-1)}}} \sim N(0, 1)$$

Stanislav Katina

Vybrané kapitoly z analýzy prežívania

Testy na porovnanie dvoch kriviek prežívania

Wilcoxonov test

Označenia

- n_j je počet pozorovaní v j -tom NV, $j = 1, 2$
- $n_1 + n_2 = n$

Mann-Whitney štatistika

$$S_{MW} = \# (x_i, y_j), \text{ kde } x_i > y_j$$

Stanislav Katina

Vybrané kapitoly z analýzy prežívania

Testy na porovnanie dvoch kriviek prežívania

Mann-Whitney test

Stredná hodnota a rozptyl S_{MW} :

$$E_0 [S_{MW}] = \frac{n_1 n_2}{2}$$

$$\text{Var}_0 [S_{MW}] = \text{Var}_0 [S_W] = \frac{n_1 n_2 (n_1 + n_2 + 1)}{12}$$

Mann-Whitney test

Ak $n_1, n_2 \geq 10$

$$Z_{MW} = \frac{S_{MW} - E_0 [S_{MW}]}{\sqrt{\text{Var}_0 [S_{MW}]}} \sim N(0, 1)$$

Stanislav Katina

Vybrané kapitoly z analýzy prežívania



Asymptotická normalita rozdelenia S_{MW}

```

n1 <- 7; n2 <- 5; n <- n1+n2
SUMmax <- sum(6:12); SUMmin <- sum(1:5)
Smw.max <- n1*n2-SUMmin+n2*(n2+1)/2
Smw.min <- n1*n2-SUMmax+n1*(n1+1)/2
x <- Smw.min:Smw.max
fx <- dwilcox(x, n1, n2); Fx <- pwilcox(x, n1, n2)
E.Smw <- n1*n2/2; Var.Smw <- n1*n2*(n1+1)/12
fx.norm <- dnorm(x, E.Smw, sqrt(Var.Smw))
Fx.norm <- cumsum(dnorm(x, E.Smw, sqrt(Var.Smw))) / sum(dnorm(x, E.Smw, sqrt(Var.Smw)))
par(mfcol=c(1,3))
plot(x, fx,type="h", col="black", sub="n1=7,n2=5", xlab="x",
      ylab="f(x)",main= "Hustota MW statistiky",ylim=range(c(fx.norm,fx)))
points(x, fx,pch=16,cex=0.7)
lines(x,fx.norm,col="red",lwd=5)
plot(x, Fx,type="s", col="black", sub="n1=7,n2=5", xlab="x",
      ylab="F(x)",main= "Distribucna funkcia MW statistiky")
points(x, Fx,pch=16,cex=0.7)
lines(x,Fx.norm,col="red",lwd=5)
abline(h=0:1, col="gray20",lty=2)
p.mw <- seq(0.001,0.999,length=length(x))
q.mw <- qnorm(p.mw,E.Smw,sqrt(Var.Smw))
plot(x,q.mw,main = "qq-diagram MW rozdelenia", ylab="kvantily", sub="n1=7,n2=5",
      pch=16,cex=0.7,asp=1)
x1 <- quantile(x,0.25); x2 <- quantile(x,0.75)
y1 <- quantile(q.mw,0.25); y2 <- quantile(q.mw,0.75)
b1 <- (y2 - y1)/(x2 - x1); b0 <- y1 - b1 * x1
abline(a=b0,b=b1,lwd=2)

```

Stanislav Katina

Vybrané kapitoly z analýzy prežívania

Testy na porovnanie dvoch kriviek prežívania

Mann-Whitney vs Wilcoxonov test

U_X vyjadruje počet dvojíc X_i, Y_j , kde platí $X_i < Y_j$

$$U_X = n_1 n_2 + \frac{n_1 (n_1 + 1)}{2} - W_X,$$

U_Y vyjadruje počet dvojíc X_i, Y_j , kde platí $X_i > Y_j$


$$U_Y = n_1 n_2 + \frac{n_2 (n_2 + 1)}{2} - W_Y$$

Stanislav Katina

Vybrané kapitoly z analýzy prežívania

Testy na porovnanie dvoch kriviek prežívania

Mann-Whitney vs Wilcoxonov test



Obr.: Rozdelenie Mann-Whitneyho štatistiky S_{MW} ($n_1 = 7, n_2 = 5$)

Stanislav Katina

Vybrané kapitoly z analýzy prežívania

Testy na porovnanie dvoch kriviek prežívania

Siegel-Tukey a Levene test

Predpoklady

- efekt nového typu liečby spôsobí rast alebo klesanie krivky prežívania oproti pôvodnému typu liečby
- liečba nespôsobuje zmenu priemernej odpovede, ale výsledná odpoveď
- X_1, \dots, X_{n_1} je náhodný výber (NV) z nejakého spojitého rozdelenia
- Y_1, \dots, Y_{n_2} je náhodný výber (NV) z nejakého spojitého rozdelenia
- oba výbery sú nezávislé

Hypotézy

- $H_0 : \text{Var}(S_1(t)) = \text{Var}(S_2(t)), \forall t$
- $H_1 : \text{Var}(S_1(t)) \neq \text{Var}(S_2(t)), \text{ pre aspoň jedno } t$

Stanislav Katina

Vybrané kapitoly z analýzy prežívania

Testy na porovnanie dvoch kriviek prežívania

Siegel-Tukey test

Stredná hodnota a rozptyl S_{ST} (resp. S_{ST}^{alt}):

$$E_0 [S_{ST}] = \frac{n_1(n_1 + n_2 + 1)}{2}$$

$$\text{Var}_0 [S_{ST}] = \frac{n_1 n_2 (n_1 + n_2 + 1)}{12}$$

Siegel-Tukey test

Ak $n_1, n_2 \geq 10$

$$Z_{ST} = \frac{S_{ST} - E_0 [S_{ST}]}{\sqrt{\text{Var}_0 [S_{ST}]}} \sim N(0, 1)$$

Stanislav Katina

Vybrané kapitoly z analýzy prežívania

Testy na porovnanie dvoch kriviek prežívania

Siegel-Tukey test

Podstata Siegel-Tukey testu je nasledovná:

- poradie R_1 priradíme najmenšiemu pozorovaniu
- poradie R_2 priradíme najväčšiemu pozorovaniu
- poradie R_3 priradíme druhému najmenšiemu pozorovaniu
- poradie R_4 priradíme druhému najväčšiemu pozorovaniu atď.

Siegel-Tukey štatistika

$$S_{ST} = \sum_{i=1}^{n_1} R_i,$$

kde daná suma prislúcha súčtu poradí pre prvý NV

Stanislav Katina

Vybrané kapitoly z analýzy prežívania

Testy na porovnanie dvoch kriviek prežívania

Levene test

Podstata Leveneho alternatívy ST testu (Levene testu) je nasledovná:

- odchýlky $D_X = |X - \mu_X|$ a $D_Y = |Y - \mu_Y|$
- odchýlky $\{d_i = |x_i - \bar{x}|\}_{i=1}^{n_1}$ a $\{d_j = |y_j - \bar{y}|\}_{j=1}^{n_2}$
- $d_{(1)} < d_{(2)} < \dots < d_{(n)}, n = n_1 + n_2$

Levene štatistika

$$S_L = S_{ST}^{alt} = \sum_{i=1}^{n_1} R_{diff,(i)},$$

kde $R_{diff,(i)}$ predstavujú poradia odchýlok od priemeru pre prvý NV

Stanislav Katina

Vybrané kapitoly z analýzy prežívania

Testy na porovnanie dvoch kriviek prežívania

Levene test

Stredná hodnota a rozptyl S_{ST}^{alt} :

$$E_0 [S_{ST}] = E_0 [S_{ST}^{alt}] = \frac{n_1(n_1 + n_2 + 1)}{2}$$

$$\text{Var}_0 [S_{ST}] = \text{Var}_0 [S_{ST}^{alt}] = \frac{n_1 n_2 (n_1 + n_2 + 1)}{12}$$

Levene test

Ak $n_1, n_2 \geq 10$

$$Z_L = Z_{SL}^{alt} = \frac{S_{ST}^{alt} - E_0 [S_{ST}^{alt}]}{\sqrt{\text{Var}_0 [S_{ST}^{alt}]}} \sim N(0, 1)$$

Stanislav Katina

Vybrané kapitoly z analýzy prežívania

Testy na porovnanie dvoch kriviek prežívania

Príklad

| | | | | | | | | | | | | |
|-------------|----|-----|----|----|----|----|-----|-----|-----|-----|-----|----|
| t_{ij} | 52 | 240 | 19 | 53 | 15 | 43 | 340 | 133 | 111 | 231 | 378 | 49 |
| ψ_{ij} | 0 | 1 | 1 | 0 | 0 | 1 | 1 | 0 | 0 | 1 | 0 | 0 |

| | | | | | | | | | | | | |
|-------------|----|----|----|----|----|----|-----|-----|-----|-----|-----|-----|
| $t_{(i)}$ | 15 | 19 | 43 | 49 | 52 | 53 | 111 | 133 | 231 | 240 | 340 | 378 |
| ψ_{ij} | 0 | 1 | 1 | 0 | 0 | 0 | 0 | 0 | 1 | 1 | 1 | 0 |
| $R_i^{(1)}$ | 1 | - | - | 4 | 5 | 6 | 7 | 8 | - | - | - | 12 |
| $R_i^{(2)}$ | - | 2 | 3 | - | - | - | - | - | 9 | 10 | 11 | - |

Wilcoxon test

$$W_{X_2} = S_W = \sum_{i=1}^5 R_i^{(2)} = 35$$

$$E_0 [S_W] = \frac{5(7+5+1)}{2}$$

$$\text{Var}_0 [S_W] = \frac{7 \times 5(7+5+1)}{12}$$

$$Z_W = (35 - 32.5) / 6.157651 = 0.405999, \text{ p-hodnota}=0.6847$$

Stanislav Katina

Vybrané kapitoly z analýzy prežívania

Testy na porovnanie dvoch kriviek prežívania

Príklad

Example

Nech $t_{ij}, i = 1, \dots, n_j, j = 1, 2$ sú časy do zlyhania (úmrtia) od diagnostiky nádoru plúc v mesiacoch, kde $j = 1$ predstavuje I. typ terapie a $j = 2$ zasa II. typ terapie, nech $\psi_{ij} = 0$ ak $j = 1$ a $\psi_{ij} = 1$ ak $j = 2$ (pozri tab.). Otestujete $H_0 : S_1(t) = S_2(t)$, alternatíva $H_1 : S_1(t) \neq S_2(t)$. Použite aj S_{MW} , S_{ST} , S_{ST}^{alt} . Vždy presne naformulujte H_1 .

| | | | | | | | | | | | | |
|-------------|----|-----|----|----|----|----|-----|-----|-----|-----|-----|----|
| t_{ij} | 52 | 240 | 19 | 53 | 15 | 43 | 340 | 133 | 111 | 231 | 378 | 49 |
| ψ_{ij} | 0 | 1 | 1 | 0 | 0 | 1 | 1 | 0 | 0 | 1 | 0 | 0 |

Stanislav Katina

Vybrané kapitoly z analýzy prežívania

Testy na porovnanie dvoch kriviek prežívania

Príklad

Mann-Whitney test

$$S_{MW} = n_1 n_2 - \sum R_i^{(2)} + n_1(n_1 + 1)/2 = 20$$

$$E_0 [S_{MW}] = n_1 n_2 / 2 = 17.5,$$

$$\text{Var}_0 [S_{MW}] = n_1 n_2 (n_1 + n_2 + 1) / 12 = 37.91667$$

$$Z_{ST} = (20 - 17.5) / 37.91667 = 0.405999, \text{ p-hodnota}=0.6847$$

Siegel-Tukey test

| | | | | | | | | | | | | |
|-------------|----|-----|----|----|----|----|-----|-----|-----|-----|-----|----|
| t_{ij} | 52 | 240 | 19 | 53 | 15 | 43 | 340 | 133 | 111 | 231 | 378 | 49 |
| ψ_{ij} | 0 | 1 | 1 | 0 | 0 | 1 | 1 | 0 | 0 | 1 | 0 | 0 |
| $R_i^{(1)}$ | 9 | - | - | 11 | 1 | - | - | 10 | 12 | - | 2 | 7 |
| $R_i^{(2)}$ | - | 6 | 3 | - | - | 5 | 4 | - | - | 8 | - | - |

$$S_{ST} = \sum_{i=1}^5 R_i^{(2)} = 26$$

$$E_0 [S_{ST}] = \frac{5(7+5+1)}{2}, \text{ Var}_0 [S_W] = \frac{7 \times 5(7+5+1)}{12}$$

$$Z_{ST} = (26 - 32.5) / 6.157651 = -3.166792, \text{ p-hodnota}=0.2912$$

Stanislav Katina

Vybrané kapitoly z analýzy prežívania

Testy na porovnanie kriviek prežívania

Prehľad testov

Testované hypotézy

- **nulovná hypotéza** $H_0 : S_i(t) = S_j(t) = S(t)$

- **alternatíva hypotéza** $H_1 :$

- $S_i(t) \neq S_j(t)$ pre aspoň jedno i, j (**KW test**)

- $S_i(t) \stackrel{st}{\prec} S_j(t)$ (**J,C,L testy**)

- $S_i(t) \stackrel{st}{\succ} S_j(t)$ (**J,C,L testy**)

pre $\forall t, i < j, i, j = 1, 2, \dots, k$

k je počet porovnávaných kriviek prežívania

$S(t)$ je funkcia prežívania

$\stackrel{st}{\prec}$ a $\stackrel{st}{\succ}$ stochasticky menší, resp. stochasticky väčší

Stanislav Katina

Vybrané kapitoly z analýzy prežívania

Testy na porovnanie viacerých kriviek prežívania

Kruskall-Wallisov test

Rozptyl S_{KW} :

$$\text{Var}[R] = \frac{1}{n-1} \sum_{i=1}^k \sum_{j=1}^{n_i} \left(R_{ij} - \frac{n+1}{2} \right)^2$$

$$\begin{aligned} \text{Var}[R|t] &= \frac{1}{n-1} \sum_{i=1}^k \sum_{j=1}^{n_i} \left(R_{ij|t} - \frac{n+1}{2} \right)^2 \\ &= \frac{n(n+1)}{12} \left[1 - \frac{1}{n(n^2-1)} \sum_{j=1}^L t_j (t_j^2 - 1) \right] \end{aligned}$$

Kruskall-Wallisov test

$$\tilde{S}_{KW} = \frac{1}{\text{Var}[R|t]} \sum_{i=1}^k n_i \left(\frac{R_i}{n_i} - \frac{n+1}{2} \right)^2 \sim \chi_{k-1}^2$$

Stanislav Katina

Vybrané kapitoly z analýzy prežívania

Testy na porovnanie viacerých kriviek prežívania

Kruskall-Wallis test

Označenia

- n_i je počet pozorovaní v i -tom NV, $i = 1, 2, \dots, k$

- $n = \sum_{i=1}^k n_i$

- $R_i = \sum_{j=1}^{n_i} R_{ij}$, $R = \sum_{i=1}^k R_i$, $\bar{R}_i = R_i/n_i$,
 $\bar{R} = R/n = (n+1)/2$

Kruskall-Wallisova testovacia štatistika

$$\begin{aligned} S_{KW} &= \frac{12}{n(n+1)} \sum_{i=1}^k n_i \left(\frac{R_i}{n_i} - \frac{n+1}{2} \right)^2 \\ &= \frac{12}{n(n+1)} \sum_{i=1}^k \frac{R_i^2}{n_i} - 3(n+1) \\ &= \frac{1}{\text{Var}[R]} \left(\sum_{i=1}^k \frac{R_i^2}{n_i} - \frac{n(n+1)^2}{4} \right) \sim \chi_{k-1}^2 \end{aligned}$$

Stanislav Katina

Vybrané kapitoly z analýzy prežívania

Testy na porovnanie viacerých kriviek prežívania

Jonckheere test

Označenia

- $i < j$, teda $i = 1, 2, \dots, k-1; j = 1+i, \dots, k$, ďalej
 $\alpha_i = 1, 2, \dots, n_i$, $\alpha_j = 1, 2, \dots, n_j$

- nech S_{MW}^{ij} je Mann-Whitney štatistika porovnávajúca i -ty a j -ty výber

$$S_{MW}^{ij} = \#(x_{i\alpha_i}, x_{j\alpha_j}), \text{ kde } x_{i\alpha_i} < x_{j\alpha_j}$$

Jonckheere štatistika

$$S_J = \sum_{i < j} S_{MW}^{ij} = \sum_{i=1}^{k-1} \sum_{j=1+i}^k S_{MW}^{ij}$$

Stanislav Katina

Vybrané kapitoly z analýzy prežívania

Testy na porovnanie viacerých krviek prežívania

Jonckheere test

Stredná hodnota a rozptyl S_J :

$$E_0 [S_J] = \frac{n^2 - \sum n_i^2}{4}$$

$$\text{Var}_0 [S_J] = \frac{n^2 (2n + 3) - \sum n_i^2 (2n_i + 3)}{72}$$

Jonckheere test

$$Z_J = \frac{S_J - E_0 [S_J]}{\sqrt{\text{Var}_0 [S_J]}} \sim N(0, 1)$$

Stanislav Katina

Vybrané kapitoly z analýzy prežívania

Testy na porovnanie viacerých krviek prežívania

Zovšeobecnený Kendallov korelačný koeficient

Označenia

- nech $(X_1, Y_1)^T, \dots, (X_n, Y_n)^T$ NV z dvojrozmerného rozdelenia
- realizácie $(x_i, y_i)^T, i = 1, 2, \dots, n$
- dvojicu jednotiek s indexami i a j , (x_i, y_i) a (x_j, y_j) , nazveme
 - **konkordantná** (usporiadaná) pokiaľ platí $x_i < x_j \wedge y_i < y_j$ alebo $x_i > x_j \wedge y_i > y_j$
 - **diskordantná** (neusporiadaná) pokiaľ platí $x_i < x_j \wedge y_i > y_j$ alebo $x_i > x_j \wedge y_i < y_j$
 - ak platí $x_i = x_j$ alebo $y_i = y_j$, nejde ani o konkordantný ani o diskordantný vzťah
- $C + D \leq n(n - 1)$, C je počet konkordantných dvojíc, D počet diskonkordantných dvojíc medzi $(x_1, y_1), \dots, (x_n, y_n)$

Stanislav Katina

Vybrané kapitoly z analýzy prežívania

Testy na porovnanie viacerých krviek prežívania

Jonckheere test

Alternatívna podoba Jonckheere štatistiky

$$\tilde{S}_J = 2 \sum_{i=1}^{k-1} \sum_{j=1+i}^k S_{MW}^{ij} - \sum_{i=1}^{k-1} \sum_{j=1+i}^k n_i n_j,$$

kde $\sum_{i=1}^{k-1} \sum_{j=1+i}^k n_i n_j = \max_{\forall S} S_J$

Stredná hodnota a rozptyl \tilde{S}_J :

$$E[\tilde{S}_J] = 0, \text{Var}_0 [\tilde{S}_J] = \frac{n^2 (2n + 3) - \sum n_i^2 (2n_i + 3)}{18}$$

Alternatívna podoba Jonckheere testu

$$\tilde{Z}_J = \frac{\tilde{S}_J - E_0 [\tilde{S}_J]}{\sqrt{\text{Var}_0 [\tilde{S}_J]}} \sim N(0, 1)$$

Stanislav Katina

Vybrané kapitoly z analýzy prežívania

Testy na porovnanie viacerých krviek prežívania

Zovšeobecnený Kendallov korelačný koeficient

Kendallov korelačný koeficient

$$\tau = \frac{1}{n(n-1)} \sum_{i=1}^n \sum_{j=1}^n \text{sign}(x_i - x_j) \text{sign}(y_i - y_j),$$

čo je identické s

$$\tilde{\tau} = \frac{2}{n(n-1)} \sum_{i=1}^{n-1} \sum_{j=i+1}^n \text{sign}(x_i - x_j) \text{sign}(y_i - y_j),$$

kde

$$\text{sign}(x_i - x_j) = \begin{cases} 1 & \text{ak } x_i > x_j \\ -1 & \text{ak } x_i < x_j \\ 0 & \text{ak } x_i = x_j \end{cases}$$

$$\text{sign}(y_i - y_j) = \begin{cases} 1 & \text{ak } y_i > y_j \\ -1 & \text{ak } y_i < y_j \\ 0 & \text{ak } y_i = y_j \end{cases}$$

Stanislav Katina

Vybrané kapitoly z analýzy prežívania

Testy na porovnanie viacerých krviek prežívania

Zovšeobecnený Kendallov korelačný koeficient

Poradovú alternatíva Kendallovho korelačného koeficientu

- nech R_1, \dots, R_n sú poradia veličín x_1, \dots, x_n
- nech Q_1, \dots, Q_n sú poradia veličín y_1, \dots, y_n

Potom platí

$$\tau = \frac{1}{n(n-1)} \sum_{i=1}^n \sum_{j=1}^n \text{sign}(R_i - R_j) \text{sign}(Q_i - Q_j),$$

čo je identické s

$$\tilde{\tau} = \frac{2}{n(n-1)} \sum_{i=1}^{n-1} \sum_{j=i+1}^n \text{sign}(R_i - R_j) \text{sign}(Q_i - Q_j)$$

Platí

$$\tilde{\tau} \in \langle -1, 1 \rangle, E[\tilde{\tau}] = 0, \text{Var}[\tilde{\tau}] = \frac{2(2n+5)}{9n(n-1)}$$

a

$$Z_{\tilde{\tau}} = \frac{\tilde{\tau}}{\sqrt{\text{Var}[\tilde{\tau}]}} \sim N(0, 1)$$

Stanislav Katina

Vybrané kapitoly z analýzy prežívania

Testy na porovnanie viacerých krviek prežívania

Zovšeobecnený Kendallov korelačný koeficient

Example

Majme pacientov s akútnou myeloidnou leukémiou (AML) a v rámci nich skupinu AG-pozitívnych (výskyt určitých špecifických indikátorov choroby v kostnej dreni). Pre chorobu je charakteristické, že s počtom bielych krvinek (white blood cells counts, WBC) vzrastná závažnosť choroby. Nech $t_i, i = 1, 2, \dots, 17$ sú časy do zlyhania v týždňoch prislúchajúce zoradeným WBC (pozri tab.). Vypočítajte τ , $\tilde{\tau}$ a R_S . Otestujte nezávislosť medzi počtom bielych krvinek a časmi do zlyhania.

Testy na porovnanie viacerých krviek prežívania

Zovšeobecnený Kendallov korelačný koeficient

Vzťah Kendallovho a Pearsonovho korelačného koeficientu

Ak $(X, Y) \sim N_2(\mu, \Sigma)$ a $\rho_{X,Y}$, potom $\tau = \frac{2}{\pi} \arcsin(\rho_{X,Y})$, kde \arcsin nadobúda hodnoty z $\langle -\frac{\pi}{2}, \frac{\pi}{2} \rangle$

Vzťah Kendallovho korelačného koeficientu a Jonckheere štatistiky

$$\tau = \frac{\tilde{S}_J}{\sum_{i=1}^{k-1} \sum_{j=1+i}^k n_i n_j}, \tau \in \langle -1, 1 \rangle,$$

kde τ nazývame **zovšeobecnený Kendallov korelačný koeficient**

Stanislav Katina

Vybrané kapitoly z analýzy prežívania

Testy na porovnanie viacerých krviek prežívania

Zovšeobecnený Kendallov korelačný koeficient

| WBC | t_i | C_{ij} | D_{ij} |
|--------|-------|----------|----------|
| 750 | 156 | 0 | 16 |
| 2300 | 65 | 5 | 9 |
| 2600 | 134 | 1 | 13 |
| 4300 | 100 | 3 | 10 |
| 5400 | 39 | 5 | 7 |
| 6000 | 16 | 7 | 4 |
| 7000 | 143 | 0 | 10 |
| 9400 | 56 | 3 | 6 |
| 10000 | 121 | 0 | 8 |
| 10500 | 108 | 0 | 7 |
| 17000 | 4 | 4 | 2 |
| 32000 | 26 | 1 | 4 |
| 35000 | 22 | 1 | 3 |
| 52000 | 5 | 1 | 2 |
| 100000 | 1 | 1 | 0 |
| 100000 | 1 | 1 | 0 |
| 100000 | 65 | 0 | 0 |

$$C_{ij} = \#(\uparrow t_i, \uparrow WBC_i) \text{ pod } i$$

$$C = \sum C_{ij} = 33$$

$$D_{ij} = \#(\downarrow t_i, \uparrow WBC_i) \text{ pod } i$$

$$D = \sum D_{ij} = 101$$

$$\frac{n(n-1)}{2} = \frac{17 \times 16}{2}$$

$$\tilde{\tau} = \frac{C-D}{\frac{n(n-1)}{2}} = -0.5$$

$$\text{Var}[\tilde{\tau}] = \frac{2(2 \times 17 + 5)}{9 \times 17(17-1)} = 0.032$$

$$Z_{\tilde{\tau}} = -0.5 / \sqrt{0.032} = -2.801$$

$$\text{p-hodnota}=0.002$$

Stanislav Katina

Vybrané kapitoly z analýzy prežívania

Stanislav Katina

Vybrané kapitoly z analýzy prežívania

Testy na porovnanie viacerých krviek prežívania

Cuzick test

Označenia

- nech R_{ij} je poradie ij -teho pozorovania v združenom NV
- nech z_{ij} je skóre prislúchajúce NV, do ktorého ij -te pozorovanie patrí
- $n = \sum_{j=1}^k n_j$

Cuzickova štatistika

$$S_C = \sum_{i=1}^{n_i} \sum_{j=1}^k z_{ij} R_{ij},$$

Stanislav Katina

Vybrané kapitoly z analýzy prežívania

Testy na porovnanie viacerých krviek prežívania

Zovšeobecnený Spearmanov korelačný koeficient

Označenia

- nech $(X_1, Y_1)^T, \dots, (X_n, Y_n)^T$ je výber z dvojrozmerného rozdelenia
- nech R_1, \dots, R_n sú poradia veličín X_1, \dots, X_n
- nech Q_1, \dots, Q_n sú poradia veličín Y_1, \dots, Y_n

Spearmanova štatistika

$$S_N = \sum_{i=1}^n R_i Q_i$$

Stanislav Katina

Vybrané kapitoly z analýzy prežívania

Testy na porovnanie viacerých krviek prežívania

Cuzick test

Stredná hodnota

$$E_0 [S_C] = \left(\sum_{i=1}^n i \right) E [Z] = \frac{1}{2} n(n+1) E [Z],$$

kde $E [Z] = \sum_{j=1}^k z_j p_j$, k je počet skupín, $z_{ij} = z_j = j$, $p_j = n_j/n$

Rozptyl

$$\text{Var} [S_C] = \left[\frac{n^2(n+1)}{12} \right] \text{Var} [Z],$$

kde $\text{Var} [Z] = \sum_{j=1}^k z_j^2 p_j - (E [Z])^2$

Cuzickov test

$$Z_C = \frac{S_C - E_0 [S_C]}{\sqrt{\text{Var}_0 [S_C]}} \sim N(0, 1)$$

Stanislav Katina

Vybrané kapitoly z analýzy prežívania

Testy na porovnanie viacerých krviek prežívania

Zovšeobecnený Spearmanov korelačný koeficient

Stredná hodnota

$$E [S_N] = n \left(\frac{n+1}{2} \right)^2$$

Rozptyl

$$\text{Var} [S_N] = \frac{1}{n-1} \left(\frac{n(n^2-1)}{12} \right)^2$$

Spearmanov test

$$\sqrt{n-1} R_S \sim N(0, 1),$$

kde $R_S = \frac{1}{\sqrt{(n-1)\text{Var}[S_N]}} (S_N - E [S_N])$, $E [R_S] = 0$,
 $\text{Var} [R_S] = \frac{1}{n-1}$

Stanislav Katina

Vybrané kapitoly z analýzy prežívania

Testy na porovnanie viacerých krviek prežívania

Zovšeobecnený Spearmanov korelačný koeficient

Vzťah Spearmanovho a Pearsonovho korelačného koeficientu

Ak $(X_1, Y_1)^T, \dots, (X_n, Y_n)^T$ je výber z dvojrozmerného normálneho rozdelenia s korelačným koeficientom $\rho_{X,Y}$, potom platí

$$\rho_{X,Y} = 2 \sin\left(\frac{\pi}{6}\right) R_S$$

Vzťah Spearmanovho korelačného koeficientu a Cuzickovej štatistiky

Cuzickova štatistika S_C je rovná Spearmanovej štatistike S_N , kde jedna premenná predstavuje zoradenú (ordinálnu) premennú a druhá spojitú premennú

Stanislav Katina

Vybrané kapitoly z analýzy prežívania

Testy na porovnanie viacerých krviek prežívania

Le test

Stredná hodnota

$$E [S_L] = 0$$

Rozptyl

$$\text{Var} [S_L] = \frac{n(n+1)}{12} \sum_{i=1}^k n_i (L_i - M_i)^2$$

Le test

$$Z_L = \frac{S_L - E_0 [S_L]}{\sqrt{\text{Var}_0 [S_L]}} \sim N(0, 1)$$

Stanislav Katina

Vybrané kapitoly z analýzy prežívania

Testy na porovnanie viacerých krviek prežívania

Le test

Označenia

- n_i je rozsah i -teho NV
- $L_i = \sum_{j < i} n_j = \#$ pozorovaní vo všetkých výberoch naľavo od i -teho výberu, $L_1 = 0$
- $M_i = \sum_{j > i} n_j = \#$ pozorovaní vo všetkých výberoch napravo od i -teho výberu, $M_k = 0$
- $L_i - M_i \in (-n, n)$
- \bar{R}_i je priemerné poradie pre i -ty výber

Le štatistika

$$S_L = \sum_{i=1}^k n_i (L_i - M_i) \bar{R}_i$$

Stanislav Katina

Vybrané kapitoly z analýzy prežívania

Testy na porovnanie viacerých krviek prežívania

Zovšeobecnenia

Test odchlonu od trendu

$$S_{KW} - \frac{S_L^2}{\text{Var} [S_L]} \sim \chi_{k-2}^2$$

Všeobecný tvar testovacej štatistiky

$$S_A = \sum_{i=1}^k n_i s_i r_i,$$

kde n_i sú rozsahy jednotlivých NV, s_i skóre prislúchajúce jednotlivým NV a r_i sú priemerné charakteristiky polohy prislúchajúce jednotlivým NV

Potom

$$\frac{(S_A - E_0 [S_A])^2}{\text{Var}_0 [S_A]} \sim \chi_1^2$$

Stanislav Katina

Vybrané kapitoly z analýzy prežívania

Testy na porovnanie viacerých krviek prežívania

Príklad

Example (pokrač.)

Nech $t_{ij}, i = 1, \dots, n_j, j = 1, 2$ sú časy do zlyhania (úmrtia) od diagnostiky nádoru plúc v mesiacoch, kde $j = 1$ predstavuje I. typ terapie a $j = 2$ zasa II. typ terapie, nech $\psi_{ij} = 0$ ak $j = 1$ a $\psi_{ij} = 1$ ak $j = 2$ (pozri tab.). Otestujte $H_0 : S_1(t) = S_2(t)$, alternatíva $H_1 : S_1(t) \neq S_2(t)$. Použite aj S_{KW} , S_J , S_C . Vždy presne naformulujte H_1 .

| | | | | | | | | | | | | |
|-------------|----|-----|----|----|----|----|-----|-----|-----|-----|-----|----|
| t_{ij} | 52 | 240 | 19 | 53 | 15 | 43 | 340 | 133 | 111 | 231 | 378 | 49 |
| ψ_{ij} | 0 | 1 | 1 | 0 | 0 | 1 | 1 | 0 | 0 | 1 | 0 | 0 |

$$S_{KW} = S_W$$

$$S_J = S_{MW}$$

$$S_{MW} = S_C$$

Stanislav Katina

Vybrané kapitoly z analýzy prežívania

Testy na porovnanie viacerých krviek prežívania

Príklad

Rozdeľme AG-pozitívnych pacientov do troch skupín nasledovne

- Skupina 1: WBC ≥ 100000 , $n_1 = 3$, (1, 1, 65)
- Skupina 2: WBC $\in (10000, 100000)$, $n_2 = 6$, (108, 121, 4, 26, 22, 5),
- Skupina 3: WBC < 10000 , $n_3 = 8$, (65, 156, 100, 134, 16, 39, 143, 56)

| | | | | | | | | |
|---------|-----|-----|---|---|----|----|----|----|
| sk.1 | 1 | 1 | | | | | | |
| sk.2 | | | 4 | 5 | | 22 | 26 | |
| sk.3 | | | | | 16 | | | 39 |
| poradie | 1.5 | 1.5 | 3 | 4 | 5 | 6 | 7 | 8 |

| | | | | | | | | |
|---------|----|------|-----|-----|-----|-----|-----|-----|
| sk.1 | | 65 | | | | | | |
| sk.2 | | | | 108 | 121 | | | |
| sk.3 | 56 | 65 | 100 | | | 134 | 143 | 156 |
| poradie | 9 | 10.5 | 12 | 13 | 14 | 15 | 16 | 17 |

Stanislav Katina

Vybrané kapitoly z analýzy prežívania

Testy na porovnanie viacerých krviek prežívania

Príklad

Example (pokrač.)

Majme pacientov s akútou myeloidnou leukémiou (AML) a v rámci nich skupinu AG-pozitívnych (výskyt určitých špecifických indikátorov choroby v kostnej dreni). Pre chorobu je charakteristické, že s počtom bielych krviniek (white blood cells counts, WBC) vzrastná závažnosť choroby. Nech $t_i, i = 1, 2, \dots, 17$ sú časy do zlyhania v týždňoch (pozri tab.). Otestujte $H_0 : S_1(t) = S_2(t) = S_3(t)$, alternatíva a)

- $H_1 : S_i(t) \neq S_j(t), i < j; i, j = 1, 2, 3$, b) $S_1(t) \stackrel{st}{\succ} S_2(t) \stackrel{st}{\succ} S_3(t)$,
c) $S_1(t) \stackrel{st}{\prec} S_2(t) \stackrel{st}{\prec} S_3(t)$.

Stanislav Katina

Vybrané kapitoly z analýzy prežívania

Testy na porovnanie viacerých krviek prežívania

Príklad

$$\bar{R}_1 = 4.50, \bar{R}_2 = 7.833, \bar{R}_3 = 11.5625$$

$$S_{KW} = \frac{12}{n(n+1)} \sum_{i=1}^k \frac{R_i^2}{n_i} - 3(n+1) = \\ \frac{12}{17 \times 18} \left[3 \times 4.5^2 + 6 \times 7.833^2 + 8 \times 11.5625^2 \right] - 3 \times 18 = \\ 4.762662, \text{ p-hodnota} = 0.0924$$

$$S_L = \sum_{i=1}^3 n_i (L_i - M_i) \bar{R}_i = \\ 3 \times (0-14) \times 4.5 + 6 \times (3-8) \times 7.833 + 8 \times (9-0) \times 11.5625 = 408.5$$

$$\text{Var}[S_L] = \frac{n(n+1)}{12} \sum_{i=1}^k n_i (L_i - M_i)^2 = \\ \frac{17(17+1)}{12} \left[3 \times (0-14)^2 + 6 \times (3-8)^2 + 8 \times (9-0)^2 \right] = 187.9973^2$$

$$Z_L = 408.5 / 187.9973 = 2.172903, \text{ p-hodnota} = 0.0298$$

$$S_{KW} - (Z_L)^2 = 4.762662 - 2.172903^2 = 0.0412, \\ \text{p-hodnota} = 0.8392$$

Stanislav Katina

Vybrané kapitoly z analýzy prežívania

Testy na porovnanie dvoch kriviek prežívania

Cenzúrované dáta–prehľad

Formulácie sčítacím procesom

- (X_i, δ_i) nahradíme $(N_i(t), Y_i(t))$, kde $N_i(t)$ je počet pozorovaných udalostí v intervale $\langle 0, t \rangle$ v jednotke i ,

$$Y_i(t) = \begin{cases} 1 & \text{jednotka } i \text{ je v riziku v čase } t \\ 0 & \text{inak} \end{cases}$$

- $Y_i(t) = I(\{T_i \geq t\})$ a $N_i(t) = I(\{T_i \leq t, \delta_i = 1\})$
- agregovaný proces $\bar{Y}(t) = \sum_i Y_i(t)$, $\bar{N}(t) = \sum_i N_i(t)$, $d\bar{N}(t) = \Delta\bar{N}(t) = \bar{N}(t) - \bar{N}(t^-)$, kde $\bar{N}(t)$ je suma udalostí do času t vrátane, $\bar{Y}(t)$ je počet jednotiek v riziku v čase t

Stanislav Katina

Vybrané kapitoly z analýzy prežívania

Testy na porovnanie dvoch kriviek prežívania

Cenzúrované dáta–prehľad

Potom asymptoticky

$$\frac{T(W, t) - E_0[T(W, t)]}{\sqrt{\text{Var}_0[T(W, t)]}} \sim N(0, 1)$$

Testy na porovnanie dvoch kriviek prežívania

Cenzúrované dáta–prehľad

Testovacia štatistika na porovnanie dvoch kriviek prežívania

$$T(W, t) = \int_0^t W(s) \frac{\bar{Y}_1(s)\bar{Y}_2(s)}{\bar{Y}_1(s)+\bar{Y}_2(s)} \left(\frac{d\bar{N}_1(s)}{\bar{Y}_1(s)} - \frac{d\bar{N}_2(s)}{\bar{Y}_2(s)} \right) ds,$$

kde $W(s)$ je funkcia váh a $s \geq 0$

- **stredná hodnota** $E_0[T(W, t)] = 0$
- **rozptyl**

$$\begin{aligned} \text{Var}_0[T(W, t)] &= \sum_{i=1}^2 \int_0^t \frac{W^2(s)}{\bar{Y}_i(s)} \left(\frac{\bar{Y}_1(s)\bar{Y}_2(s)}{\bar{Y}_1(s)+\bar{Y}_2(s)} \right)^2 \\ &\times \left(1 - \frac{\Delta\bar{N}_1(s) + \Delta\bar{N}_2(s) - 1}{\bar{Y}_1(s) + \bar{Y}_2(s) - 1} \right) \\ &\times \left(\frac{\Delta\bar{N}_1(s) + \Delta\bar{N}_2(s)}{\bar{Y}_1(s) + \bar{Y}_2(s)} \right) ds \end{aligned}$$

Stanislav Katina

Vybrané kapitoly z analýzy prežívania

Testy na porovnanie dvoch kriviek prežívania

Cenzúrované dáta–prehľad

Tarone a Ware (1977) trieda váh

- konštantný rozdiel v **logitovej** škále $f(p) = \ln \frac{p}{1-p}$, potom váhy $W(t) = 1$
 - konštantný rozdiel v **aritmetickej** škále: $f(p) = p$, potom váhy $W(t) = (\frac{1/\bar{Y}(t)}{1-1/\bar{Y}(t)})^{-1} = \bar{Y}^2(t)/(\bar{Y}(t)-1) \approx \bar{Y}(t)$
 - konštantný rozdiel v **arcsin** škále: $f(p) = \arcsin \sqrt{p}$, potom sú váhy rovné $W(t) = \frac{\bar{Y}(t)}{\sqrt{\bar{Y}(t)-1}} \approx \sqrt{\bar{Y}(t)}$ kde $p_t = 1/\bar{Y}(t)$ a $\bar{Y}(t)$ počet osôb v riziku v združenom výbere v čase t
- Vo všeobecnosti môžeme váhy zapísť ako $W(t) = g(\bar{Y}(t)/n)$

Stanislav Katina

Vybrané kapitoly z analýzy prežívania

Stanislav Katina

Vybrané kapitoly z analýzy prežívania

Testy na porovnanie dvoch kriviek prežívania

Cenzúrované dáta–prehľad

Harrington a Fleming (1982) trieda váh $W(t) = \hat{S}^\rho(t)$, $\rho \geq 0$

- ① $\rho = 0$, a teda $W(t) = \hat{S}^0(t) = 1$ (**Cox-Mantel test** alebo **log-rank test**; Cox, 1972; Mantel, 1966)
- ② $\rho = 1$, a teda $W(t) = \hat{S}^1(t) = \hat{S}(t)$ (**Gehan-Wilcoxon test** alebo **Peto-Peto-Wilcoxon test**, Gehan, 1965; Peto a Peto, 1972)

Stanislav Katina

Vybrané kapitoly z analýzy prežívania

Testy na porovnanie dvoch kriviek prežívania

Zovšeobecnený Wilcoxon test

Označenia

- majme dva náhodné výbery s rozsahmi n_1 a n_2
- prvý výber má r_1 cenzúr a $n_1 - r_1$ zlyhaní
- druhý výber r_2 cenzúr a $n_2 - r_2$ zlyhaní
- realizácie

$$\underbrace{x_{j1}^{(c)}, x_{j2}^{(c)}, \dots, x_{jr_j}^{(c)}}_{\text{cenzúry}}, \underbrace{x_{jr_j+1}, x_{jr_j+2}, \dots, x_{jn_j}}_{\text{zlyhania}}, j = 1, 2$$

Testovacia štatistika $S_W^{(c)} = \sum_{i,j} U_{ij}$, kde

$$U_{ij} = \begin{cases} -1, & \text{ak } x_{1i} < x_{2j} \vee x_{1i} \leq x_{2j}^{(c)} \\ 0, & \text{ak } x_{1i} = x_{2j} \vee x_{1i}^{(c)} = x_{2j}^{(c)} \vee x_{1i}^{(c)} < x_{2j} \vee x_{1i} > x_{2j}^{(c)} \\ +1, & \text{ak } x_{1i} > x_{2j} \vee x_{1i}^{(c)} \geq x_{2j} \end{cases},$$

kde sumujeme cez všetkých $n_1 n_2$ porovnávaní

Stanislav Katina

Vybrané kapitoly z analýzy prežívania

Testy na porovnanie dvoch kriviek prežívania

Cenzúrované dáta–prehľad

Formálna formulácia

Testovacia štatistika na porovnanie dvoch kriviek prežívania

$$T(W, t) = \sum_{j=0}^t W_j \left(d_{1j} - d_j \frac{n_{1j}}{n_k} \right),$$

potom

- **stredná hodnota** $E_0[T(W, t)] = 0$
- **rozptyl**

$$Var_0[T(W, t)] = \sum_{j=0}^t W_j^2 \frac{n_{1j}}{n_j} \left(1 - \frac{n_{1j}}{n_j} \right) \frac{d_j(n_j - d_j)}{n_j - 1}$$

Stanislav Katina

Vybrané kapitoly z analýzy prežívania

Testy na porovnanie dvoch kriviek prežívania

Zovšeobecnený Wilcoxon test

Ak nemáme prítomné cenzúry, $S_W^{(c)}$ sa redukuje na **Wilcoxonovu štatistiku** S_W , **Mann-Whitneho štatistiku** S_{MW} a **Kendallovo τ** nasledovne

$$S_W^{(c)} = n_2(n_1 + n_2 + 1) - 2S_W = 2S_{MW} - n_1 n_2 = \tau,$$

kde S_W je suma poradí druhého výberu v združenom výbere, $S_{MW} = \#(x_{1i}, x_{2j})$, $x_{1i} < x_{2j}$ a posledná rovnosť platí aj v prítomnosti zhôd

$S_W^{(c)}$ je možné zjednodušiť ak všetky cenzúry nastali v čase t_n (Halperin, 1960), teda

$$S_W^{(c)} = 2S^{(z)} + r_1 r_2 - n_1 n_2,$$

kde $S^{(z)} = S_{MW}^{(z)} - r_1(n_2 - r_2)$, $S_{MW}^{(z)}$ je Mann-Whitney štatistika počítaná len na základe $(n_1 - r_1) + (n_2 - r_2)$ zlyhaní

Stanislav Katina

Vybrané kapitoly z analýzy prežívania

Testy na porovnanie dvoch kriviek prežívania

Zovšeobecnený Wilcoxon test

Za platnosti H_0 platí

- stredná hodnota $E_0[S_W^{(c)}] = 0$
- rozptyl

$$\begin{aligned} \text{Var}_0[S_W^{(c)}] &= \\ \frac{n_1 n_2}{n(n-1)} &\left\{ \sum_{j=1}^L d_j D_{j-1} (D_{j-1} + 1) + \sum_{j=1}^L l_j D_j (D_j + 1) \right. \\ &+ \left. \sum_{j=1}^L (d_j(n - D_j - L_{j-1})(n - 3D_{j-1} - d_i - L_{j-1} - 1)) \right\}, \end{aligned}$$

kde $n_1 + n_2 = n$, $D_i = \sum_{j=1}^i d_j$, $D_0 = 0$, $L_i = \sum_{j=1}^i l_j$, $L_0 = 0$,
 d_j je počet necenzúrovaných pozorovaní (zlyhaní) s
poradím j (R_j) v zdrúženom výbere zlyhaní, l_j je počet
cenzúr z intervalu (R_j, R_{j+1})

Stanislav Katina

Vybrané kapitoly z analýzy prežívania

Testy na porovnanie dvoch kriviek prežívania

Zovšeobecnený Wilcoxon test vs. kontingenčné tabuľky

Majme špeciálny prípad, kde

- $d_1 = d$, $l_1 = l$, $d_j = l_j = 0$ pre $i \neq 0$
- pozorovania usporiadajme do **kontingenčnej tabuľky** (KT) 2×2 s fixovanými marginálnymi početnosťami ako výsledok náhodného výberu z **hypergeometrického rozdelenia**
- následne sa testovacia štatistika $S_W^{(c)}$ redukuje na **rozdiel súčinov diagonálnych a mimodiagonálnych prvkov**, čo je v úzkom vzťahu ku **pomeru šancí**
- rozptyl** $\text{Var}_0[S_W^{(c)}] = \frac{l d n_1 n_2}{n_1 + n_2 - 1}$

Stanislav Katina

Vybrané kapitoly z analýzy prežívania

Testy na porovnanie dvoch kriviek prežívania

Zovšeobecnený Wilcoxon test

Ak **nemáme žiadne zhody**, $d_1 = \dots = d_L = 1$, ako aj žiadne cenzúry, $l_1 = \dots = l_L = 0$ ($L = n$), potom

$$\text{Var}_0[S_W^{(c)}] = \frac{1}{3} n_1 n_2 (n + 1)$$

Ak **nemáme zhody a všetky cenzúry sa objavili po**

$L = (n_1 - r_1) + (n_2 - r_2)$ **zlyhaniach**, teda
 $d_1 = \dots = d_L = 1$, $l_1 = \dots = l_{L-1} = 0$, $l_L = r_1 + r_2$.

$$\text{Var}_0[S_W^{(c)}] = \frac{n_1 n_2 (n - r_1 - r_2)}{n(n-1)} \left(n(r_1 + r_2) + \frac{1}{3} ((n - r_1 - r_2)^2 - 1) \right)$$

Ak **máme len zlyhania, ale vyskytujú sa zhody**, dostaneme (Hemelrijk, 1952)

$$\text{Var}_0[S_W^{(c)}] = \text{Var}_0[S_{MW} | \mathbf{t}] = \text{Var}_0[S_{MW}] - \frac{n_1 n_2 \sum_j t_j (t_j^2 - 1)}{12(n_1 + n_2)(n_1 + n_2 - 1)}$$

Stanislav Katina

Vybrané kapitoly z analýzy prežívania

Testy na porovnanie dvoch a viac kriviek prežívania

Kontingenčné tabuľky

KT 2×2

| | y_1 | y_2 | \sum |
|--------|----------|----------|--------|
| x_1 | a | b | n_1 |
| x_2 | c | d | n_2 |
| \sum | $n_{.1}$ | $n_{.2}$ | 1 |

početnosti $n_{j.}$, $n_{.j}$, $j = 1, 2$ sa nazývajú marginálne početnosti a sú v tomto prípade fixované

χ^2 **test nezávislosti** (alebo **homogeneity**) pre KT 2×2

$$\chi^2 = \left(\frac{a - E_0[A]}{\sqrt{\text{Var}_0[A]}} \right)^2 \sim \chi^2_{df}, df = 1,$$

kde a je početnosť v prvej bunke KT

Stanislav Katina

Vybrané kapitoly z analýzy prežívania

Testy na porovnanie dvoch a viac kriviek prežívania

Kontingenčné tabuľky

Kombinovanie L jednoduchých KT (Gart, 1970; Cox, 1972) v L časoch zlyhania do **mnohorozmernej (L -rozmernej) KT**

- pre **dvojvýberový prípad** je KT $(2 \times 2) \times L$
- pre **k -rozmerný prípad** je KT $(2 \times k) \times L$

Použitý χ^2 test porovnania nezávislých kriviek prežívania bude potom formálne identický s **Birch-Armitage štatistikou asociácie týchto KT** (Mantel, 1966; Birch, 1965; Armitage, 1966)

χ^2 test pre kombináciu L KT $2 \times k$ (Mantel a Haenszel, 1959)

$$\chi^2 = \left(\frac{\sum_{i=1}^L (a_i - E_0[A_i])}{\sqrt{\sum_{i=1}^L \text{Var}_0[A_i]}} \right)^2 \sim \chi^2_{df}, df = k - 1$$

Stanislav Katina

Vybrané kapitoly z analýzy prežívania

Testy na porovnanie dvoch kriviek prežívania

Prehľad testov

Testované hypotézy

$$H_0 : \lambda_1(t) = \lambda_2(t), H_1 : \lambda_1(t) = \theta \lambda_2(t),$$

$$H_0 : S_1(t) = S_2(t), H_1 : S_1(t) = [S_2(t)]^\theta$$

kde

- $\lambda(t)$ je riziko v čase t
- θ neznáma konštantá proporcionality rizík

Ak $\theta < 1$, liečba 1 je efektívnejšia ako liečba 2, naopak v prípade $\theta > 1$

Stanislav Katina

Vybrané kapitoly z analýzy prežívania

Testy na porovnanie dvoch kriviek prežívania

Prehľad testov

Pre každé $t_{(i)}, 1 \leq i \leq I$, môžeme dátá zapísat do KT 2×2

| výber/status | zlyhanie v $t_{(i)}$ | nažive v $t_{(i)}$ | spolu v $t_{(i)}$ |
|--------------|----------------------|--------------------|-------------------|
| 1 | d_{1i} | a_{1i} | n_{1i} |
| 2 | d_{2i} | a_{2i} | n_{2i} |
| spolu | d_i | a_i | n_i |

- $n_{1i} = \#$ subjektov v prvom NV, ktorí boli v riziku tesne pred časom $t_{(i)}$, $n_{2i} = \#$ subjektov v druhom NV, ktorí boli v riziku tesne pred časom $t_{(i)}$, $n_i = n_{1i} + n_{2i}$
- $d_{1i} = \#$ zlyhaní z prvého NV, $d_{2i} = \#$ zlyhaní z druhého NV, $d_i = d_{1i} + d_{2i}$
- $a_i = n_i - d_i = a_{1i} + a_{2i} = \#$ subjektov, ktorí ostali nažive v čase $t_{(i)}$
- $\#$ zlyhaní do času $t_{(i)}$ vrátane $d = \sum_{j:t_j \leq t_{(i)}} d_j$

Stanislav Katina

Vybrané kapitoly z analýzy prežívania

Testy na porovnanie dvoch kriviek prežívania

Prehľad testov

- marginálne početnosti v tab., n_{1i} , n_{2i} a d_i sú náhodné premenné závislé iba na minulosť pred časom $t_{(i)}$
- Mantel a Haenzel (1959): **rozdelenie pozorovaní (realizácií) v bunkách KT podmienené pozorovanými marginálnymi početnosťami** (d_i, a_i, n_{1i}, n_{2i}) za platnosti H_0
- to implikuje **rozdelenie iba jednej bunky**, d_{1i} , pretože ostatné početnosti sú ľahko odvoditeľné od marginálnych
- za platnosti nulovej hypotézy, H_0 , **rozdelenie d_{1i}** je **hypergeometrické**, teda

$$\Pr(d_{1i}) = \frac{\binom{n_{1i}}{d_{1i}} \binom{n_{2i}}{d_{1i} - d_{1i}}}{\binom{n_i}{d_i}}$$

- v tejto forme H_0 o rovnosti kriviek prežívania implikuje **nezávislosť výberu a statusu (nažive alebo zlyhanie)**

Stanislav Katina

Vybrané kapitoly z analýzy prežívania

Testy na porovnanie dvoch kriviek prežívania

Prehľad testov

Za platnosti H_0

- očakávaná (stredná) hodnota $E_0 [d_{1i}] = n_{1i} \frac{d_i}{n_i}$
- rozptyl

$$\text{Var}_0 [d_{1i}] = \left[n_{1i} \frac{d_i}{n_i} \left(1 - \frac{d_i}{n_i} \right) \right] \left(\frac{n_i - n_{1i}}{n_i - 1} \right) = \frac{n_{1i} n_{2i} a_i d_i}{n_i^2 (n_i - 1)}$$

Informáciu o KT v čase $t_{(j)}$ nám dá nasledovný vzťah

$$\chi_i^2 = \frac{[d_{1i} - E_0 [d_{1i}]]^2}{\text{Var}_0 [d_{1i}]} \sim \chi_{df}^2, df = 1$$

Stanislav Katina

Vybrané kapitoly z analýzy prežívania

Testy na porovnanie dvoch kriviek prežívania

Príklad

Example

Majme dátá z klinickej štúdie zhrnuté v nasledovnej tabuľke.

| t_i | n_i | d_i | n_{1i} | d_{1i} | $E_0 [d_{1i}]$ | $d_{1i} - E_0 [d_{1i}]$ | $\text{Var}_0 [d_{1i}]$ |
|-------|-------|-------|----------|----------|----------------|-------------------------|-------------------------|
| 3 | 10 | 1 | 5 | 1 | 0.50 | 0.50 | 0.2500 |
| 5 | 9 | 1 | 4 | 1 | 0.44 | 0.56 | 0.2469 |
| 7 | 8 | 1 | 3 | 1 | 0.38 | 0.62 | 0.2344 |
| 12 | 6 | 1 | 1 | 0 | 0.17 | -0.17 | 0.1389 |
| 18 | 5 | 1 | 1 | 1 | 0.20 | 0.80 | 0.1600 |
| 19 | 4 | 1 | 0 | 0 | 0.00 | 0 | 0 |
| 20 | 3 | 1 | 0 | 0 | 0.00 | 0 | 0 |
| suma | | | 4 | 1.69 | 2.31 | 1.0302 | |

$$\chi^2 = 2.31^2 / 1.0302 = 5.179674$$

$$\text{p-hodnota}=0.0229$$

$$z = \sqrt{2.31^2 / 1.0302} = 2.275890$$

$$\text{p-hodnota}=2 \times 0.0114 = 0.0229$$

Stanislav Katina

Vybrané kapitoly z analýzy prežívania

Testy na porovnanie dvoch kriviek prežívania

Prehľad testov

Pre všetky tabuľky ($i = 1, 2, \dots, I$) píšeme

$$U = \sum_{i=1}^I (d_{1i} - E_0 [d_{1i}]),$$

$$E_0 [U] = 0, \text{Var}_0 [U] = \sum_{i=1}^I \text{Var}_0 [d_{1i}] = \sum_{i=1}^I \frac{n_{1i} n_{2i} a_i d_i}{n_i^2 (n_i - 1)}$$

Ak máme fixované d_i, n_{1i}, n_{2i} , potom platí (Mantel a Haenzel, 1959)

$$Q_{MH} = \frac{\left[\sum_{i=1}^I (d_{1i} - E_0 [d_{1i}]) \right]^2}{\sum_{i=1}^I \text{Var}_0 [d_{1i}]} = \frac{U^2}{\text{Var}_0 [U]} \sim \chi_{df}^2, df = 1,$$

$$Q = \frac{(U - E_0 [U])^2}{\text{Var}_0 [U]} \sim \chi_1^2, Z = \frac{U - E_0 [U]}{\sqrt{\text{Var}_0 [U]}} \sim N(0, 1)$$

Stanislav Katina

Vybrané kapitoly z analýzy prežívania

Testy na porovnanie dvoch kriviek prežívania

Prehľad testov

Majme váhy w_i asociované s KT v čase t_i , potom

$$U = \sum_{i=1}^I w_i (d_{1i} - E_0 [d_{1i}]),$$

$$E_0 [U] = 0, \text{Var}_0 [U] = \sum_{i=1}^I w_i^2 \text{Var}_0 [d_{1i}] = \sum_{i=1}^I w_i^2 \frac{n_{1i} n_{2i} a_i d_i}{n_i^2 (n_i - 1)}$$

Ak máme fixované d_i, n_{1i}, n_{2i} , potom platí (Mantel a Haenzel, 1959)

$$Q = \frac{(U - E_0 [U])^2}{\text{Var}_0 [U]} \sim \chi_1^2, Z = \frac{U - E_0 [U]}{\sqrt{\text{Var}_0 [U]}} \sim N(0, 1)$$

Stanislav Katina

Vybrané kapitoly z analýzy prežívania

Testy na porovnanie dvoch kriviek prežívania

Prehľad testov

Podľa výberu váh w_i rozoznávame nasledovné typy testov:

- ak $w_i = n_i$, $Q = Q_G$, ide o **Gehan-Wilcoxon test**
(zovšeobecnený Wilcoxonov test; Gehan, 1965), ktorý môžeme zredukovať na Wilcoxonovu štatistiku pri absencii cenzúr
- ak $w_i = 1$, $Q = Q_{MH}$, ide o **Cox-Mantel test (log-rank test)**; Mantel a Haenzel, 1959)
- ak $w_i = \sqrt{n_i}$, $Q = Q_{TW}$, ide o **Tarone-Ware test** (Tarone a Ware, 1977)
- ak $w_i = \hat{S}_{\text{pooled}}(t_i) = \prod_{j:t_j \leq t_i} \frac{n_j - d_j + 1}{n_j + 1}$, $Q = Q_P$, ide o **Peto-Peto test** (Peto a Peto, 1972; Prentice, 1978).

Stanislav Katina

Vybrané kapitoly z analýzy prežívania

Testy na porovnanie viacerých kriviek prežívania

Prehľad testov

Testované hypotézy

$$H_0 : \lambda_1(t) = \lambda_2(t) = \dots = \lambda_k(t)$$

$$H_1 : \exists \text{ aspoň jedno } i < j, \lambda_i(t) \neq \lambda_j(t)$$

Pre každé $t_{(i)}$, $1 \leq i \leq I$, môžeme dátá zapísat do KT $2 \times k$

| status/výber | 1 | 2 | ... | j | ... | k | spolu |
|-------------------------------|----------|----------|-----|----------|-----|----------|-------|
| zlyhanie v $t_{(i)}$ | d_{1i} | d_{2i} | ... | d_{ji} | ... | d_{ki} | d_i |
| nažive v čase $t_{(i)}$ | a_{1i} | a_{2i} | ... | a_{ji} | ... | a_{ki} | a_i |
| v riziku pred časom $t_{(i)}$ | n_{1i} | n_{2i} | ... | n_{ji} | ... | n_{ki} | n_i |

$$a_i = \sum_j a_{ji} = n_i - d_i, a_{ji} = n_{ji} - d_{ji}$$

$$n_i = \sum_j n_{ji}$$

$$d_i = \sum_j d_{ji}$$

Stanislav Katina

Vybrané kapitoly z analýzy prežívania

Testy na porovnanie dvoch kriviek prežívania

Prehľad testov

Za platnosti alternatívnej hypotézy $H_1 : \lambda_1(t_i) \neq \lambda_2(t_i)$, pre $\forall i$, očakávaná hodnota rozdielu

$$E[d_{1i} - E_0[d_{1i}]] = \tau_i \left(\frac{\lambda_1(t_i)}{\lambda_2(t_i)} - 1 \right), \tau_i = \frac{n_{1i}n_{2i}}{n_i \left(n_{1i} \frac{\lambda_1(t_i)}{\lambda_2(t_i)} + n_{2i} \right)},$$

a suma bude

$$NC_{\text{parameter}} = \sum_i \tau_i \left(\frac{\lambda_1(t_i)}{\lambda_2(t_i)} - 1 \right),$$

U čo nie je očakávaná hodnota sumy $\sum_i [d_{1i} - E_0[d_{1i}]]$, no Schoenfeld (1981) ukázal, že ide asymptoticky o **parameter necentrality normálneho rozdelenia**

Stanislav Katina

Vybrané kapitoly z analýzy prežívania

Testy na porovnanie viacerých kriviek prežívania

Prehľad testov

Za platnosti nulovej hypotézy a fixovaných marginálnych početnostiach sa dá ukázať, že počet zlyhaní v k výberoch má **hypergeometrické rozdelenie s dimenziou $k - 1$**

$$U_j = \sum_{i=1}^I [d_{ji} - E_0[d_{ji}]], j = 1, 2, \dots, k,$$

stredné hodnoty v časoch $t_{(i)}$

$$E_0[d_{ji}] = n_{ji} \frac{d_i}{n_i},$$

kovariancie v časoch $t_{(i)}$

$$\text{Cov}(d_{li}, d_{si}) = \begin{cases} \frac{n_{li}(n_j - n_{li})d_i a_j}{n_i^2(n_i - 1)} & \text{pre } l = s \\ -\frac{n_{lj}n_{si}d_i a_j}{n_i^2(n_i - 1)} & \text{pre } l \neq s \end{cases},$$

$$j = 1, 2, \dots, k - 1$$

Stanislav Katina

Vybrané kapitoly z analýzy prežívania

Testy na porovnanie viacerých krviek prežívania

Prehľad testov

U_j substituujeme $(k - 1)$ -stĺpcovým vektorom \mathbf{U} s elementami

$U_j, j = 1, 2, \dots, k - 1$

$\mathbf{V}(t_{(i)})$ je $(k - 1) \times (k - 1)$ **kovariančná matica** s komponentami v časoch $t_{(i)}$ daných nasledovne

$$(\mathbf{V}(t_{(i)}))_{ls} = \text{Cov}(d_{li}, d_{si})$$

$$\mathbf{V} = \sum_{i=1}^I \mathbf{V}(t_{(i)})$$

Testovacia štatistika

$$Q_{\text{overall}} = \mathbf{U}^T \mathbf{V}^{-1} \mathbf{U} \sim \chi_{k-1}^2$$

Ak $k = 2$, štatistika $Q_{\text{overall}} = Q_{\text{MH}}$

Stanislav Katina

Vybrané kapitoly z analýzy prežívania

Testy na porovnanie viacerých krviek prežívania

Prehľad testov

Voľba váh je nasledovná:

- ak $w_i = n_i$, ide o **zovšeobecnený Wilcoxonov test (zovšeobecnený Kruskal-Wallis test, Gehan-Breslow test)**,
- ak $w_i = 1$, ide o **Cox-Mantel test (log-rank test)**,
- ak $w_i = \hat{S}(t_i^-)^\rho$, $\rho = 0$ ide o **Mantel-Haenszelov test (log-rank test)**, ak $\rho = 1$, ide o **Peto-Peto-Wilcoxon test**.

Stanislav Katina

Vybrané kapitoly z analýzy prežívania

Testy na porovnanie viacerých krviek prežívania

Prehľad testov

V prípade pridania váh, bude platiť

$$\mathbf{U}_w = \sum_{i=1}^I w_i \mathbf{U}_i,$$

kde w_i sú váhy asociované s pozorovaním v čase $t_{(i)}$

$$\mathbf{U}_i = \begin{pmatrix} d_{1i} - E_0 [d_{1i}] \\ \vdots \\ d_{ji} - E_0 [d_{ji}] \\ \vdots \\ d_{ki} - E_0 [d_{ki}] \end{pmatrix}$$

Podobne ako vyššie bude platiť

$$\mathbf{U}_w^T \mathbf{V}^{-1} \mathbf{U}_w \sim \chi_{k-1}^2,$$

$$\text{kde } \mathbf{V}_w = \mathbf{w}^T \mathbf{V} \mathbf{w}$$

Stanislav Katina

Vybrané kapitoly z analýzy prežívania

Testy na porovnanie viacerých krviek prežívania

Test trendu

Test nulovej hypotézy oproti stochasticky usporiadanej alternatíve je *testom trendu*, kde testujeme zoradený vzťah medzi k funkiami prežívania definovanými v zmysle vektora váh $\mathbf{w}_* = (w_1^*, w_2^*, \dots, w_j^*, \dots, w_k^*)^T$, potom

$$H_0 : \lambda_1(t) = \lambda_2(t) = \dots = \lambda_k(t)$$

a H_1 :

$$\lambda_1(t) = w_1^* \lambda_k(t),$$

$$\lambda_2(t) = w_2^* \lambda_k(t),$$

...

$$\lambda_j(t) = w_j^* \lambda_k(t),$$

$$\lambda_{k-1}(t) = w_{k-1}^* \lambda_k(t),$$

kde bez straty na všeobecnosti môžeme predpokladať, že $w_k = 1$

Stanislav Katina

Vybrané kapitoly z analýzy prežívania

Testy na porovnanie viacerých krviek prežívania

Test trendu

Testovacia štatistika

$$Q_{trend} = \frac{[U_{trend}]^2}{\mathbf{w}_*^T \mathbf{V}_* \mathbf{w}_*} \sim \chi^2_1,$$

kde

$$\begin{aligned} U_{trend} &= \sum_{j=1}^k U_{trend}^{(j)} = \sum_{j=1}^k w_j^* U_j \\ &= \sum_{j=1}^k w_j^* \sum_{i=1}^l [d_{ji} - E_0[d_{ji}]], \end{aligned}$$

a \mathbf{V}_* počítame tak ako \mathbf{V} , ale s tým rozdielom, že ide o maticu $k \times k$

Stanislav Katina

Vybrané kapitoly z analýzy prežívania

Testy na porovnanie viacerých krviek prežívania

Príklad

Example

Majme experiment (Thomas et all, 1977), kde sme mali 3 rôzne koncentrácie látky ($konc_1 = 2.0$, $konc_2 = 1.5$ a $konc_3 = 0$) a hľadali sme jej účinok na pacientov, u ktorých sme sledovali objavenie sa nádoru (pozri Tab.). Zaujíma nás testovanie A)

$H_0 : \lambda_1(t) = \lambda_2(t) = \lambda_3(t)$ oproti $H_1 : \exists$ aspoň jedno $i < j$, $\lambda_i(t) \neq \lambda_j(t)$ B) $H_0 : \lambda_1(t) = \lambda_2(t) = \lambda_3(t)$ oproti $\lambda_1(t) = w_1^* \lambda_3(t)$, $\lambda_2(t) = w_2^* \lambda_3(t)$, kde $w_j^* = konc_j$, $j = 1, 2$ (test trendu).

Pozn.: časy do zlyhania alebo cenzúry; $+$ znamená cenzúru, $n_0 = \#$ pozorovaní v t_0 , $konc_j$ je koncentrácia látky v skupine j ,

| $konc_j$ | n_0 | | | | | | | | | |
|----------|-------|-----------------|-----------------|-----------------|-----------------|-----------------|-----------------|-----|-----|------------------|
| 2.0 | 10 | 41 ⁺ | 41 ⁺ | 47 | 47 ⁺ | 47 ⁺ | 58 | 58 | 58 | 100 ⁺ |
| 1.5 | 10 | 43 ⁺ | 44 ⁺ | 45 ⁺ | 67 | 68 ⁺ | 136 | 136 | 150 | 150 |
| 0 | 9 | 73 ⁺ | 74 ⁺ | 75 ⁺ | 76 | 76 | 76 ⁺ | 99 | 166 | 246 ⁺ |

Testy na porovnanie viacerých krviek prežívania

Test trendu

Testovaciu štatistiku Q_{trend} budeme potom písat nasledovne

$$Q_{trend} = \frac{\left(\sum_{j=1}^k w_j^* \sum_{i=1}^l [d_{ji} - E_0[d_{ji}]] \right)^2}{\sum_{i=1}^l \frac{n_i - d_i}{n_i - 1} \left(\sum_{j=1}^k (w_j^*)^2 E_0[d_{ji}] - \frac{1}{d_i} \left[\sum_{j=1}^k (w_j^*) E_0[d_{ji}] \right]^2 \right)}$$

a ak sú váhy rozdelené lineárne, $w_j^* = j$, potom hovoríme o teste lineárneho trendu

Platí

$$Q_{residual} = Q_{overall} - Q_{trend} \sim \chi^2_{k-2},$$

čo vedie ku záveru, že ak je tento test štatisticky signifikantný, potom váhy použité v Q_{trend} treba nahradit inými, ktoré by lepšie modelovali trend v dátach

Stanislav Katina

Vybrané kapitoly z analýzy prežívania

Testy na porovnanie viacerých krviek prežívania

Príklad

| d_{ji} | 47 | 58 | 67 | 76 | 99 | 117 | 136 | 150 | 166 |
|----------|----|----|----|----|----|-----|-----|-----|-----|
| konc. 1 | 1 | 3 | 0 | 0 | 0 | 1 | 0 | 0 | 0 |
| konc. 2 | 0 | 0 | 1 | 0 | 0 | 0 | 2 | 3 | 0 |
| konc. 3 | 0 | 0 | 0 | 2 | 1 | 0 | 0 | 0 | 1 |

| a_{ji} | 47 | 58 | 67 | 76 | 99 | 117 | 136 | 150 | 166 |
|----------|----|----|----|----|----|-----|-----|-----|-----|
| konc. 1 | 7 | 2 | 2 | 2 | 2 | 0 | 0 | 0 | 0 |
| konc. 2 | 7 | 7 | 6 | 5 | 5 | 5 | 3 | 0 | 0 |
| konc. 3 | 9 | 9 | 9 | 4 | 2 | 2 | 2 | 2 | 1 |

| n_{ji} | 47 | 58 | 67 | 76 | 99 | 117 | 136 | 150 | 166 |
|----------|----|----|----|----|----|-----|-----|-----|-----|
| konc. 1 | 8 | 5 | 2 | 2 | 2 | 1 | 0 | 0 | 0 |
| konc. 2 | 7 | 7 | 7 | 5 | 5 | 5 | 5 | 3 | 0 |
| konc. 3 | 9 | 9 | 9 | 6 | 3 | 2 | 2 | 2 | 2 |

Stanislav Katina

Vybrané kapitoly z analýzy prežívania

Stanislav Katina

Vybrané kapitoly z analýzy prežívania

Testy na porovnanie viacerých krviek prežívania

Príklad

Prvý čas, kedy sa nádor objavil je $t_{(1)} = 47$ a KT v $t_{(1)}$ je nasledovná

| dávka | udalosť v $t_{(1)}$ | bez udalostí v $t_{(1)}$ | v riziku pred $t_{(1)}$ |
|-------|---------------------|--------------------------|-------------------------|
| 2.0 | 1 | 7 | 8 |
| 1.5 | 0 | 7 | 7 |
| 0.0 | 0 | 9 | 9 |
| spolu | 1 | 23 | 24 |

Čiastkové výpočty v $t_{(1)}$

| dávka | $E_0 [d_{j1}]$ | U_{j1} |
|-------|----------------|--------------------------|
| 2.0 | 0.33333 | $1 - 0.33333 = 0.66667$ |
| 1.5 | 0.29167 | $0 - 0.29167 = -0.29167$ |
| 0.0 | 0.37500 | |

Stanislav Katina

Vybrané kapitoly z analýzy prežívania



R príkazy [R je voľne dostupné na <http://cran.r-project.org/>]

Príklad 1 (poznámky sú uvedené za znakom #):

```

library(survival)
attach(aml)
names(aml)
## odhad pre obe skupiny zvlást
# median, priemerny cas prezívania, rozsahy, pocty zlyhania
kmfit.aml <- survfit(Surv(cas,status)~skupina, data=aml)
print(kmfit.aml,show.rmean=TRUE)
## odhad v jednotlivych casoch
# fcia prezívania, IS, pocet v riziku, pocet udalosti v case
## testovanie hypotez
# default rho = 0 [log-rank]
test.aml<-survdiff(Surv(cas,status)~skupina, data=aml)
# Peto test rho = 1
test.aml<-survdiff(Surv(cas,status)~skupina, data=aml,rho = 1)

```

Stanislav Katina

Vybrané kapitoly z analýzy prežívania

Testy na porovnanie viacerých krviek prežívania

Príklad

$$\mathbf{V}(t_{(1)}) = \begin{bmatrix} \frac{8 \times (24-8) \times 1 \times (24-1)}{24^2(24-1)} = 0.222 & -\frac{8 \times 7 \times 1 \times 23}{24^2 \times 23} = -0.097 \\ -0.097 & \frac{7 \times (24-7) \times 1 \times 23}{24^2 \times 23} = 0,207 \end{bmatrix}$$

$$\mathbf{U} = \begin{pmatrix} 3.209 \\ -0.803 \end{pmatrix}$$

$$\mathbf{V} = \begin{pmatrix} 1.319 & -0.641 \\ -0.641 & 2.663 \end{pmatrix}, \mathbf{V}^{-1} = \begin{pmatrix} 0.859 & 0.207 \\ 0.207 & 0.425 \end{pmatrix}$$

$$Q_{overall} = \mathbf{U}^T \mathbf{V}^{-1} \mathbf{U} = 8.050, \text{ p-hodnota}=0.018$$

Ak $w^* = (0.0, 1.5, 2.0)^T$, potom

$$U_{trend}^2 = 36.186, \mathbf{w}_*^T \mathbf{V}_* \mathbf{w}_* = 5.991,$$

$$Q_{trend} = 6.04, \text{ p-hodnota}=0.014,$$

$$\text{a naviac } Q_{residual} = Q_{overall} - Q_{trend} = 2.01, \text{ p-hodnota}=0.156$$

Stanislav Katina

Vybrané kapitoly z analýzy prežívania



R príkazy [R je voľne dostupné na <http://cran.r-project.org/>]

Príklad 1 (pokrač.):

```


skup <- as.numeric(aml$skupina)
cas1 <- kmfit.aml.1$time; cas2 <- kmfit.aml.2$time;
CAS <- c(cas1,cas2)
## kumulatívne riziko (KM a NA)
# (počítane rovnako ako v príklade 2, handout 1)
LAM.KM <- c(Lambda.KM.1,Lambda.KM.2)
par(mfcol=c(1,2)) # nastavenie počtu podokien
## obrazok (limitacia osi-argument xlim,ylim, kde beriem do
## úvahy rozsah združeneho vektora kum.rizik)
## KM odhad kum.rizika (podobne aj NA odhad)
plot(CAS,LAM.KM,xlab="cas do relapsu (v týždnoch)",
      ylab="kumulatívne riziko", type="n", ylim=range(LAM.KM),
      xlim=c(0,50))
lines(cas1,Lambda.KM.1,lty=1,lwd=2,type="s")
lines(cas2,Lambda.KM.2,lty=2,lwd=2,type="s")
abline(h=0,col="gray")
title(main="KM kumulatívne riziko pre AML data")
legend("topleft",c("skup M","skup NM"),lty=c(1,2))

```


Stanislav Katina

Vybrané kapitoly z analýzy prežívania

KM kumulatívne riziko pre AML data




NA kumulatívne riziko pre AML data



Stanislav Katina

Vybrané kapitoly z analýzy prežívania

Krivky prezívania a IS



Stanislav Katina

Vybrané kapitoly z analýzy prežívania

Príklad 1 (pokrač.):

```
## odhad funkcie prezívania pre kazdu skupinu zvlást
kmf1 <- survfit(Surv(cas[skup == 1], status[skup == 1])~1)
kmf2 <- survfit(Surv(cas[skup == 2], status[skup == 2])~1)
## obrázok (hrubka ciary lwd, conf.int kresli IS)
plot(kmf1, xlab="cas do relapsu (v týždnoch)",
     ylab="pravdepodobnosť dožitia", conf.int=FALSE, lwd=2)
lines(kmf2, lty=2, lwd=2)
legend("topright", c("skup M", "skup NM"), lty=c(1,2))
title(main="Krivky prezívania a IS", sub="plain skala")
```

Stanislav Katina

Vybrané kapitoly z analýzy prežívania

Príklad 2:

```
## odhad funkcie prezívania pre kazdu skupinu zvlást
## data z prednasky
konc1 <- c(41, 41, 47, 47, 47, 58, 58, 58, 100, 117)
status1 <- c(0, 0, 1, 0, 0, 1, 1, 1, 0, 1)
konc2 <- c(43, 44, 45, 67, 68, 136, 136, 150, 150, 150)
status2 <- c(0, 0, 1, 0, 1, 1, 1, 1, 1, 1)
konc3 <- c(73, 74, 75, 76, 76, 99, 166, 246)
status3 <- c(0, 0, 0, 1, 1, 0, 1, 1, 0)
data.all <- c(konc1, konc2, konc3)
status.all <- c(status1, status2, status3)
skup.all <- c(rep(1, 10), rep(2, 10), rep(3, 9))
## testovanie hypotez
# default rho = 0 [log-rank]
survdiff(formula = Surv(data.all, status.all)~skup.all)
# Peto test rho = 1
survdiff(formula = Surv(data.all, status.all)~skup.all, rho=1)
```

Stanislav Katina


Vybrané kapitoly z analýzy prežívania

Príklad 2 (pokrač.):

```
## NA kumulativne riziko
# (pocitane rovnako ako v priklade 2, handout 1)
LAM <- Lambda.NA.1
plot(cas,Lambda.NA,xlab="cas do relapsu (v
tyzdnoch)",ylab="kumulativne riziko", type="n", ylim=range(LAM),
xlim=c(0,166))
lines(cas,Lambda.NA.1,lty=1,lwd=2,type="s")
lines(cas,Lambda.NA.2,lty=2,lwd=2,type="s")
lines(cas,Lambda.NA.3,lty=3,lwd=2,type="s")
abline(h=0,col="gray")
title(main="NA kumulativne riziko")
legend("bottomleft",c("skup 1","skup 2","skup 3"),lty=c(1,2,3))
```

Stanislav Katina

Vybrané kapitoly z analýzy prežívania

NA kumulativne riziko

Stanislav Katina


Vybrané kapitoly z analýzy prežívania

Príklad 2 (pokrač.):

```
## odhady funkcie prezivania pre kazdu skupinu zvlast
kmf1 <- survfit(Surv(konc1,status1)~1)
kmf2 <- survfit(Surv(konc2,status2)~1)
kmf3 <- survfit(Surv(konc3,status3)~1)
## obrazok (hrubka ciary lwd, conf.int kresli IS)
plot(kmf1,xlab="cas do zlyhania",ylab="pravdepodobnosť
dozitia",conf.int=FALSE,lwd=2)
lines(kmf2,lty=2,lwd=2)
lines(kmf3,lty=3,lwd=2)
legend("bottomleft",c("skup 1","skup 2","skup 3"),lty=c(1,2,3))
title(main="Krivky prezivania a IS",sub="plain skala")
```

Stanislav Katina

Vybrané kapitoly z analýzy prežívania

Krivky prezivania a IS

Stanislav Katina

Vybrané kapitoly z analýzy prežívania

Vybrané kapitoly z analýzy prežívania

Regresné modely

Stanislav Katina¹

¹Ústav matematiky a statistiky
Přírodovědecká fakulta
Masarykova univerzita v Brne

ZS 2013



INVESTICE DO ROZVOJE VZDĚLÁVÁNÍ

Stanislav Katina

Vybrané kapitoly z analýzy prežívania

Parametrické regresné modely

Prehľad rozdelení pravdepodobnosti

1 Exponenciálne rozdelenie

2 Weibullovo rozdelenie

3 Rozdelenie extrémnych (minimálnych) hodnôt

4 Log-normálne rozdelenie

5 Log-logistické rozdelenie

6 Gama rozdelenie

Poděkování

Tento učební text vznikl za přispění Evropského sociálního fondu a státního rozpočtu ČR prostřednictvím Operačního programu Vzdělávání pro konkurenčeschopnost v rámci projektu Univerzitní výuka matematiky v měnícím se světě

(CZ.1.07/2.2.00/15.0203)

Stanislav Katina

Vybrané kapitoly z analýzy prežívania

Parametrické regresné modely

Exponenciálne rozdelenie

Náhodná premenná T má **exponenciálne rozdelenie $Exp(\lambda)$** práve vtedy, ak jej **hustota** má tvar

$$f(t, \lambda) = \lambda e^{-\lambda t}, \text{ kde } \lambda > 0, t \geq 0$$

a naviac

- **funkcia rizika** $\lambda(t, \lambda) = \lambda$
- **distribučná funkcia** $F(t, \lambda) = \int_0^t \lambda e^{-\lambda t} dt = 1 - e^{-\lambda t}$
- **funkcia prežívania** $S(t, \lambda) = e^{-\lambda t}$
- **stredná hodnota** $E[T] = \frac{1}{\lambda}$
- **rozptyl** $Var[T] = \frac{1}{\lambda^2}$
- **p-ty kvantil** $t_p = -\frac{1}{\lambda} \log(1 - p)$

Stanislav Katina

Vybrané kapitoly z analýzy prežívania

Stanislav Katina

Vybrané kapitoly z analýzy prežívania

Parametrické regresné modely

Exponenciálne rozdelenie

- jednoduchosť modelu – **riziko je konštantné**, teda
 - riziko nezávisí na t a
 - pravdepodobnosť zlyhania v intervale $[y, y + \delta y]$ je nezávislá na tom, aký dlhý čas jedinec doteraz prežil
- **riziko bez pamäte** – obmedzenie v praxi, nakoľko riziko zvyčajne s časom narastá
- **podmienka konštantnosti rizika** – **odhad kumulatívneho rizika zobrazí voči t** – graf bude potom predstavovať **priamku**
 - **kumulatívne riziko** $\Lambda(t) = -\log S(t)$
 - pre exponenciálne rozdelenie $\log(\Lambda(t)) = \log(-\log S(t)) = \log(\lambda) + \log(t)$, kde $\log(t) = -\log(\lambda) + \log(-\log S(t))$
 - **graf $\log(t)$ voči $\log(-\log S(t))$** je priamka so **sklonom rovným jednej a interceptom** $-\log(\lambda)$
 - **graf času t voči riziku λ** je **horizontálna priamka**
- **medián času prežívania** je daný riešením rovnice $F(t, \lambda) = \frac{1}{2}$, a teda $t_{0.5} = \frac{1}{\lambda} \log 2$
- exponenciálny model je **špeciálnym prípadom Weibullovho a Gama rozdelenia s parametrom tvaru rovným jednej**

Stanislav Katina

Vybrané kapitoly z analýzy prežívania

Parametrické regresné modely

Weibulovo rozdelenie

Náhodná premenná T má **Weibulovo rozdelenie $W(\lambda, \theta)$** práve vtedy, ak jej **hustota** má tvar

$$f(t, \lambda, \theta) = \lambda \theta (\lambda t)^{\theta-1} e^{-(\lambda t)^\theta}, \text{ kde } \lambda > 0, \theta > 0, t \geq 0$$

a naviac

- **funkcia rizika** $\lambda(t, \lambda, \theta) = \lambda \theta (\lambda t)^{\theta-1}$
- **distribučná funkcia** $F(t, \lambda, \theta) = 1 - e^{-(\lambda t)^\theta}$
- **funkcia prežívania** $S(t, \lambda, \theta) = e^{-(\lambda t)^\theta}$
- **stredná hodnota** $E[T] = \int_0^\infty \theta(\lambda t)^\theta e^{-(\lambda t)^\theta} dt = \lambda^{-1} \Gamma\left(1 + \frac{1}{\theta}\right)$
- **rozptyl** $Var[T] = \lambda^{-2} [\Gamma(1 + \frac{2}{\theta}) - \Gamma^2(1 + \frac{1}{\theta})]$
- **p -ty kvantil** $t_p = \frac{1}{\lambda} (-\log(1-p))^{\frac{1}{\theta}}$

Stanislav Katina

Vybrané kapitoly z analýzy prežívania

Parametrické regresné modely

Exponenciálne rozdelenie




Figure: Funkcie prežívania (Exponenciálne rozdelenie)

Stanislav Katina

Vybrané kapitoly z analýzy prežívania

Parametrické regresné modely

Weibulovo rozdelenie

- $\Gamma(x)$ predstavuje **Gama funkciu** a je definovaná ako $\int_0^\infty u^{x-1} e^{-u} du, x > 0$
- parameter θ sa nazýva **parameter tvaru**
- **funkcia rizika** je
 - **rastúca**, keď je $\theta > 1$
 - **klesajúca**, keď $\theta < 1$
 - **konštantná**, keď $\theta = 1$
- parameter λ sa nazýva **škála**, nakoľko jeho hodnoty menia iba škálu na horizontálnej časovej t osi a nie tvar funkcie
- Weibulov model je veľmi flexibilný a ukázalo sa, že je v praxi často aplikovateľný
- často očakávame **rastúce riziko s časom**, ako napr. modelovanie času prežívania pacientov s leukémiou, ktorí neodpovedajú na liečbu, kde je udalosťou smrť
- avšak môžeme mať aj opačnú situáciu, teda **klesajúce riziko**, ak sa pacienti napr. zotavujú po chirurgickom zákroku

Stanislav Katina

Vybrané kapitoly z analýzy prežívania

Parametrické regresné modely

Weibullovo rozdelenie

- pre Weibullovo rozdelenie
 $\log(\Lambda(t)) = \log(-\log S(t)) = \theta(\log(\lambda) + \log(t))$, kde
 $\log(t) = -\log(\lambda) + \sigma \log(-\log S(t))$, kde $\sigma = \frac{1}{\theta}$
- graf $\log(t)$ voči $\log(-\log S(t))$ je priamka so sklonom rovným $\sigma = \frac{1}{\theta}$ a interceptom $-\log(\lambda)$
- medián času prežívania je daný riešením rovnice $F(t, \lambda, \theta) = \frac{1}{2}$, a teda $t_{0.5} = \frac{1}{\lambda}(-\log 2)^{\frac{1}{\theta}}$
- Weibullovo rozdelenie je úzko previazané s **rozdelením extrémnych hodnôt [extreme value distribution]** – **logaritmická transformácia**
Weibullovej náhodnej premennej nám dáva náhodnú premennú majúcu rozdelenie extrémnych hodnôt

Stanislav Katina

Vybrané kapitoly z analýzy prežívania

Parametrické regresné modely

Weibullovo rozdelenie




Figure: Funkcie rizika (Weibullove rozdelenie)

Stanislav Katina

Vybrané kapitoly z analýzy prežívania

Parametrické regresné modely

Weibullovo rozdelenie





Figure: Funkcie prežívania (Weibullove rozdelenie)

Stanislav Katina

Vybrané kapitoly z analýzy prežívania

Parametrické regresné modely

Rozdelenie extrémnych (minimálnych) hodnôt

Nech $\mu \in \mathbb{R}$ a $\sigma > 0$ sú parametre polohy a škály – **standardizované rozdelenie extrémnych hodnôt** má $\mu = 0$ a $\sigma = 1$; potom

- hustota** $f(t, \mu, \sigma) = \frac{1}{\sigma} \exp\left(\frac{t-\mu}{\sigma}\right) - \exp\left(\frac{t-\mu}{\sigma}\right)$
 - distribučná funkcia** $F(t, \mu, \sigma) = 1 - \exp\left(-\exp\left(\frac{t-\mu}{\sigma}\right)\right)$
 - funkcia prežívania** $S(t, \mu, \sigma) = \exp\left(-\exp\left(\frac{t-\mu}{\sigma}\right)\right)$
 - stredná hodnota** $E[T] = \mu - \gamma\sigma$
 - rozptyl** $Var[T] = \frac{\pi^2}{6}\sigma^2$
 - p-ty kvantil** $t_p = \mu + \sigma \log(-\log(1-p))$
- kde $\gamma \doteq 0.5772$ je Eulerovo číslo, parameter polohy μ je 0.632-tý kvantil a $t \in \mathbb{R}$
- potom ak T je Weibullova náhodná premenná s parametrami θ a λ , $Y = \log(T)$ má rozdelenie extrémnych hodnôt s parametrami $\mu = -\log \lambda$ a $\sigma = \frac{1}{\theta}$
 - naviac $Y = \mu + \sigma Z$, kde Z má standardizované rozdelenie extrémnych hodnôt
 - parametre μ a σ nemenia tvar rozdelenia, iba polohu a škálu

Stanislav Katina

Vybrané kapitoly z analýzy prežívania

Parametrické regresné modely

Log-normálne rozdelenie

Ak je čas prežívania T **log-normálne rozdelený**, potom $Y = \log(T)$ je normálne rozdelené s parametrami μ a σ , teda $Y \sim N(\mu, \sigma^2)$. Nech $Y = \mu + \sigma Z$, potom $Z \sim N(0, 1)$. Nech $\theta, \lambda > 0$, potom

- **hustota** $f(t, \theta, \lambda) = \frac{1}{\sqrt{2\pi}} \theta t^{-1} \exp\left(-\frac{\theta^2(\log(\lambda t))^2}{2}\right)$
- **distribučná funkcia** $F(t, \theta, \lambda) = \Phi(\theta \log(\lambda t))$
- **funkcia prežívania** $S(t, \theta, \lambda) = 1 - \Phi(\theta \log(\lambda t))$
- **funkcia rizika** $\lambda(t, \theta, \lambda) = \frac{f(t, \theta, \lambda)}{S(t, \theta, \lambda)}$
- **stredná hodnota** $E[T] = \exp(\mu + \frac{\sigma^2}{2})$
- **rozptyl** $Var[T] = (\exp(\sigma^2) - 1)(\exp(2\mu + \sigma^2))$

kde $\mu = -\log \lambda$ a $\sigma = \frac{1}{\theta}$

- **funkcia rizika** sa rovná nule v čase $t = 0$, **rastie** do maxima, potom **klesá** smerom k nule, keď t dosahuje veľké hodnoty – **riziko klesá pre veľké hodnoty t , čo sa môže zdať ako nepoužiteľná vlastnosť tohto rozdelenia**, napr. pri modelovaní prežívania tuberkulóznych pacientov, kde ich zlyhávanie najprv stúpa a potom neskôr klesá, tento model vhodný je
- dobrú aproximáciu log-normálneho rozdelenia je **log-logistické rozdelenie**

Stanislav Katina

Vybrané kapitoly z analýzy prežívania

Parametrické regresné modely

Log-logistické rozdelenie

- tento model sa stal populárny, podobne ako Weibullov model, aj pre jednoduché vyjadrenie funkcie prežívania a funkcie rizika
- aproximácia cenzurovaných dát pomocou tohto modelu sa v praxi ukázala lepšia ako aproximácia log-normálny rozdelením (okrem extrémov v chvostoch rozdelenia)
- **riziková funkcia je podobná Weibullovej**, lišia sa len menovateľom $1 + (\lambda t)^\theta$.
- ak $\theta < 1$ ($\sigma > 1$) je riziková funkcia monotónne **klesajúca** z ∞ a
- ak $\theta = 1$ ($\sigma = 1$), je riziková funkcia monotónne **klesajúca** z λ
- Ak $\theta > 1$ ($\sigma < 1$) je riziková funkcia monotónne **rastúca** z nuly do maxima v $t = \frac{(\theta-1)^{\frac{1}{\theta}}}{\lambda}$ a **klesajúca** potom k nule
- dá sa ľahko ukázať, že **šanca prežitia za časom t** sa dá zapísať ako

$$\frac{S(t)}{1 - S(t)} = (\lambda t)^{-\theta}$$

a potom **log t** je lineárnu funkciu logaritmu šance prežívania za časom t , teda $\log t = \mu + \sigma(-\log \frac{S(t)}{1 - S(t)})$, kde $\mu = -\log \lambda$ a $\sigma = \frac{1}{\theta}$

- **graf $\log t$ oproti $-\log \frac{S(t)}{1 - S(t)}$** je priamka so **sklonom σ** a **interceptom μ**

Stanislav Katina

Vybrané kapitoly z analýzy prežívania

Parametrické regresné modely

Log-logistické rozdelenie

Ak je čas prežívania T **log-logisticky rozdelený**, potom $Y = \log(T)$ je logisticke rozdelené s parametrom **polohu μ** a **škálu σ** . Nech $Y = \mu + \sigma Z$, potom Z má štandardizované logisticke rozdelenie s hustotou

$$f(z) = \frac{\exp z}{(1 + \exp z)^2}, z \in \mathbb{R},$$

ktorá je **symetrická**, jej **chvosty** sú o niečo ľahšie ako chvosty normálneho rozdelenia, šikmosť a špicatosť sú rovné 1.2, $E[Z] = 0$ a $Var[Z] = \frac{\pi^2}{3}$. Potom pre T a $\lambda, \theta > 0$ platí

- **hustota** $f(t, \lambda, \theta) = \lambda \theta (\lambda t)'^{\theta-1} (1 + (\lambda t)^\theta)^{-2}$
- **distribučná funkcia** $F(t, \lambda, \theta) = 1 - \frac{1}{1 + (\lambda t)^\theta}$
- **funkcia prežívania** $S(t, \lambda, \theta) = \frac{1}{1 + (\lambda t)^\theta}$
- **funkcia rizika** $\lambda(t, \lambda, \theta) = \frac{\lambda \theta (\lambda t)'^{\theta-1}}{1 + (\lambda t)^\theta}$
- **p-ty kvantil** $t_p = \lambda^{-1} \left(\frac{p}{1-p} \right)^{\frac{1}{\theta}}$

kde $\mu = -\log \lambda$ a $\sigma = \frac{1}{\theta}$

Stanislav Katina

Vybrané kapitoly z analýzy prežívania

Parametrické regresné modely

Log-logistické rozdelenie




Figure: Funkcie prežívania (Log-logistické rozdelenie)

Stanislav Katina

Vybrané kapitoly z analýzy prežívania

Parametrické regresné modely

Log-logistické rozdelenie




Figure: Funkcie rizika (Log-logistické rozdelenie)

Stanislav Katina

Vybrané kapitoly z analýzy prežívania

Parametrické regresné modely

Gama rozdelenie

- ak $k > 1$ funkciu rizika monotónne **rastie** z 0
- ak $k < 1$ funkciu rizika monotónne **klesá** z ∞
- ak $k = 1$, potom sa Gama rozdelenie redukuje na **exponenciálne rozdelenie** a riziková funkcia je **konštantná**, t.j. rovná λ
- **model** pre $Y = \log T$ môžeme písť v tvare $Y = \mu + Z$, kde Z má hustotu $\frac{\exp(kz - \exp(z))}{\Gamma(k)}$
- náhodná premenná Y sa nazýva **log-Gama náhodná premenná s parametrami k a $\mu = -\log \lambda$**
- Z má negatívne zošikmené rozdelenie s klesajúcou šikmosťou ak k rastie
- ak $k = 1$ potom ide o **exponenciálny model** a Z má štandardizované rozdelenie extrémnej hodnoty
- s výnimkou $k = 1$ **nie je Gama rozdelenie členom rodiny polohovo-škálových rozdelení, ale iba členom rodiny polohových rozdelení**

Stanislav Katina

Vybrané kapitoly z analýzy prežívania

Parametrické regresné modely

Gama rozdelenie

Náhodná premenná T má **Gama rozdelenie Gama (λ, k)** práve vtedy, ak jej **hustota** má tvar

$$f(t) = \frac{\lambda^k}{\Gamma(k)} t^{k-1} e^{-\lambda t}, \text{ kde } t \geq 0, \lambda > 0, k > 0.$$

Potom ak neúplná Gama funkcia $I_k(s) = \left(\int_0^s t^{k-1} e^{-\lambda t} dt \right) / \Gamma(k)$, tak

- **funkcia rizika** $\lambda(t, \lambda, k) = \frac{\lambda(\lambda t)^{k-1} e^{-\lambda t} \Gamma^{-1}(k)}{1 - I_k(\lambda t)}$
- **distribučná funkcia** $F(t, \lambda, k) = I_k(\lambda t)$
- **funkcia prežívania** $S(t, \lambda, k) = 1 - I_k(\lambda t)$
- **stredná hodnota** $E[T] = \frac{k}{\lambda}$
- **rozptyl** $Var[T] = \frac{k}{\lambda^2}$

Stanislav Katina

Vybrané kapitoly z analýzy prežívania

Parametrické regresné modely

Rozdelenia pravdepodobnosti – zhrnutie

Okrem Gama rozdelenia majú všetky spomenuté rozdelenia času prežívania T vlastnosť, že **rozdelenie $\log T$ je členom rodiny polohovo-škálových rozdelení**. Spoločné črty spomenutých rozdelení sú nasledovné

- ① rozdelenie T má dva parametre škálu λ a tvar θ
- ② rozdelenie $\log T$ má dva parametre škálu $\mu = -\log \lambda$ a tvar $\sigma = 1/\theta$
- ③ pre všetky rozdelenia platí, že $Y = \log T = \mu + \sigma Z$, kde Z má štandardizované rozdelenie s $\mu = 0 (\lambda = 1)$ a $\sigma = 1 (\theta = 1)$
- ④ tieto modely sú **log-lineárnymi modelmi**

| T | $Y = \log T$ |
|---------------------------|------------------------------|
| Weibullove rozdelenie | rozdelenie extrémnych hodnôt |
| log-normálne rozdelenie | normálne rozdelenie |
| log-logistické rozdelenie | logistické rozdelenie |

Stanislav Katina

Vybrané kapitoly z analýzy prežívania

Parametrické regresné modely

Konštrukcia qq-diagramu

- nech $\hat{S}_{KM}(t)$ je Kaplan-Meierov odhad funkcie prežívania v čase t
- nech $t_i, i = 1, 2, \dots, r \leq n$ sú zoradené necenzurované časy do zlyhania
- pre každý necenzurovaný výberový kvantil $y_i = \log t_i$ je odhadnutá pravdepodobnosť zlyhania $\hat{p}_i^{(KM)} = 1 - \hat{S}_{KM}(t_i)$
- parametrický štandardizovaný kvantil získame použitím $\hat{p}_i = F_{0,1}(z_i) = \Pr(Z \leq z_i)$, kde $F_{0,1}(z_i)$ je distribučná funkcia štandardizovaného parametrického modelu ($\mu = 0, \sigma = 1$)
- tieto štandardizované kvantily porovnávame s kvantilmami neparametrického odhadu $\hat{S}_{KM}(t)$ – ak je navrhovaný model adekvátny, potom graf (z_i, y_i) leží na priamke so sklonom σ a interceptom μ

| t_p kvantil | $y_p = \log t_p$ kvantil | štandardizovaný kvantil z_p |
|----------------|--------------------------|--|
| Weibull r. | roz.extr.h. | $\log(-\log \hat{S}(t_p)) = \log(\lambda t_p) = \log(-\log(1-p))$ |
| log-norm.r. | norm.r. | $\Phi^{-1}(p)$ |
| log-logis.roz. | logis.r. | $= -\log \frac{\hat{S}(t_p)}{1-\hat{S}(t_p)} = -\log(\frac{1-p}{p})$ |

Stanislav Katina

Vybrané kapitoly z analýzy prežívania

Regresné modely pre jednovýberový prípad

Odhady a testy pre exponenciálny model pre necenzurované dátá

- exaktné rozdelenie – ak $T_i \sim Exp(\lambda)$, potom $\sum_{i=1}^n T_i \sim Gama(\lambda, k = n)$, potom

$$2\lambda \sum_{i=1}^n T_i = 2n \frac{\lambda}{\bar{T}} \sim \chi_{2n}^2$$

potom $(1 - \alpha) \times 100\%$ interval spoľahlivosti (IS) pre λ

$$\left\{ \lambda : \lambda \in (\chi_{2n}^2(1 - \alpha/2) \frac{\bar{T}}{2n}, \chi_{2n}^2(\alpha/2) \frac{\bar{T}}{2n}) \right\},$$

$(1 - \alpha) \times 100\%$ IS pre $1/\lambda$ (IS pre strednú hodnotu $E[T]$)

$$\left\{ 1/\lambda : 1/\lambda \in \left(\frac{2n\bar{T}}{\chi_{2n}^2(\alpha/2)}, \frac{2n\bar{T}}{\chi_{2n}^2(1 - \alpha/2)} \right) \right\}$$

Stanislav Katina

Vybrané kapitoly z analýzy prežívania

Regresné modely pre jednovýberový prípad

Odhady a testy pre exponenciálny model pre necenzurované dátá

funkcia vieročnosti

$$L(\lambda | \mathbf{t}) = \prod_{i=1}^n \lambda \exp(-\lambda t_i) = \lambda^n \exp(-\lambda \sum_{i=1}^n t_i)$$

logaritmus funkcie vieročnosti

$$l(\lambda | \mathbf{t}) = n \log \lambda - \lambda \sum_{i=1}^n t_i$$

maximálne vieročné odhady (MLE)

$$\frac{\partial l(\lambda | \mathbf{t})}{\partial \lambda} = \frac{n}{\lambda} - \sum_{i=1}^n t_i = 0, \text{ potom}$$

$$\hat{\lambda} = \frac{n}{\sum_{i=1}^n t_i} = \frac{1}{\bar{T}}, \widehat{E[T]} = \frac{1}{\hat{\lambda}} = \bar{T}, \widehat{\text{Var}[T]} = \frac{1}{\hat{\lambda}^2} = \bar{T}^2$$

Stanislav Katina

Vybrané kapitoly z analýzy prežívania

Regresné modely pre jednovýberový prípad

Odhady a testy pre exponenciálny model pre necenzurované dátá

- p-ty kvantil t_p , kde $p = F(t_p | \lambda) = 1 - \exp(-\lambda t_p)$, potom $t_p = -\log(1-p)/\lambda$; nech \hat{t}_p je MLE t_p , potom $\hat{t}_p = -\log(1-p)/\hat{\lambda} = -\bar{T} \log(1-p)$ a MLE mediánu je $\hat{t}_{0.5} = -\bar{T} \log(\frac{1}{2}) = \bar{T} \log 2$

test pomerom vieročnosti

$$LR(\lambda_0 | \mathbf{t}) = -2 \log \frac{L(\lambda_0 | \mathbf{t})}{L(\lambda | \mathbf{t})} \sim \chi_1^2$$

kde

$$l(\lambda_0 | \mathbf{t}) = n \log \lambda_0 - \lambda_0 n \bar{T}$$

a

$$l(\lambda | \mathbf{t}) = n \log \frac{1}{\bar{T}} - \frac{1}{\bar{T}} n \bar{T}$$

Stanislav Katina

Vybrané kapitoly z analýzy prežívania

Regresné modely pre jednovýberový prípad

Odhady a testy pre exponenciálny model pre necenzurované dátá

Example (exponenciálny model)

(pokrač.) Majme AML dátá. Ak predpokladáme, že cenzúry sú zlyhania (problém B, kap.1), potom vypočítajte MLE pre strednú hodnotu $1/\lambda$, medián $\hat{t}_{0.5}$ ako aj 95%IS pre λ a $1/\lambda$. Otestujte $H_0 : E[T] = 30$ oproti $H_1 : E[T] \neq 30$ na $\alpha = 0.05$

| Skupina | Čas po kompletnej relaps (v týždňoch) | n | udalostí | cenzúr |
|-----------|--|----|----------|--------|
| skupina A | 9, 13, 13+, 18, 23, 28+, 31, 34, 45+, 48, 161+ | 11 | 7 | 4 |
| skupina B | 5, 5, 8, 8, 12, 16+, 23, 27, 30, 33, 43, 45 | 12 | 11 | 1 |

Stanislav Katina

Vybrané kapitoly z analýzy prežívania

Regresné modely pre jednovýberový prípad

Odhady a testy pre exponenciálny model pre cenzúrované dátá

- Potom platí $\hat{\theta} \sim N_d(\theta, I^{-1}(\theta))$, kde
 - d je dimenzia \mathbf{x}
 - $I(\theta)$ je matica $d \times d$
 - i -ty diagonálny element $I^{-1}(\theta)$ je asymptotickým rozptylom i -teho elementu θ
 - mimodiagonálne elementy sú asymptotickými kovarianciami korešpondujúcich elementov θ
- ak je θ skalár, potom $Var(\theta) = \frac{1}{I(\theta)}$, kde $I(\theta) = -E\left[\frac{\partial^2}{\partial \theta^2} I(\theta|\mathbf{x})\right]$
- pre cenzúrované dátá ide o **funkciu cenzúrovaného rozdelenia G ako aj rozdelenia času prežívania F**
- preto je potrebné aproximovať $I(\theta)$ **pozorovanou informačnou maticou** $I^*(\theta)$ v bode $\hat{\theta}$, kde $I^*(\theta) = -E\left[\frac{\partial^2}{\partial \theta_j \partial \theta_k} I(\theta|\mathbf{x})\right]$
- v jednorozmernom prípade $I^*(\theta) = -E\left[\frac{\partial^2}{\partial \theta^2} I(\theta|\mathbf{x})\right]$, kde rozptyl $Var(\theta) = (I^*(\theta))^{-1}$

Stanislav Katina

Vybrané kapitoly z analýzy prežívania

Regresné modely pre jednovýberový prípad

Odhady a testy pre exponenciálny model pre cenzúrované dátá

- $u \in \mathbb{U}$ – necenzurované pozorovania
- $c \in \mathbb{C}$ – cenzúrované pozorovania
- n_u počet necenzurovaných pozorovaní
- vektor pozorovaní $\mathbf{x} = (x_1, \dots, x_n)^T$ a
- vektor indikácií zlyhania a cenzúry $\delta = (\delta_1, \dots, \delta_n)^T$ (zodpovedajúci \mathbf{x} ; 1 je zlyhanie a 0 je cenzúra)
- Fisherova informačná matica $I(\theta) = -E\left[\frac{\partial^2}{\partial \theta_j \partial \theta_k} I(\theta|\mathbf{x})\right] = nI_1(\theta)$
- Fisherova informačná matica nejakého jedného pozorovania $x_1 I_1(\theta) = -E\left[\frac{\partial^2}{\partial \theta_j \partial \theta_k} f(x_1|\theta)\right]$

Stanislav Katina

Vybrané kapitoly z analýzy prežívania

Regresné modely pre jednovýberový prípad

Odhady a testy pre exponenciálny model pre cenzúrované dátá

- funkcia viero hodnosti** – vo všeobecnosti pre náhodne cenzúrované dátá platí

$$L(\theta|\mathbf{x}) = \prod_{i=1}^n f(x_i|\theta)^{\delta_i} S_f(x_i|\theta)^{1-\delta_i}$$

potom

$$\begin{aligned} L(\lambda|\mathbf{x}) &= \prod_{i:u \in \mathbb{U}} \lambda \exp(-\lambda x_i) \prod_{i:c \in \mathbb{C}} \exp(-\lambda x_i) \\ &= \lambda^{n_u} \exp(-\lambda \sum_{i:u \in \mathbb{U}} x_i) \exp(-\lambda \sum_{i:c \in \mathbb{C}} x_i) \\ &= \lambda^{n_u} \exp(-\lambda \sum_{i=1}^n x_i) \end{aligned}$$

Stanislav Katina

Vybrané kapitoly z analýzy prežívania

Regresné modely pre jednovýberový prípad

Odhady a testy pre exponenciálny model pre cenzúrované dátá

• logaritmus funkcie viero hodnosti

$$I(\theta|\mathbf{x}) = \sum_{i:u \in \mathbb{U}} \log f(x_i|\theta) + \sum_{i:c \in \mathbb{C}} \log S_i(x_i|\theta),$$

$$I(\lambda|\mathbf{x}) = n_u \log \lambda - \lambda \sum_{i=1}^n x_i$$

• maximálne viero hodné odhady (MLE) – prvá a druhá derivácia $I(\lambda|\mathbf{x})$

$$\frac{\partial I(\lambda|\mathbf{x})}{\partial \lambda} = \frac{n_u}{\lambda} - \sum_{i=1}^n x_i, \quad \frac{\partial^2 I(\lambda|\mathbf{x})}{\partial \lambda^2} = -\frac{n_u}{\lambda^2} = -I^*(\lambda),$$

potom

$$\hat{\lambda} = \frac{n_u}{\sum_{i=1}^n x_i}, \quad \widehat{\text{Var}}[\hat{\lambda}] = \frac{\hat{\lambda}^2}{E[n_u]}, \quad \text{kde } E[n_u] = n \Pr(T \leq C)$$

Stanislav Katina

Vybrané kapitoly z analýzy prežívania

Regresné modely pre jednovýberový prípad

Odhady a testy pre exponenciálny model pre cenzúrované dátá

• p -ty kvantil t_p , $\hat{t}_p = -\log(1-p)/\hat{\lambda} = -\frac{\sum_{i=1}^n x_i}{n_u} \log(1-p)$ a MLE mediánu je $\hat{t}_{0.5} = -\frac{\sum_{i=1}^n x_i}{n_u} \log(\frac{1}{2})$; rozptyl p -teho kvantilu

$$\widehat{\text{Var}}(\hat{t}_p) = \log^2(1-p) \widehat{\text{Var}}(1/\hat{\lambda}) \approx \log^2(1-p) \frac{1}{\hat{\lambda}^2 n_u}$$

$(1-\alpha) \times 100\%$ IS pre $t_{0.5}$

$$\left\{ t_{0.5} : t_{0.5} \in (\hat{t}_{0.5} - u_{\alpha/2} \text{SE}(\hat{t}_{0.5}), \hat{t}_{0.5} + u_{\alpha/2} \text{SE}(\hat{t}_{0.5})) \right\}$$

• pomocou delta metódy môžeme vypočítať IS, ktorého hranice sú menej vychýlené najdením transformácií, ktoré eliminujú závislosť rozptylu nejakého parametra na parametri samotnom. Napr. $g(\lambda) = \log \lambda$, $g'(\lambda) = 1/\lambda$ a potom $\text{Var}(\log \lambda) = \lambda^{-2} \frac{\lambda^2}{E[n_u]} \approx \frac{1}{n_u}$

Stanislav Katina

Vybrané kapitoly z analýzy prežívania

Regresné modely pre jednovýberový prípad

Odhady a testy pre exponenciálny model pre cenzúrované dátá

• asymptotické rozdelenie λ

$$\frac{\hat{\lambda} - \lambda}{\sqrt{\widehat{\text{Var}}(\hat{\lambda})}} \sim N(0, 1), \quad \text{kde } \widehat{\text{Var}}(\hat{\lambda}) \approx \frac{\hat{\lambda}^2}{n_u} = \frac{1}{I^*(\lambda)}$$

kde $E[n_u]$ substituujeme za n_u , lebo rozdelenie $G(\cdot)$ nepoznáme. Treba si uvedomiť, že rozptyl je závislý na λ ; potom $(1-\alpha) \times 100\%$ IS pre λ

$$\left\{ \lambda : \lambda \in (\hat{\lambda} - u_{\alpha/2} \text{SE}(\hat{\lambda}), \hat{\lambda} + u_{\alpha/2} \text{SE}(\hat{\lambda})) \right\},$$

$(1-\alpha) \times 100\%$ IS pre $1/\lambda$

$$\left\{ 1/\lambda : 1/\lambda \in (1/\hat{\lambda} - u_{\alpha/2} \text{SE}(1/\hat{\lambda}), 1/\hat{\lambda} + u_{\alpha/2} \text{SE}(1/\hat{\lambda})) \right\},$$

kde $\text{Var}(1/\lambda)$ dostaneme pomocou delta metódy, kde $g(\lambda) = 1/\lambda$, $g'(\lambda) = -1/\lambda^2$ a $\text{Var}(1/\lambda) = \frac{1}{\lambda^2 E[n_u]} \approx \frac{1}{\lambda^2 n_u}$

Stanislav Katina

Vybrané kapitoly z analýzy prežívania

Regresné modely pre jednovýberový prípad

Odhady a testy pre exponenciálny model pre cenzúrované dátá

Potom $\log(\hat{\lambda}) \sim N(\log \lambda, 1/n_u)$, $(1-\alpha) \times 100\%$ IS pre $\log \lambda$

$$\left\{ \log \lambda : \log \lambda \in (\log \hat{\lambda} - u_{\alpha/2} \frac{1}{\sqrt{n_u}}, \log \hat{\lambda} + u_{\alpha/2} \frac{1}{\sqrt{n_u}}) \right\}$$

Analogicky dostaneme

$$\log \frac{1}{\hat{\lambda}} \sim N(\log \frac{1}{\lambda}, \frac{1}{n_u}), \quad \log \hat{t}_{0.5} \sim N(\log t_{0.5}, \frac{1}{n_u}),$$

potom $(1-\alpha) \times 100\%$ IS pre $\log(1/\lambda)$

$$\left\{ \log(1/\lambda) : \log(1/\lambda) \in (\log(1/\hat{\lambda}) - u_{\alpha/2} \frac{1}{\sqrt{n_u}}, \log(1/\hat{\lambda}) + u_{\alpha/2} \frac{1}{\sqrt{n_u}}) \right\}$$

a $(1-\alpha) \times 100\%$ IS pre $\log t_{0.5}$

$$\left\{ \log t_{0.5} : \log t_{0.5} \in (\log \hat{t}_{0.5} - u_{\alpha/2} \frac{1}{\sqrt{n_u}}, \log \hat{t}_{0.5} + u_{\alpha/2} \frac{1}{\sqrt{n_u}}) \right\}$$

Spätnou transformáciou hraníc IS pre $\log(\text{paramater})$ dostaneme hranice pre IS parametra ako $\exp(\text{koncové body})$

Stanislav Katina

Vybrané kapitoly z analýzy prežívania

Regresné modely pre jednovýberový prípad

Odhady a testy pre exponenciálny model pre cenzúrované dátá

- ML odhad funkcie prežívania $\widehat{S}(t) = \exp(-\widehat{\lambda}t)$, ktorej rozdelenie môžeme dostať pomocou delta metódy

Alternatívne zoberieme **log-log transformáciu**, ktorá zvyčajne urýchli konvergenciu k normalite (kvôli nezávislosti rozptylu na neznámom parametri λ). Vieme, že $\log(\widehat{\lambda}) \sim N(\log \lambda, 1/n_u)$, potom

$$\log(-\log \widehat{S}(t)) = \log(\widehat{\lambda}) + \log t$$

a pre rozptyl platí

$$\text{Var}(\widehat{-\log \widehat{S}(t)}) = \text{Var}(\widehat{\log(\widehat{\lambda})}) \approx \frac{1}{n_u}$$

Z delta metódy pre každé fixované t platí

$$\log(-\log \widehat{S}(t)) \sim N\left(\log(-\log S(t)), \frac{1}{n_u}\right), \text{ kde } \log(-\log S(t)) = \log(\lambda t)$$

$(1 - \alpha) \times 100\%$ IS pre $S(t)$

$$\left\{ S(t) : S(t) \in \left(\exp\left(\log \widehat{S}(t) \exp\left(\frac{u_{\alpha/2}}{\sqrt{n_u}}\right)\right), \exp\left(\log \widehat{S}(t) \exp\left(\frac{-u_{\alpha/2}}{\sqrt{n_u}}\right)\right) \right) \right\}$$

Stanislav Katina

Vybrané kapitoly z analýzy prežívania

Regresné modely pre jednovýberový prípad

Odhady a testy pre exponenciálny model pre cenzúrované dátá

Example (exponenciálne rozdelenie)

(pokrač.) Majme AML dátá. Vypočítajte MLE pre strednú hodnotu $1/\lambda$, medián $\widehat{t}_{0.5}$ ako aj 95%IS pre λ a $1/\lambda$. Otestujte $H_0 : E[T] = 30$ oproti $H_1 : E[T] \neq 30$ na $\alpha = 0.05$.

| Skupina | Čas po kompletnej relaps (v týždňoch) | n | udalostí | cenzúr |
|-----------|--|----|----------|--------|
| skupina A | 9, 13, 13+, 18, 23, 28+, 31, 34, 45+, 48, 161+ | 11 | 7 | 4 |
| skupina B | 5, 5, 8, 8, 12, 16+, 23, 27, 30, 33, 43, 45 | 12 | 11 | 1 |

Example (exponenciálne rozdelenie)

(pokrač.) Použitím funkcie survreg pre cenzurované dátá zopakujte výpočty urobené ručne, teda vypočítajte bodové odhady strednej hodnoty a mediánu ako aj ich 95%IS a zostrojte qq-diagram. Nakreslite funkcie prežívania pre exponenciálne, Weibullovo a log-logistické rozdelenie a porovnajte ich s $\widehat{S}_{KM}(t)$.

Stanislav Katina

Vybrané kapitoly z analýzy prežívania

Regresné modely pre jednovýberový prípad

Odhady a testy pre exponenciálny model pre cenzúrované dátá

- test pomerom vierošodnosti

$$LR(\lambda_0) = -2 \log \frac{L(\lambda_0)}{L(\lambda)} \sim \chi^2_1,$$

kde

$$I(\lambda_0 | \mathbf{x}) = n_u \log \lambda_0 - \lambda_0 \sum_{i=1}^n x_i$$

a

$$I(\lambda | \mathbf{x}) = n_u \log \frac{n_u}{\sum_{i=1}^n x_i} - n_u$$

Stanislav Katina

Vybrané kapitoly z analýzy prežívania

Regresné modely pre jednovýberový prípad

Odhady a testy pre exponenciálny model pre cenzúrované dátá

Pozn.: **Exponenciálne rozdelenie** času t je Weibullovo rozdelenie s parametrom tvaru $\theta = 1$ alebo $\log t$ má rozdelenie extrémnej hodnoty so škálou $\sigma = 1$. Funkcia survreg fituje $\log t$ a výstupom je $\widehat{\mu} = -\log \widehat{\lambda}$ (parameter polohy rozdelenia extrémnej hodnoty). Pre **Weibullovo rozdelenie** $\widehat{\lambda} = \exp(-\widehat{\mu})$ a odhad $1/\widehat{\lambda} = \exp(\widehat{\mu})$ a naviac $\widehat{\sigma} = 1/\widehat{\theta}$. Funkcia summary(fit), kde fit je vypočítaný pomocou funkcie survreg, nám poskytuje práve $\widehat{\mu}$ a $\widehat{\sigma}$. Vo funkcií survreg treba špecifikovať rozdelenie dist="weibull". Funkcia predict je doplnkom ku funkcií survreg a jej výstupom sú odhady kvantilov a ich štandardných chýb. Jeden z argumentov funkcie predict je type. Nastavte type="uquantile", kedy ide o log-transformáciu. Default počíta odhady rozptylu a IS pomocou delta metódy. Ak chceme odhadnúť lineárny prediktor (lp), potom použijeme funkciu predict(fit, type="lp", newdata = list(skupina = 1)).

Pri výpočte $\widehat{S}(t)$ pre **log-logistické rozdelenie** treba mať na zreteli, že parametre z log-logistického modelu ($\widehat{\mu}$ a $\widehat{\sigma}$, funkcia survreg) sa aplikujú na $Y = \log T$. Vo funkcií survreg treba špecifikovať rozdelenie dist="loglogistic". Pre **lognormálne rozdelenie** dist="lognormal". Označenia distribučných funkcií v R sú nasledovné

| | Weibullovo r. | logistické r. ($Y = \log T$) | normálne r. ($Y = \log T$) |
|--------|---------------------------------------|--------------------------------|------------------------------|
| $F(t)$ | pweibull(q, θ, λ^{-1}) | plogis(q, μ, σ) | pnorm(q, μ, σ) |
| t_p | qweibull(p, θ, λ^{-1}) | qlogis(p, μ, σ) | qnorm(p, μ, σ) |

Stanislav Katina

Vybrané kapitoly z analýzy prežívania

Regresné modely pre jednovýberový prípad

Odhady a testy pre exponenciálny model pre cenzúrované dátá




Figure: Porovnanie qq-diagramov

Stanislav Katina

Vybrané kapitoly z analýzy prežívania

Regresný model pre dvojvýberový prípad

Úvod

- zamerajme sa na **porovnanie dvoch škálových parametrov λ**
– v **log-transformácii** pôjde o porovnanie dvoch parametrov polohy $\mu = -\log \lambda$
- použijeme AML dátá, kde **nparametrický log-rank test** zamietol H_0 o rovnosti dvoch kriviek prežívania (p-hodnota=0.03265)
- najprv si položíme otázku, **či nejaký model** (log-rozdelenie, ktoré patrí do rodiny rozdelení polohy a škály) **fituje dátá adekvátnie**
- satuovaný (plný) log-lineárny model** môžeme písť ako

$$\begin{aligned} Y = \log T &= \tilde{\mu} + \epsilon \\ &= \beta_0^* + \beta^* \text{skupina} + \epsilon \\ &= \begin{cases} \beta_0^* + \beta^* \text{skupina} + \epsilon, & \text{kde skupina=1} \\ \beta_0^* + \epsilon, & \text{kde skupina=0} \end{cases} \end{aligned}$$

Stanislav Katina

Vybrané kapitoly z analýzy prežívania

Regresné modely pre jednovýberový prípad

Odhady a testy pre exponenciálny model pre cenzúrované dátá




Figure: Porovnanie funkcií prežívania

Stanislav Katina

Vybrané kapitoly z analýzy prežívania

Regresný model pre dvojvýberový prípad

Úvod

- parameter $\tilde{\mu} = \beta_0^* + \beta^* \text{skupina}$ – **lineárny prediktor**, ktorý nadobúda dve hodnoty
 - $\mu_1 = \beta_0^* + \beta^*$
 - $\mu_2 = \beta_0^*$
- vieme, že $\tilde{\mu} = -\log \tilde{\lambda}$, kde $\tilde{\lambda}$ znamená **parameter škály** rozdelenia premennej T
- potom $\tilde{\lambda} = \exp(-\beta_0^* - \beta^* \text{skupina})$ nadobúda dve hodnoty
 - $\lambda_1 = \exp(-\beta_0^* - \beta^*)$
 - $\lambda_2 = \exp(-\beta_0^*)$
- nulová hypotéza**
 $H_0 : \lambda_1 = \lambda_2$ vtedy a len vtedy, keď $\mu_1 = \mu_2$ vtedy a len vtedy, keď $\beta^* = 0$
- treba si uvedomiť, že **parameter škály** σ v log-transformovanom modeli je rovný $(\text{parameter polohy})^{-1}$, kde ide o parameter polohy θ originálneho (netransformovaného) modelu, teda $\sigma = 1/\theta$

Stanislav Katina

Vybrané kapitoly z analýzy prežívania

Regresný model pre dvojvýberový prípad

Úvod

H_0 testujeme za nasledovných dvoch predpokladov

P1 Predpokladáme **rovnaký parameter tvaru** θ , teda predpokladáme, že $\sigma_1 = \sigma_2$ (**parametre škály**) sa rovnajú.
Potom sa chyba $\epsilon = \sigma Z$, kde náhodná premenná Z pochádza z rozdelenia extrémnych hodnôt, štandardizovaného logistického rozdelenia alebo štandardizovaného normálneho rozdelenia.

P2 Predpokladáme **rôzne parametre tvaru** θ , teda $\sigma_1 \neq \sigma_2$

Na testovanie H_0 použijeme tri nasledovné modely

M1 Dáta pochádzajú z **rovnakého rozdelenia**, kde **nulový model** bude mať tvar $Y = \log T = \beta_0^* + \sigma Z$, kde Z pochádza z rozdelenia extrémnych hodnôt.

M2=P1 **Model s rôznymi parametrami polohy** μ a **rovnakými parametrami škály** σ bude mať tvar

$$Y = \log T = \beta_0^* + \beta^* \text{skupina} + \sigma Z$$

M3=P2 **Model s rôznymi parametrami polohy** μ a **škály** σ bude mať tvar $Y = \log T = \beta_0^* + \beta^* \text{skupina} + \epsilon$

Stanislav Katina

Vybrané kapitoly z analýzy prežívania

Regresný model pre dvojvýberový prípad

Exponenciálny a Weibullov regresný model pre dve skupiny

Nech $\tilde{\mu} = -\log \tilde{\lambda}$ a $\sigma = 1/\theta$. Potom

$$\lambda(t|\text{skupina}) = \theta \tilde{\lambda}^\theta t^{\theta-1} = \theta \lambda^\theta t^{\theta-1} \exp(\beta \text{skupina}) = \lambda_0(t) \exp(\beta \text{skupina}),$$

kde $\lambda = \exp(-\beta_0^*)$ a $\beta = -\beta^*/\sigma$, $\lambda_0(t)$ je **baseline riziko** (teda ak skupina=0 alebo $\beta = 0$). Teda $\lambda_0(t)$ je **riziková funkcia pre Weibullovo rozdelenie so škálou** λ nezávislá na ďalších premenných.

Pomer rizík skupina=1 a skupina=0

$$\text{HR} = \frac{\lambda(t|1)}{\lambda(t|0)} = \frac{\exp \beta}{\exp 0} = \exp \beta,$$

teda môžeme povedať, že Weibullov model spĺňa **podmienku proporcionality rizík**. Ak $\theta = 1$ ide o exponenciálny regresný model.

Regresný model pre dvojvýberový prípad

Úvod

| model | parametre | slovné vyjadrenie |
|-------|--|------------------------------|
| M1 | β_0^*, σ | rovnaká poloha a škála |
| M2 | $\beta_0^*, \beta^*, \sigma \equiv \mu_1, \mu_2, \sigma$ | rôzna poloha a rovnaká škála |
| M3 | $\beta_0^*, \beta^*, \sigma_1, \sigma_2 \equiv \mu_1, \mu_2, \sigma_1, \sigma_2$ | rôzna poloha a škála |

Stanislav Katina

Vybrané kapitoly z analýzy prežívania

Všeobecné zápisy regresných modelov

Exponenciálny regresný model

Nech **funkcia rizika** $\lambda(t, \lambda) = \lambda(t) = \lambda$ je konštantná pri rôznych hodnotách t a $E[T] = 1/\lambda$. Modelujme riziko λ ako funkciu vektora premenných \mathbf{x} , potom **funkcia rizika** bude mať tvar

$$\lambda(t|\mathbf{x}) = \lambda_0(t) \exp(\mathbf{x}^T \beta) = \lambda \exp\left(\sum_{i=1}^k \beta_i x_i\right),$$

odkiaľ je zreteľné, že premenné ovplyvňujú riziko **multiplikatívne**. V log-lineárnom modeli

$$\log(\lambda(t|\mathbf{x})) = \log(\lambda) + \mathbf{x}^T \beta = \log(\lambda) + \sum_{i=1}^k \beta_i x_i$$

premenné ovplyvňujú logaritmus rizika **aditívne** a $\sum_{i=1}^k \beta_i x_i$ sa nazýva **lineárny prediktor log-riazika**.

Stanislav Katina

Vybrané kapitoly z analýzy prežívania

Stanislav Katina

Vybrané kapitoly z analýzy prežívania

Všeobecné zápisy regresných modelov

Exponenciálny regresný model

Funkcia prežívania

$$S(t|\mathbf{x}) = \exp(-\lambda(t|\mathbf{x})t) = \exp(-\lambda t \exp(\mathbf{x}^T \boldsymbol{\beta}))$$

Hustota

$$f(t|\mathbf{x}) = \lambda(t|\mathbf{x}) S(t|\mathbf{x}) = \lambda \exp(\mathbf{x}^T \boldsymbol{\beta}) \exp(-\lambda t \exp(\mathbf{x}^T \boldsymbol{\beta}))$$

Ak T je **rozdelené exponenciálne**, potom $Y = \log T$ má **rozdelenie extrémnych hodnôt s parametrom škály** $\sigma = 1$. Potom

$$\tilde{\mu} = -\log(\lambda(t|\mathbf{x})) = -\lambda \exp(\mathbf{x}^T \boldsymbol{\beta}) = -\log \lambda - \mathbf{x}^T \boldsymbol{\beta}, \sigma = 1$$

a platí

$$Y = \log T = \tilde{\mu} + \sigma Z = \beta_0^* + \mathbf{x}^T \boldsymbol{\beta}^* + Z,$$

kde $\beta_0^* = -\log \lambda$, $\boldsymbol{\beta}^* = -\boldsymbol{\beta}$ a $Z \sim f(z) = \exp(z - e^z)$, $z \in \mathbb{R}$ je **rozdelenie extrémnych hodnôt**.

Zhrnutie: $\lambda(t|\mathbf{x}) = \lambda \exp(\mathbf{x}^T \boldsymbol{\beta})$ je log-lineárny model zlyhania a je transformovaný na lineárny model $Y = \log T$.

Stanislav Katina

Vybrané kapitoly z analýzy prežívania

Všeobecné zápisy regresných modelov

Weibullov regresný model

Ak $T \sim W(\lambda, \theta)$, potom $Y = \log T = \tilde{\mu} + \sigma Z$, podmienené dátami \mathbf{x} ,

$$\tilde{\mu} = -\log(\tilde{\lambda}) = \log(\lambda(\exp(\mathbf{x}^T \boldsymbol{\beta}))^{\frac{1}{\theta}}) = -\log(\lambda) - \frac{1}{\theta} \sum_{i=1}^k \beta_i x_i, \sigma = \frac{1}{\theta}$$

a Z má **štandardizované rozdelenie extrémnych hodnôt**. Preto

$$Y = \tilde{\mu} + \sigma Z = \beta_0^* + \mathbf{x}^T \boldsymbol{\beta}^* + \sigma Z$$

kde $\beta_0^* = -\log \lambda$, $\boldsymbol{\beta}^* = -\sigma \boldsymbol{\beta}$.

Stanislav Katina

Vybrané kapitoly z analýzy prežívania

Všeobecné zápisy regresných modelov

Weibullov regresný model

Zovšeobecníme teraz funkciu rizika $\lambda(t) = \theta \lambda^{\theta} t^{\theta-1}$ tak, že budeme modelovať $\lambda(t)$ ako funkciu vektora premenných \mathbf{x} . Potom **funkcia rizika** bude mať tvar

$$\begin{aligned}\lambda(t|\mathbf{x}) &= \lambda_0(t) \exp(\mathbf{x}^T \boldsymbol{\beta}) \\ &= \theta \lambda^{\theta} t^{\theta-1} \exp(\mathbf{x}^T \boldsymbol{\beta}) \\ &= \theta \left(\lambda(\exp(\mathbf{x}^T \boldsymbol{\beta}))^{\frac{1}{\theta}} \right)^{\theta} t^{\theta-1} = \theta \tilde{\lambda}^{\theta} t^{\theta-1},\end{aligned}$$

kde $\tilde{\lambda} = \lambda(\exp(\mathbf{x}^T \boldsymbol{\beta}))^{\frac{1}{\theta}}$. Potom **log-lineárny model** bude mať tvar

$$\begin{aligned}\log(\lambda(t|\mathbf{x})) &= \log(\theta) + \theta \log(\tilde{\lambda}) + (\theta - 1) \log(t) \\ &= \log(\theta) + \theta \log(\lambda) + \sum_{i=1}^k \beta_i x_i + (\theta - 1) \log(t)\end{aligned}$$

Stanislav Katina

Vybrané kapitoly z analýzy prežívania

Všeobecné zápisy regresných modelov

Weibullov regresný model

Funkcia prežívania

$$S(t|\mathbf{x}) = \exp(-(\tilde{\lambda} t)^{\theta}).$$

Vieme, že $\Lambda(t|\mathbf{x}) = -\log(S(t|\mathbf{x}))$. Potom **logaritmus funkcie kumulatívneho rizika**

$$\begin{aligned}\log(\Lambda(t|\mathbf{x})) &= \theta \log(\tilde{\lambda}) + \theta \log(t) \\ &= \theta \log(\lambda) + \theta \log(t) + \sum_{i=1}^k \beta_i x_i \\ &= \log(\Lambda_0(t)) + \sum_{i=1}^k \beta_i x_i,\end{aligned}$$

kde $\Lambda_0(t) = -\log(S_0(t)) = (\lambda t)^{\theta}$ je **baseline funkcie kumulatívneho rizika**.

Stanislav Katina

Vybrané kapitoly z analýzy prežívania

Všeobecné zápisy regresných modelov

Weibullov regresný model

Logaritmus funkcie kumulatívneho rizika je lineárny v $\log t$ a v regresných koeficientoch β . Potom vo fixovaných x graf $\Lambda(t|x)$ oproti t v log-log škále je priamka so **sklonom** θ a **interceptom** $\mathbf{x}^T \beta + \theta \log \lambda$. Dá sa ľahko ukázať, že

$$\Lambda(t|x) = \Lambda_0(t) \exp(\mathbf{x}^T \beta) = (\lambda t)^\theta \exp(\mathbf{x}^T \beta).$$

Weibullov regresný model je jediný log-lineárny model, ktorý spĺňa podmienku **proporcionality rizika**. Vieme, že

$\lambda(t|x) = \lambda_0(t) \exp(\mathbf{x}^T \beta)$, kde $\lambda_0(t) = \theta \lambda^\theta t^{\theta-1}$ ako aj to, že

$\Lambda_0(t) = (\lambda t)^\theta$. Ďalej vieme, že $\log(\Lambda(t|x)) = \theta \log(\lambda) + \theta \log(t) + \mathbf{x}^T \beta$.

Vzťah medzi koeficientami log-lineárnom modelu a koeficientami v rizikovej funkcií je nasledovný

$$\beta = -\sigma^{-1} \beta^* \text{ a } \lambda = \exp(-\beta_0^*).$$

Pomer rizík sa dá napísť nasledovne

$$HR(t|x_1, x_2) = \frac{\lambda(t|x_2)}{\lambda(t|x_1)} = \left(\exp((\mathbf{x}_2^T - \mathbf{x}_1^T) \beta^*) \right)^{1/\sigma}.$$

Stanislav Katina

Vybrané kapitoly z analýzy prežívania

Všeobecné zápisy regresných modelov

Log-logistický regresný model

Nech $Z^* = \sigma Z$. Potom môžeme písť

$$Y = \beta_0^* + \mathbf{x}^T \beta^* + Z^*,$$

kde $Z^* \sim \text{logistické rozdelenie so strednou hodnotou } \beta_0^*$ a škálou σ . Potom **baseline riziková funkcia** log-logistického času $T^* = \exp Z^*$ je

$$\lambda_0^*(t^*) = \frac{\lambda \theta (\lambda t^*)^{\theta-1}}{1 + (\lambda t^*)^\theta}$$

kde $\beta_0^* = -\log \lambda$ a $\sigma = 1/\theta$. Treba si uvedomiť, že $\lambda_0^*(t^*)$ je nezávislý na β^* . Potom pre **rizikovú funkciu** T píšeme

$$\lambda(t|x) = \frac{\tilde{\lambda}^\theta t^{\theta-1}}{1 + \tilde{\lambda}^\theta t^\theta},$$

kde $\tilde{\lambda} = \lambda \exp(-\mathbf{x}^T \beta^*)$. A naviac pre dané x , $T \sim \text{log-logisticky rozdelené s parametrami } \tilde{\lambda}$ a θ .

Stanislav Katina

Vybrané kapitoly z analýzy prežívania

Všeobecné zápisy regresných modelov

Log-logistický regresný model

Majme model

$$T = \exp Y = \exp(\beta_0^* + \mathbf{x}^T \beta^* + \sigma Z) = \exp(\mathbf{x}^T \beta^*) T^*,$$

kde $T^* = \exp Z^*$, $Z^* = \beta_0^* + \sigma Z$. Teda x má **multiplikatívny efekt** na čas T . **Riziková funkcia** času T (pre dané x) sa dá zapísať ako funkcia $\lambda_0^*(\cdot)$ v podobe

$$\lambda(t|x) = \lambda_0^* \left(\exp(-\mathbf{x}^T \beta^*) t \right) \exp(-\mathbf{x}^T \beta^*),$$

čo vyplýva z transformačnej vety.

Pozn.: $f(t) = f^*(g^{-1}(t)) \left| \frac{\partial g^{-1}(t)}{\partial t} \right|$, kde $t = g(t^*)$.

Nech $Y = \log T$, potom má **log-lineárny model** tvar

$$Y = \beta_0^* + \mathbf{x}^T \beta^* + \sigma Z,$$

kde $Z \sim \text{štandardizované logistické rozdelenie}$.

Stanislav Katina

Vybrané kapitoly z analýzy prežívania

Všeobecné zápisy regresných modelov

Log-logistický regresný model

Teda

$$Y = \log T = \tilde{\mu} + \sigma Z,$$

kde $\tilde{\mu} = -\log(\tilde{\lambda}) = -\log \lambda + \mathbf{x}^T \beta^* = \beta_0^* + \mathbf{x}^T \beta^*$ a $Z \sim \text{štandardizované logistické rozdelenie}$. Log-logistický model je **log-lineárnym modelom**, ale nie je modelom proporcionalného rizika ako napr. Weibullov regresný model.

Log-logistický regresný model má jednu výhodu oproti ostatným modelom, pretože ide o **model proporcionalných šancí a proporcionalného času**. Log-logistická funkcia prežívania má tvar $S(t|x) = S_0^*(\exp(-\mathbf{x}^T \beta^*) t) = S_0^*(t^*)$, kde $= S_0^*(\cdot)$ je **baseline funkcia prežívania**.

Pozor! x mení škálu horizontálnej (t) osi. Ak $\mathbf{x}^T \beta^*$ rastie, potom čas do zlyhania klesá a naopak. Preto sa takýto log-lineárny model nazýva **spomaľovací (zrýchľovací) model času zlyhania (accelerated (decelerated) failure time model)**. Do tejto skupiny modelov patrí aj exponenciálny, Weibullov a aj log-normálny regresný model.

Stanislav Katina

Vybrané kapitoly z analýzy prežívania

Všeobecné zápisy regresných modelov

Log-logistický regresný model

Pre funkciu prežívania platí

$$S(t|\mathbf{x}) = S_0^*(\exp(-\mathbf{x}^T \beta^*)t) = \frac{1}{1 + (\exp(y - \beta_0^* - \mathbf{x}^T \beta^*))^\theta},$$

kde $y = \log t$, $\beta_0^* = -\log \lambda$ a $\theta = 1/\sigma$.

Šanca prežitia za časom t je daná ako

$$\frac{S(t|\mathbf{x})}{1 - S(t|\mathbf{x})} = \left(\exp(y - \beta_0^* - \mathbf{x}^T \beta^*) \right)^{-\theta},$$

kde treba zdôrazniť, že $-\log(\text{šanca})$ je lineárnom funkciou $\log t$ ako aj premenných $x_j, j = 1, 2, \dots, k$. Pomer šancí za časom t počítaný medzi x_1 a x_2 sa dá vyjadriť nasledovne

$$\text{OR}(t|\mathbf{x}_2, \mathbf{x}_1) = \left(\exp(\mathbf{x}_2 - \mathbf{x}_1)^T \beta^* \right)^\theta$$

naviac časový pomer v t počítaný medzi x_1 a x_2

$$\text{TR}(t|\mathbf{x}_2, \mathbf{x}_1) = (\text{OR}(\mathbf{x}_2, \mathbf{x}_1))^{1/\theta}$$

Stanislav Katina

Vybrané kapitoly z analýzy prežívania

Všeobecné zápisy regresných modelov

Log-logistický regresný model

- $\text{OR} = \text{TR}^\theta$, kde pomer OR je kontrolovaný θ , tvarovým parametrom log-logistického rozdelenia

Example

Ak $\theta = 1$, tak $\text{OR} = \text{TR}$. Ak $\theta = 2$, tak $\text{TR} = 2$ a $\text{OR} = 2^2 = 4$.

- na jednotku nárastu jednej premennej, fixovaním ostatných premených v \mathbf{x} , $\text{OR} \rightarrow +\infty \vee 0$ ak $\theta \rightarrow \infty$ (v závislosti od znamienka korešpondujúcej premennej pri β^*)
- na zistenie $\widehat{\text{HR}}$ a $\widehat{\text{OR}}$ – odhady vypočítané funkciou `survreg`
- ľubovoľný $p \times 100\%$ percentil log-logistického modelu času t

$$t_p(\mathbf{x}) = \left(\frac{p}{1-p} \right)^\sigma \exp(\beta_0^* + \mathbf{x}^T \beta^*)$$

- log-logistický regresný model je jediným akcelerovaným modelom zlyhania, ktorý spĺňa podmienky proporcionality šancí a proporcionality času

Stanislav Katina

Vybrané kapitoly z analýzy prežívania

Všeobecné zápisy regresných modelov

Log-logistický regresný model

- pomer šancí je často používaný na meranie efektu premenných x_j a je nezávislý na čase t , čo nazývame **vlastnosť proporcionality šancí**.

Example

Ak $\text{OR} = 2$, potom šanca prežitia za časom t jedincov s x_2 je $2\times$ tak veľká ako u jedincov s x_1 , čo platí pre všetky t .

- rovnako aj **TR je nezávislý na čase**, čo nazývame **vlastnosť proporcionality časov**.

Example

Podobne ak $\text{TR} = 2$, tak čas prežívania jedincov s x_2 je $2\times$ väčší ako u jedincov s x_1 .

Stanislav Katina

Vybrané kapitoly z analýzy prežívania

Všeobecné zápisy regresných modelov

Príklad v R

Example

(pokrač.) Použitím funkcie `survreg` pre cenzurované dátu odhadnite parametre Weibullovho, log-logistického a log-normálneho modelu a samotné modely porovnajte.

Stanislav Katina

Vybrané kapitoly z analýzy prežívania

Všeobecné zápisy regresných modelov

Príklad v R

- Na základe výsledkov LR testu medzi modelmi M1 a M2 ako aj M2 a M3 môžeme konštatovať, že model M2, ktorý predpokladá rovnakú škálu je adekvatný.
- Výsledky z modelov M1, M2 a M3 zhrnieme v nasledovnej tabuľke

| rozdelenie | $L(\hat{\beta}_0^*, \hat{\beta}^*)$ | p-hodnota | $\hat{\beta}_0^*$ | $\hat{\beta}^*$ | p-hodnota (skupina) |
|----------------|-------------------------------------|-----------|-------------------|-----------------|---------------------|
| Weibullov | -80.5 | 0.021 | 3.180 | 0.929 | 0.0151 |
| log-logistické | -79.4 | 0.120 | 2.899 | 0.604 | 0.1240 |
| log-normálne | -78.9 | 0.062 | 2.854 | 0.724 | 0.0568 |

- Vo Weibullovom modeli je efekt skupiny signifikantný (prvá skupina zostáva v remisií dlhšie, t.j. prežívanie je v druhej skupine kratšie) s odhadmi $\hat{\mu}_1 = 4.109$ a $\hat{\mu}_2 = 4.109 - 0.929 = 3.18$ rozdelenia extrémnych hodnôt.
- Log-normálny model má maximálnu vieročnosť najväčšiu a Weibullov model najmenšiu. Avšak LR testu fitu modelu je signifikantný len pre Weibullov model, kde p-hodnota=0.0151.

Stanislav Katina

Vybrané kapitoly z analýzy prežívania

Všeobecné zápisy regresných modelov

Príklad v R




Figure: Porovnanie kvantilových diagramov (Weibullove modely M1 a M2, log-logistický model, log-normálny model)

Stanislav Katina

Vybrané kapitoly z analýzy prežívania

Všeobecné zápisy regresných modelov

Príklad v R

- Mediány s ich 95%IS zhŕňa pre všetky modely nasledovná tabuľka

| model | med 1 | 95%IS pre med 1 | med 2 | 95%IS pre med 2 |
|----------------|--------|------------------|--------|------------------|
| Weibullov | 45.566 | (24.901, 83.381) | 17.990 | (10.966, 29.514) |
| Log-logistický | 33.215 | (18.902, 58.366) | 18.147 | (10.747, 30.641) |
| Log-normálny | 35.833 | (20.510, 62.605) | 17.364 | (10.556, 28.561) |

- Odhad lineárneho prediktora $\hat{\mu} = \hat{\beta}_0^* + \hat{\beta}^* \text{skupina}$, $\hat{\mu} = \log(\hat{\lambda})$, $\hat{\lambda} = \exp(-\hat{\mu}) = \exp(-\hat{\beta}_0^* - \hat{\beta}^* \text{skupina})$, $\hat{\theta} = 1/\hat{\sigma}$ pre všetky tri modely (Weibullov, log-logistický a log-normálny; zlava doprava) zhŕňa nasledovná tabuľka

| skupina | $\hat{\lambda}$ | $\hat{\sigma}$ | $\hat{\lambda}$ | $\hat{\sigma}$ | $\hat{\lambda}$ | $\hat{\sigma}$ |
|---------|-----------------|----------------|-----------------|----------------|-----------------|----------------|
| 0 | 0.042 | 1.264 | 0.055 | 1.950 | 0.058 | 1.160 |
| 1 | 0.016 | 1.264 | 0.030 | 1.950 | 0.028 | 1.160 |

- Z qq-diagramu je zrejmé, že log-logistický a log-normálny model fitujú skupinu Maintained lepšie ako Weibullov regresný model. Avšak fit skupiny Nonmain- tained sa použitím týchto modelov nezlepší.

Stanislav Katina

Vybrané kapitoly z analýzy prežívania

Všeobecné zápisy regresných modelov

Príklad v R

- Neparametrický prístup (KM odhad) dáva lepší náhľad na AML dátu




Figure: Porovnanie funkcií prežívania

Stanislav Katina

Vybrané kapitoly z analýzy prežívania

- Majme Weibullov model. Nech

$$\hat{\beta} = -\hat{\beta}^*/\hat{\sigma} = -0.929/0.791 = -1.1745, \text{ potom odhad pomeru rizík}$$

$$\widehat{HR} = \hat{\lambda}(t|1)/\hat{\lambda}(t|0) = \exp(\hat{\beta})/\exp(0) = \exp(\hat{\beta}) = 0.31.$$

Skupina Maitained má 31% riziko z rizika kontrolnej skupiny Nonmaitained. Alebo kontrolná skupina má $1/0.31 = 3.23 \times$ väčšie riziko ako skupina Maitained. HR je teda miera efektu vplyvu skupiny na čas prežívania (čas do relapsu alebo recidívy).

- Majme opäť Weibullov model. Ak vypočítame pomer odhadnutých pravdepodobností prežívania, napr. v čase $t = 31$ týždňov

$$(\hat{\lambda} = \exp(-\hat{\mu})), \text{ dostaneme}$$

$\hat{S}(31|1)/\hat{S}(31|0) = 0.6531634/0.2517891 = 2.594$, čo znamená, že skupina Maitained má $2.594 \times$ väčšiu pravdepodobnosť zostať v remisií (dočasné zlepšenie stavu) najmenej 31 týždňov ako skupina Nonmaitained.




Figure: Porovnanie intervalov spoľahlivosti pre medián (Weibullov, log-logistický a log-normálny model)