

3. Procjena distribucije vremena života

3.1 Uvod

Želimo procijeniti $F(t)$ od T
→ *neparametarska procjena!*

“Najjednostavnija metoda”: opaža se vrlo velik broj novorođenih osoba do njihove smrti.

Problemi s “najjednostavnijom” metodom:

1. ako i nađemo dovoljno velik uzorak, trebali bi ga opažati barem 100 godina
2. osobe mogu napustiti opažanje i prije eventualne smrti (zbog raznih razloga)

→ *cenzurirani podaci*

3.2 Mehanizmi cenzuriranja

Vrste cenzuriranja:

1. desno cenzuriranje
2. lijevo cenzuriranje
3. intervalno cenzuriranje
4. slučajno cenzuriranje
5. neinformativno cenzuriranje
6. cenzuriranje tipa I
7. cenzuriranje tipa II

3.3 Kaplan - Meierov procjenitelj

3.3.2 Kaplan-Meierova procjena

$$\hat{F}(t) = 1 - \prod_{t_j \leq t} (1 - \hat{\lambda}_j)$$

gdje je $\hat{\lambda}_j = d_j/n_j$, $j = 1, \dots, k$

Ovdje su;

t_j ... vrijeme smrti

d_j ... broj umrlih u vremenu t_j

n_j ... broj živih i pod rizikom od smrti neposredno prije t_j (tj. do t_j-)

3.4 Usporedba razdioba vremena života

Greenwoodova formula:

$$\text{Var}[\hat{F}(t)] \approx (1 - \hat{F}(t))^2 \sum_{t_j \leq t} \frac{d_j}{n_j(n_j - d_j)}$$

3.3 Nelson - Aalenov procjenitelj

Procjena integriranog hazarda:

$$\Lambda_t = \int_0^t \mu_s ds + \sum_{t_j \leq t} \lambda_j$$

3.3.2 Nelson - Aalenova procjena

$$\hat{\Lambda}_t = \sum_{t_j \leq t} \frac{d_j}{n_j}$$

$$\text{Var}[\hat{\Lambda}_t] \approx \sum_{t_j \leq t} \frac{n_j - d_j}{n_j^3}$$

Primjer. U tablici se nalaze podaci o 12-torici pacijenata koji su bili podvrgnuti nekoj operaciji.

pacijent	vrijeme op. (tjedni)	opažanje prestalo (u tjednu)	raz. za prestanak
1	0	120	cenzurirano
2	0	68	smrt
3	0	40	smrt
4	4	120	cenzurirano
5	5	35	cenzurirano
6	10	40	smrt
7	20	120	cenzurirano
8	44	115	smrt
9	50	90	smrt
10	63	98	smrt
11	70	120	smrt
12	80	110	smrt

Pretpostavljamo: cenzuriranje je neinformativno.

- (i) Procijenite funkciju doživljenja pomoću Kaplan - Meierove metode i odredite 95% p.i. za njene vrijednosti.
- (ii) Procijenite integrirani hazard Nelson - Aalen-ovom procjenom i pomoću njega procijenite funkciju doživljenja.
- (iii) Procijenite vjerojatnost da će pacijent doživjeti 70-ti tjedan nakon operacije.

Rješenje:

(i): Razdoblje opažanja počinje u trenutku $t = 0$ odmah nakon operacije. Opažena relativna vremena su redom (u tjednima, '+' označava cenzuriranje):

120+, 68, 40, 116+, 30+, 30, 100+, 71, 40, 35, 50, 30

Statistike:

t_j	n_j	d_j	$\hat{\lambda}_j = \frac{d_j}{n_j}$	$1 - \hat{\lambda}_j$	$\Pi(1 - \hat{\lambda}_j)$
30	12	2	1/6	5/6	0.8333
35	9	1	1/9	8/9	0.7407
40	8	2	1/4	3/4	0.5556
50	6	1	1/6	5/6	0.4630
68	5	1	1/5	4/5	0.3703
71	4	1	1/4	3/4	0.2778

Kaplan-Meierova procjena $\hat{S}(t)$ za $S(t)$:

$t_{j-1} \leq t < t_j$	$\hat{S}(t) = \prod_{t_j \leq t} (1 - \hat{\lambda}_j)$	$\pm 2 \cdot \text{s.e.}(\hat{S}(t))$
$0 \leq t < 30$	1	± 0
$30 \leq t < 35$	0.8333	± 0.2154
$35 \leq t < 40$	0.7407	± 0.2592
$40 \leq t < 50$	0.5556	± 0.2987
$50 \leq t < 68$	0.4630	± 0.3010
$68 \leq t < 71$	0.3703	± 0.2922
$71 \leq t$	0.2778	± 0.2717

gdje je:

$$\text{s.e.}(\hat{S}(t)) = \hat{S}(t) \sqrt{\sum_{t_j \leq t} \frac{d_j}{n_j(n_j - d_j)}}$$

(ii): Nelson - Aalenova procjena $\tilde{S}(t)$ za $S(t)$:

$t_{j-1} \leq t < t_j$	$\hat{\Lambda}(t) = \sum_{t_j \leq t} \hat{\lambda}_j$	$\tilde{S}(t) = e^{-\hat{\Lambda}(t)}$
$0 \leq t < 30$	0	1
$30 \leq t < 35$	0.1667	0.8465
$35 \leq t < 40$	0.2778	0.7575
$40 \leq t < 50$	0.5278	0.5899
$50 \leq t < 68$	0.6944	0.4994
$68 \leq t < 71$	0.8944	0.4088
$71 \leq t$	1.1444	0.3184

(iii): $\hat{S}(70) = 0.3703$

4. Coxov regresijski model

4.1 Ovisnost o varijablama (kovarijatama)

4.2 Potpuno parametarsko modeliranje

Pretpostavka: distribucija vremena života pripada nekoj parametarskoj porodici (npr. eksponencijalna, Weibullova, Gompertz-Makehamova,...)

→ populacije se uspoređuju usporedbom parametara

→ može se primijeniti ako postoji apriorno znanje o pripadnosti određenoj param. porodici

4.3 Coxov poluparametarski model:

$$\lambda(t; z) = \lambda_0(t) \exp(\beta z^T)$$

gdje su:

- $\lambda_0(t)$... osnovni hazard
- β ... $1 \times p$ -vektor regresijskih parametara
- z ... $1 \times p$ -vektor p -dim, kovarijate

Osnovna pretpostavka Coxovog modela:

Omjeri hazarda različitih osoba s vrijednostima kovarijata z_1, z_2 ne ovise o t , tj.

$$\frac{\lambda(t; z_1)}{\lambda(t; z_2)} = \exp(\beta(z_1^T - z_2^T))$$

→ model *proporcionalnih* hazarda

Upotreba Coxovog modela:

– ako nas primarno zanima istraživanje *efekta* od z na $\lambda(t; z)$, a ne sama funkcija doživljenja (tj. λ)

→ poluparametarski pristup

4.4 Parcijalna vjerodostojnost

Pretpostavka: $d_j = 1$ za svaki j

$$L(\beta) = \prod_{j=1}^k \frac{\exp(\beta z_j^\tau)}{\sum_{i \notin R(t_j)} \exp(\beta z_i^\tau)}$$

gdje je $R(t_j)$ skup svih osoba i živih i pod rizikom do t_j —

→ procjena od β (numeričkom) maksimizacijom $L(\beta)$

U praksi se može dogoditi:

(a) $d_j > 0$

(b) postoje cenzurirana opažanja u nekom od t_j

Ad (a): Breslowova aproksimacija:

$$L(\beta) = \prod_{j=1}^k \frac{\exp(\beta s_j^\tau)}{\left(\sum_{i \notin R(t_j)} \exp(\beta z_i^\tau) \right)^{d_j}}$$

gdje je s_j zbroj svih z vrijednosti osoba umlih u t_j

Ad (b): Osobe cenzurirane u t_j su uključene u skup $R(t_j)$.

Primjer. U tablici se nalaze podaci malog uzorka zaposlenih u jednoj tvornici koji predstavljaju vremena u mjesecima do prvog izostajanja s posla. Sa " + " su označena vremena napuštanja posla koja se ne smatraju izostajanjem.

M:	6+	11	13+	15	16+	19+	20	
F:	2+	4	7	8+	10+	12+	17	21+

Stopa hazarda se modelira po Coxovom modelu:

$$\lambda(t) = \lambda_0(t)e^{\beta x}$$

gdje su:

$x = 0$ za muškarce (M) i

$x = 1$ za žene (F).

- (i) Odredite parcijalnu vjerodostojnost od β i MLE.
- (ii) Procijenite asimptotski 95% p.i. za β .
- (iii) Testirajte hipotezu da žene imaju veću stopu izostanka s posla od muškaraca.

(i): t_j : $4F, 7F, 11M, 15M, 17F, 20M$

Parcijalna vjerodostojnst:

$$\begin{aligned}
 L(\beta) &= \\
 &= \prod_j \frac{e^{\beta x_j}}{\sum_{i \in R(t_j)} e^{\beta x_i}} = \\
 &= \frac{e^{\beta(1+1+0+0+1+0)}}{(7e^{\beta \cdot 1} + 7)(6e^{\beta \cdot 1} + 6)(3e^{\beta \cdot 1} + 6)(2e^{\beta \cdot 1} + 4)(2e^{\beta \cdot 1} + 2)(e^{\beta \cdot 1} + 1)} \\
 &= \frac{e^{3\beta}}{7 \cdot 6 \cdot 3 \cdot 2^2 (e^{\beta} + 1)^4 (e^{\beta} + 2)^2}
 \end{aligned}$$

Parcijalna log-vjerodostojnost:

$$\ell(\beta) = \log L(\beta) = 3\beta - 4\log(e^\beta + 1) - 2\log(e^\beta + 2) + \text{const.}$$

$$\begin{aligned}\ell'(\beta) &= 3 - \frac{4e^\beta}{1+e^\beta} - \frac{2e^\beta}{2+e^\beta} = 0 \\ \Leftrightarrow 3e^{2\beta} + e^\beta - 6 &= 0 \\ \Leftrightarrow e^\beta &= \frac{\sqrt{73}-1}{6} = 1.2573 \\ \Rightarrow \hat{\beta} &= 0.2290 \quad (\text{MLE})\end{aligned}$$

(ii):

$$\ell''(\beta) = -\frac{4e^\beta}{(1+e^\beta)^2} - \frac{4e^\beta}{(2+e^\beta)^2} \Rightarrow \ell''(\hat{\beta}) = -1.4610$$

Asimptotska razdioba od MLE:

$$\hat{\beta} - \beta \rightsquigarrow N\left(0, -\frac{1}{\ell''(\hat{\beta})}\right) \equiv N(0, 0.8273^2)$$

95% p.i. za β :

$$\hat{\beta} \pm 2 \cdot 0.8273 = 0.2290 \pm 1.6546$$

(iii): Treba testirati hipoteze:

$$H_0 : \beta = 0 \text{ vs. } H_1 : \beta > 0$$

Testna statistika:

$$Z = \frac{\hat{\beta} - 0}{\sqrt{-\ell''(0)^{-1}}} \stackrel{H_0}{\rightsquigarrow} N(0, 1)$$


Kritično područje uz $\alpha = 5\%$: $[1.64, +\infty)$

$$z = \frac{0.2290}{0.8321} = 0.2752 \notin [1.64, +\infty)$$

Žene nemaju značajno veću stopu izostanka s posla od muškaraca.

5. Markovljev proces s dva stanja

5.1 Pretpostavke



${}_t p_x :=$ (uvjetna) vjerojatnost da osoba (proces) ostane u stanju a u dobi $x + t$ ako je bila u tom stanju u dobi x

${}_t q_x :=$ (uvjetna) vjerojatnost da osoba (proces) bude u stanje d u dobi $x + t$ ako je bila u stanju a u dobi x

Pretpostavka 1.

Vjerojatnost da će se osoba dobi x naći u određenom stanju u dobi $x + t$ ovisi samo o dobi x i stanju u kojem se u toj dobi nalazi.

Pretpostavka 2.

$$h q_{x+t} = \mu_{x+t} \cdot h + o(h), \quad h \rightarrow 0+, \quad \text{za } t \geq 0.$$

→ u cilju procjene modela, restrikcija na dobni interval $[x, x + 1]$

Pretpostavka 3.

$$t \mapsto \mu_{x+t} = \mu = \text{konst. za } 0 \leq t < 1.$$

Sve ostalo (npr. stanje zdravlja, zanimanje,...) nije uključeno u model.

Znajući te faktore, možemo:

(a) *stratificirati* problem, tj. za svaku kombinaciju razina faktora postaviti model

(b) postaviti adekvatan *regresijski model* s tim faktorima kao kovarijatama

5.2 Vjerojatnosti prijelaza

$${}_{t+h}p_x = \cdots = {}_tp_x(1 - \mu_{x+t}h) + o(h), \quad h \rightarrow 0+$$

\Rightarrow

$${}_tp_x = \exp\left(-\int_0^t \mu_{x+s} ds\right)$$

5.3 Statistike


Opažamo N osoba u dobi od x do $x + 1$
(pretp. da je $\mu_x \equiv \mu$ konst.)

→ niz nezavisnih i jednako distribuiranih jedinki

→ cenzuriranje tipa I

$x + a_i$... dob osobe i na početku razdoblja opažanja
ili ulaska u grupu

$x + b_i$... dob osobe i na kraju razdoblja opažanja
ako doživi tu dob



SLIKA 2

Slučajne varijable (statistike):

D_i ... indikator smrti ($D_i = 1$ ako je opažena smrt osobe i , inače $D_i = 0$)

$x + T_i$... dob osobe i u trenutku prestanka opažanja te osobe

$V_i := T_i - a_i$... ukupno vrijeme opažanja osobe i

→ dovoljna statistika za osobu i : (D_i, V_i)

Opažena vrijednost od (D_i, V_i) : (d_i, v_i)

Vjerodostojnost od μ :

$$L(\mu) = \prod_{i=1}^N e^{-v_i \mu} \mu^{d_i} = e^{-\mu \sum_{i=1}^N v_i} \cdot \mu^{\sum_{i=1}^N d_i} = e^{-\mu v} \mu^d$$

gdje su $v = \sum_{i=1}^N v_i$ i $d = \sum_{i=1}^N d_i$
opažene vrijednosti statistika:

$D = \sum_{i=1}^N D_i \dots$ ukupan broj umrlih u uzorku u dobi
od x do $x + 1$

$V = \sum_{i=1}^N V_i \dots$ ukupno vrijeme boravka opažanih
osoba iz uzorka u dobnom intervalu $[x, x + 1]$

5.4 Procjena maksimalne vjerodostojnosti

Log-vjerodostojnost:

$$\ell(\mu) = \log L(\mu) = -\mu v + d \log \mu$$

$$\ell'(\mu) = -v + \frac{d}{\mu} = 0 \quad \Leftrightarrow \quad \hat{\mu} = \frac{d}{v}$$

Procjenitelj MLE:

$$\tilde{\mu} = \frac{D}{V}$$

Asimptotska razdioba MLE:

$$\ell''(\mu) = -\frac{d}{\mu^2} \Rightarrow -\frac{1}{\ell''(\hat{\mu})} = \frac{\hat{\mu}}{v}$$

$$\tilde{\mu} - \mu \dot{\sim} N\left(0, -\frac{1}{\ell''(\tilde{\mu})}\right) \equiv N\left(0, \frac{\tilde{\mu}}{V}\right)$$

standardna pogreška: $\text{s.e.}(\tilde{\mu}) = \sqrt{\frac{\tilde{\mu}}{V}}$

95% p.i. za μ : $\tilde{\mu} \pm 2 \cdot \sqrt{\frac{\tilde{\mu}}{V}}$