

Analiza cenzuriranih podataka i krivulje preživljenja

Mladen Petrovečki

Katedra za medicinsku informatiku, Medicinski fakultet Sveučilišta u Rijeci
i Klinička bolnica Dubrava, Zagreb

Analiza preživljenja

1. temeljni pojmovi
2. izračun vjerojatnosti preživljenja
 - a) tablice preživljenja
 - b) Kaplan-Meierov postupak
3. rizik umiranja
4. programska potpora
5. usporedba podataka o preživljenju
6. statističko zaključivanje
7. regresijska analiza cenzuriranih podataka

Obrada podataka o preživljenju bolesnika

- analiza preživljenja
- *survival analysis*
- ponekad
 - analiza tablica preživljenja
 - analiza osiguravateljskih (aktuarskih) podataka
 - *actuarial analysis*

Analiza preživljenja

- Edmund Halley, 17. st
- engleski astronom, geofizičar, matematičar, meteorolog i fizičar
- http://en.wikipedia.org/wiki/Edmond_Halley

www.aktuari.hr


- aktuar – stručnjak koji se bavi problemima financijske neizvjesnosti i rizika koristeći matematičke metode teorije vjerojatnosti, statistike i financijske matematike
- posao – analiza podataka iz prošlosti, procjenu postojećih rizika i razvoj modela za projekciju budućih događaja
- zaposlenje – osiguranje i mirovinsko osiguranje
- znanja – matematika, ekonomija, praksa i zakoni države u kojoj radi, demografska i financijska kretanja, vještina komunikacije

Analiza preživljenja

- psihijatrija – 1%
- patologija – 1%
- kirurgija – 12%
- onkologija – 14%
- izvorni znanstveni radovi u *The New England Journal of Medicine* – 32%
- podaci 1986.-2001., Dawson Saunders & Trapp, *Basic and Clinical Biostatistics*


Analiza preživljenja

- analiza podataka vezanih uz vremensko praćenje događaja
- dvije točke praćenja:
 - početak (P) (*time origin*)
 - kraj (K) (*end point*)




Početak praćenja

- rođenje
- pojava znaka bolesti
- postavljanje dijagnoze
- početak liječenja
- dan operativnog zahvata



Kraj praćenja

- smrt od osnovne bolesti
- smrt (svi ostali mogući uzroci)
- ponovno javljanje bolesti
- postizanje učinka liječenja
- gubitak iz uzorka (ispitne skupine)



Kraj praćenja

- smrt od osnovne bolesti
- smrt (svi ostali mogući uzroci)

usklađeno
preživljenje
engl. *adjusted
survival rate*

ukupno preživljenje
engl. *observed survival rate*


Manual for Staging of Cancer
3rd ed., AJCC

Vrijeme praćenja

- raspodjela u pravilu nije simetrična
- podaci su nepotpuni, praćenje je nepotpuno, "cenzurirano" (*censored data*)
- podaci za primjere:
 - istraživanje karcinoma usne šupljine
 - MFK KBD
 - dr. Ivica Lukšić
 - n = 52; 1. siječnja 2000. – 31. prosinca 2004.
 - reprezentativni probirani uzorak
 - dio populacije tog razdoblja
 - prva dg. karcinoma, bez regionalnih metastaza, itd.


Vrijeme praćenja (1)

- raspodjela u pravilu nije simetrična




Vrijeme praćenja (2)

- potpuni podaci (potpuno praćenje)




Vrijeme praćenja (2)

- podaci su nepotpuni, praćenje je nepotuno, "cenzurirano"
 - cenzurirano vrijeme praćenja = jedinka tijekom praćenja ne dostiže očekivani događaj



Vrijeme praćenja (3)


- podaci su nepotpuni, praćenje je nepotuno, "cenzurirano"
 - cenzurirano vrijeme praćenja = jedinka tijekom praćenja ne dostiže očekivani događaj



Cenzuriranje


- događaj se ostvaruje = 1
- sve ostalo = 0 (cenzurirani podaci)
 - kraj istraživanja (*end of the study*)
 - gubitak iz praćenja (*lost to follow-up*)
 - ostali događaji

Cenzuriranje: bolesnici s postavljenom dijagnozom (P) u zadanih pet godina




1. siječnja 00. vrijeme istraživanja 31. prosinca 04.

Cenzuriranje: bolesnici liječeni u zadanom petogodišnjem razdoblju



1. siječnja 00. vrijeme istraživanja 31. prosinca 04.

Cenzuriranje: bolesnici liječeni u zadanom petogodišnjem razdoblju



Cenzuriranje

- desno (right censoring)
 - nije lijevo
 - nije intervalno
- neinformativno (non informative)
 - nije "informativno"
 - vrijeme preživljenja neke jedinke neovisno je od svakog mogućeg mehanizma koji može uzrokovati da ista jedinka bude cenzurirana
 - npr. cenzuriranje bolesnika s pogoršanjem zdravstvenog stanja

A sada – veselje!

$$R(t) = P\{T > t\} = \int_t^{\infty} f(u) du = 1 - F(t).$$

- funkcija preživljenja
 - biomedicina
 - survival function
- funkcija pouzdanosti
 - inženjerstvo
 - reliability function

S(t) ili R(t):

- vjerojatnost da će jedinka preživjeti ili točno doživjeti vrijeme od t jedinica praćenja, ili
- vjerojatnost preživljenja jedinke u rasponu od početka praćenja do trenutka praćenja t

A sada – još veće veselje!

$$h(t) = \lim_{\Delta t \rightarrow 0} \frac{R(t) - R(t + \Delta t)}{\Delta t \cdot R(t)}, \quad F(t) = \int_0^t f(x) dx$$

- funkcija rizika
 - hazard function
- kumulativna funkcija rizika umiranja
 - $H(t) = -\log S(t)$

h(t):

- vjerojatnost da će jedinka umrijeti u trenutku t , uz uvjet da je preživjela do toga trenutka, i uz uvjet da je
- $F(t)$ funkcija gustoće

Zaključak: podaci o preživljenju

- vjerojatnost preživljenja
 - $S(t)$
- rizik umiranja
 - $H(t) = -\log S(t)$

Izračunavanje preživljenja

- neparametrijski postupci
 - Cutler-Edererov postupak (tablice preživljenja)
 - Kaplan-Meireov postupak
- parametrijski

I. Tablice preživljenja

- osiguravateljske tablice
- tablice smrtnosti

vrijeme praćenja	vjerojatnost smrti $q=d/(n-w/2)$	vjerojatnost preživljenja $p=1-q$	kumulativna vjerojatnost preživljenja $S(t)=\prod p$
0-12 mj.	0,11	0,89	0,89
13-24 mj.	0,27	0,73	0,65
25-36 mj.	0	1	0,65
37-48 mj.	0,4	0,6	0,39
49-60 mj.	0	1	0,39

Kako do preživljenja?

- upis podataka
- preuređenje podataka
- izračun podataka

1. Upis podataka, Excel®

Uključivanje celija

Formula: $= (C2-B2)/365*12$

	B	C	D	E
1	pacijent	datumop	datumkraj	cenzus
2	23456	23.6.2000	15.4.2007	0
3	24485	15.10.2003	8.11.2005	0
4	23080	25.7.2000	29.8.2004	0
5	23511	28.12.2001	15.2.2007	0
6	24188	20.2.2002	29.10.2004	0
7	22701	17.12.2003	8.6.2005	1
8	24241	17.7.2002	29.4.2007	0
9	23480	15.5.2003	20.8.2007	0
10	22823	5.10.2000	26.9.2002	1

2. Preuređenje podataka

	A	B	C	D	E
1	pacijent	datumop	datumkraj	cenzus	mjeseci
2	24485	15.10.2003	8.11.2005	0	24,8
3	23080	25.7.2000	29.8.2004	0	49,2
4	24188	20.2.2002	29.10.2004	0	32,3
5	22701	17.12.2003	8.6.2005	1	17,7
6	23898	27.4.2000	2.2.2004	1	45,2
7	24544	9.1.2002	29.9.2003	1	20,6
8	23869	10.10.2000	16.11.2003	0	37,2
9	22819	1.3.2001	6.2.2002	1	11,2
10	22921	26.4.2004	7.12.2004	0	7,4
11	23309	9.7.2004	18.7.2006	0	24,3

vrijeme praćenja	živi na početku intervala n	smrtni ishod u intervalu d	cenzurirani u intervalu w
0-12 mj.	10	1	1
13-24 mj.	8	2	1
25-36 mj.	5	0	2
37-48 mj.	3	1	1
49-60 mj.	1	0	1

3. Izračun podataka

vrijeme praćenja	vjerojatnost smrti $q=d/(n-w/2)$	vjerojatnost preživljenja $p=1-q$	kumulativna vjerojatnost preživljenja $S(t)=\prod p$
0-12 mj.	0,11	0,89	0,89
13-24 mj.	0,27	0,73	0,65
25-36 mj.	0	1	0,65
37-48 mj.	0,4	0,6	0,39
49-60 mj.	0	1	0,39

vrijeme praćenja	živi na početku intervala n	smrtni ishod u intervalu d	cenzurirani u intervalu w
0-12 mj.	10	1	1
13-24 mj.	8	2	1
25-36 mj.	5	0	2
37-48 mj.	3	1	1
49-60 mj.	1	0	1


3. Izračun podataka

vrijeme praćenja	vjerojatnost smrti $q=d/(n-w/2)$	vjerojatnost preživljenja $p=1-q$	kumulativna vjerojatnost preživljenja $S(t)=\prod p$
0-12 mj.	0,11	0,89	0,89
13-24 mj.	0,27	0,73	0,65
25-36 mj.	0	1	0,65
37-48 mj.	0,4	0,6	0,39
49-60 mj.	0	1	0,39

$$q = \frac{d + \frac{1}{2} w q}{n}$$

d – smrtni ishod u intervalu
n – živi na početku intervala
w – izgubljeni u intervalu


3. Izračun podataka




II. Kaplan-Meierov postupak

- nema zadane intervale praćenja
- vjerojatnost preživljenja se izračunava za svakog bolesnika koji umre
- cenzurirani ispitanici nisu dio izračunavanja vjerojatnosti
- dugotrajno izračunavanje kod velikih skupina ispitanika

KM podaci o preživljenju



KM krivulja preživljenja



Kaplan, Meier


- među 5 najcitiranijih radova u znanosti od trenutka objavljivanja (M. Zhou, Kentucky University; <http://www.ms.uky.edu/~mai/>)
- prikaz krivulje u zavisnosti od N
<http://www.ms.uky.edu/~mai/java/stat/KapMei.html>

Rizik umiranja

- $H(t) = -\log S(t)$
- snaga mortaliteta (epidemiologija)
- ...

Programska potpora

Primjer...




Preživljenje, MedCalc®

Survival time	mjeseci	
Endpoint	cenzus	
Sample size		43
Median survival		-


Survival time	Survival Proportion	Standard Error		
7,3973	-	-	44,3176	-
10,3562	0,976	0,024	45,2384	0,692
11,2438	0,952	0,033	46,3233	0,077
11,6384	0,929	0,040	49,1836	-
12	0,905	0,045	49,4466	-
17,7205	0,881	0,050	51,2219	-
17,8849	0,857	0,054	56,3507	-
20,6466	0,833	0,058	56,9096	-
22,1918	0,810	0,061	57,3041	-
23,7041	0,786	0,063	57,4356	-
24,2959	-	-	58,0274	-
24,8219	-	-	58,126	-
27,1663	0,760	0,066	58,9479	-
			61,6438	-
			65,6219	-
			69,074	-
			73,2164	-
			81,7644	-
			88,0438	-

npr., prosječno petogodišnje preživljenje: 69,2±7,7%

Krivulja preživljenja, MedCalc®



Granice pouzdanosti




Izračun granica pouzdanosti


- granice pouzdanosti (*Confidence Intervals*)
- CI = $x \pm z \text{ SE}(x)$
 - 95%CI = $x \pm 1,96 \text{ SE}(x)$
 - 99%CI = $x \pm 2,56 \text{ SE}(x)$

$$P(Z \leq z) = \int_{-\infty}^z \frac{1}{\sqrt{2\pi}} e^{-\frac{u^2}{2}} du$$

<http://www.fourmilab.ch/rpkp/experiments/analysis/zCalc.html> (pazi: p/2!)



Results from life table analysis are usually presented in a survival curve rather than in tables. The solid line in Fig 11-3 is a survival curve for the kidney transplant data. The dashed lines on either side of the survival curve represent 95% **confidence bands** for the curve. Although confidence bands are often not presented in journal articles, they should be included because they help readers interpret the amount of variability in the results. Typically, as the time interval from entry into the study becomes longer, the number of patients who have been in the study that long becomes increasingly smaller. The confidence




Vjerojatnost preživljaja (%)

Vrijeme praćenja (mj.)


Number at risk

Vrijeme praćenja (mj.)	0	12	24	36	48	60	72	84	96	108
Number at risk	43	38	33	24	16	6	3	1	1	1




Life Table													
Survival Variable MJESECI													
Intvrl	Number Entering	Number At Risk	Number Censored	Number Exposed to Terminal Event	Propn Terminating	Propn Surviving at End	Cumulative Survival Probability	Proba- bility Density	Hazard Rate	Intvrl Start Time	SE of Dur- viving	SE of Cumulative Survival Probability	SE of Hazard Rate
0	43,0	43,0	0	43,0	0,0000	1,0000	1,0000	0,0000	0,0000	0	0,0000	0,0000	0,0000
6,0	43,0	1,0	42,5	3,0	0,0700	0,9300	0,9300	0,0000	0,0000	6	0,0000	0,0000	0,0000
12,0	39,0	0	39,0	3,0	0,0769	0,8531	0,8531	0,0000	0,0000	12	0,0000	0,0000	0,0000
18,0	36,0	0	36,0	3,0	0,0833	0,7700	0,7700	0,0000	0,0000	18	0,0000	0,0000	0,0000
24,0	33,0	2,0	32,0	0	0,0000	0,7700	0,7700	0,0000	0,0000	24	0,0000	0,0000	0,0000
30,0	31,0	5,0	28,5	0	0,0700	0,7000	0,7000	0,0000	0,0000	30	0,0000	0,0000	0,0000
36,0	28,0	5,0	23,5	0	0,0000	0,7000	0,7000	0,0000	0,0000	36	0,0000	0,0000	0,0000
42,0	19,0	2,0	18,0	0	0,0526	0,6474	0,6474	0,0000	0,0000	42	0,0000	0,0000	0,0000
48,0	16,0	3,0	14,5	0	0,0000	0,6474	0,6474	0,0000	0,0000	48	0,0000	0,0000	0,0000
54,0	13,0	7,0	9,5	0	0,0000	0,6474	0,6474	0,0000	0,0000	54	0,0000	0,0000	0,0000
60,0	6,0	2,0	5,0	0	0,0000	0,6474	0,6474	0,0000	0,0000	60	0,0000	0,0000	0,0000
66,0	4,0	1,0	3,5	0	0,0000	0,6474	0,6474	0,0000	0,0000	66	0,0000	0,0000	0,0000
72,0	3,0	1,0	2,5	0	0,0000	0,6474	0,6474	0,0000	0,0000	72	0,0000	0,0000	0,0000
78,0	2,0	1,0	1,5	0	0,0000	0,6474	0,6474	0,0000	0,0000	78	0,0000	0,0000	0,0000
84,0	1,0	1,0	0,5	0	0,0000	0,6474	0,6474	0,0000	0,0000	84	0,0000	0,0000	0,0000

The median survival time for these data is:



Kaplan-Meier, Statistica®



“Preživljenje”


- generalno: **preživljenje**
 - survival
 - pračenje
 - ◆ početak
 - ◆ smrt od osnovne bolesi
- posebno: **preživljenje bez znaka bolesi**
 - disease-free survival (DFS)
 - pračenje
 - ◆ početak
 - ◆ relaps bolesi ili smrt od osnovne bolesi

DFS, primjer

Survival curves for 277 patients with T₂ tongue carcinoma treated with an ¹⁹²Ir, ¹³⁷Cs or ²²⁶Ra needle;

thin – regional disease-free survival
thick – distant metastasis-free survival

<http://www.royal-society.com/content/1/1/21/figure/F5>



Usporedba podataka o preživljenju

- usporedba dvije skupine podataka
 - log-rank (logrank) test
 - ◆ Mentelov ili Mentel-Coxov test
 - Wilcoxonov test
 - ◆ generalizirani Wilcoxonov test
 - ◆ Gehanov test
 - ◆ Gehan-Breslowljev test
 - ◆ opći Kruskal-Wallisov test za cenzurirane podatke
 - Mantel-Haenszelov test
 - Tarone-Wareov test
- usporedba triju i više skupina

Usporediti dvije skupine...


ceiving a kidney in 1984 is above the curve for patients receiving a kidney in 1978, indicating a higher proportion of patients retaining a functioning graft at any one point in time. However, variation in samples may be expected to occur simply by chance, and a reasonable question is whether the differences between the two patient cohorts is greater than expected by chance. To test this hypothesis, we need methods to compare survival distributions. If there are no censored observations, the **Wilcoxon rank-sum test** in-

Primjer


• N = 43

Codes X	cenzus	
0	31	(72.1%)
1	12	(27.8%)
Chi-square		7.535
DF		1
Significance level		P = 0.0061


Variable	mjeseci
Select	(cenzus = 1) or (cenzus = 0)
Sample size	43
Lowest value	7.3973
Highest value	88.0438
Arithmetic mean	40.9563
95% CI for the mean	34.8091 to 47.1074



Dvije skupine, MedCalc®




Dvije skupine, SPSS®




Omjer izgleda

odds ratio, hazard ratio



Usporedba triju skupina




Zaključivanje

- granice pouzdanosti
- p-vrijednosti

Regresijska analiza podataka

- korelacija
- pravocrtna regresija
- višestruka regresija
- logistička regresija
- Coxova regresija
- Passing-Bablokova regresija



Linearni sustavi i kaos

Coxov regresijski test

- multivarijatan postupak
- *Cox regression*
 - Cox, 1972.
 - *proportional hazard model*

10.5.3 Importance of the Cox Model

The Cox model is very useful in medicine, and it is easy to see why it is being used with increasing frequency. It provides the only valid method of predicting a time-dependent outcome, and many health-related outcomes are related to time. If the independent variables are divided into two categories (dichotomized), the exponential of the regression coefficient, $\exp(b)$, is the odds ratio, a useful way to interpret the risk associated with any specific factor. In addition, the Cox model provides a method for producing survival curves that are adjusted for confounding variables. The Cox model can be extended to the case of multiple events for a subject, but that

Podaci

- zavisni pokazatelji
 - vrijeme praćenja
 - podatak o ishodu (cenzuriranje)
- nezavisni pokazatelji
 - prediktori ili kovarijate (*covariates*)
 - sve mjerene ljestvice dopuštene
- rezultat
 - regresijski koeficijenti
 - ⇒ omjer rizika (*hazard ratio (HR)*, *ratio of the hazard function*)
 - ⇒ mjera rizika (relativni rizik; *relative risk (RR)*)

$$h_i(t) = h_0(t) \exp(\beta_1 x_{i1} + \beta_2 x_{ik} + \dots + \beta_k x_{ik})$$

Primjer, MedCalc® Coxov regresijski test

- analiza preživljenja (smrt od osnovne bolesti)
- podaci – cenzurirani
- nezavisni pokazatelji
 - spol (M, Ž)
 - zahvaćena strana lica (L, D, M)
 - T-klasifikacija
 - resekcija donje čeljusti (1-5 kao nije, segmentalna, marginalna...)
 - liječenje zračenjem (da, ne)
 - najveći promjer tumora (cm)

Primjer, MedCalc® “svi pokazatelji”

Cox proportional hazards regression		
Survival time Endpoint	mjeseci	
Method	Enter	
Sample size		43
Overall Model Fit		
Null model -2 Log Likelihood		84,67522
Full model -2 Log Likelihood		73,62894
Chi-square		11,0463
DF		6
Significance level		P = 0,0870
Coefficients and Standard Errors		
Covariate	B	SE P Exp(B) 95% CI of Exp(B)
spol	0,6557	1,2109 0,5881 1,9266 0,1817 to 20,4295
strana	1,1296	0,5442 0,0379 3,0845 1,0708 to 8,9427
T	-0,1311	0,5540 0,7948 0,8771 0,3283 to 2,3438
respond	-0,2161	0,3444 0,5265 0,8040 0,4109 to 1,5738
radioth	1,6251	0,6270 0,0494 5,0789 1,0126 to 25,4756
Tmaxiprom	0,0919	0,3077 0,7652 1,0962 0,6016 to 1,8974

$$RR = \text{Exp}(b) \text{ ili } \text{Exp}(\beta) = e^b = 2,72^b$$

Primjer, MedCalc® “postupno biranje, unaprijed”

Cox proportional-hazards regression

Survival time

mjeseci

Endpoint

cenzus

Method

Enter

Sample size

43

Overall Model Fit

Null model -2 Log Likelihood

84,67522

Full model -2 Log Likelihood

73,62894

Chi-square

11,0463

DF

6

Significance level

P = 0,0870

Coefficients and Standard Errors

Covariate	b	SE	P	Exp(b)	95% CI of Exp(b)
spol	0,6557	1,2109	0,5881	1,9266	0,1817 to 20,4295
strana	1,1296	0,5442	0,0379	3,0845	1,0708 to 8,9427
T	-0,1311	0,5540	0,7948	0,8771	0,3283 to 2,3438
respond	-0,2161	0,3444	0,5265	0,8040	0,4109 to 1,5738
radioth	1,6251	0,6270	0,0494	5,0789	1,0126 to 25,4756
Tmaxiprom	0,0919	0,3077	0,7652	1,0962	0,6016 to 1,8974

Cox proportional-hazards regression

Survival time

mjeseci

Endpoint

cenzus

Method

Forward

Enter variable if P >

0,05

Remove variable if P >

0,1

Sample size

43

Overall Model Fit

Null model -2 Log Likelihood

84,67522

Full model -2 Log Likelihood

73,62894

Chi-square

11,0463

DF

6


Significance level

P = 0,0192

Coefficients and Standard Errors

Covariate	b	SE	P	Exp(b)	95% CI of Exp(b)
spol	1,1744	0,5445	0,0159	3,2361	1,2103 to 8,6541

Primjer, MedCalc® “postupno biranje, unaprijed”



Univariate hazards regression				
		miopact1		
		census		
		Forward		
Step if P >		0,05		
Model if P >		0,1		
				43
Overall Model Fit				
Null model -2 Log Likelihood				84,67522
Full model -2 Log Likelihood				78,19430
Chi square				5,4809
DF				1
Significance level				P = 0,0192
Coefficients and Standard Errors				
Covariate	b	SE	P	Exp(b) 95% CI of Exp(b)
slane	1,1744	0,5045	0,0199	3,2391 1,2100 to 8,6543

mp@kbd.hr