

# Vybrané kapitoly z analýzy prežívania

## Testovanie hypotéz

Stanislav Katina<sup>1</sup>

<sup>1</sup>Ústav matematiky a statistiky  
Přírodovědecká fakulta  
Masarykova univerzita v Brně

ZS 2013



INVESTICE DO ROZVOJE VZDĚLÁVÁNÍ

Stanislav Katina

Vybrané kapitoly z analýzy prežívania

## Pod'akovanie

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

#### *Delenie testov na porovnanie kriviek prežívania*

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

Stanislav Katina

Vybrané kapitoly z analýzy prežívania

## Testy na porovnanie kriviek prežívania

### Prehľad testov

#### *Neparametrické testy porovnania kriviek prežívania pre necenzurované dáta*

- 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

## Neparametrické testy porovnania kriviek prežívania pre cenzurované dáta

- 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)

## Testované hypotézy

- nulová hypotéza  $H_0 : S_1(t) = S_2(t) = S(t)$
- alternatíva hypotéza  $H_1 :$ 
  - $S_1(t) \neq S_2(t)$
  - $S_1(t) \stackrel{st}{<} S_2(t)$
  - $S_1(t) \stackrel{st}{>} S_2(t)$

pre  $\forall t$

$S(t)$  je funkcia prežívania

$\stackrel{st}{<}$  a  $\stackrel{st}{>}$  stochasticky menší, resp. stochasticky väčší

## 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 posunutú o nejakú konštantu  $\delta$
- veličiny  $X_1, \dots, X_{n_1}$  a  $Y_1 - \delta, \dots, Y_{n_2} - \delta$  majú rovnaké rozdelenie
- oba výbery sú nezávislé

## Hypotézy

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

## 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 usporiadaného združeného NV

## Wilcoxonova štatistika

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

## 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

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

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 posunutú o nejakú konštantu  $\delta$
- 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*

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

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

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  $n_1, n_2 \geq 10$

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

$U_X$  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  $X_i > Y_j$

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




## 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)
```

## Testy na porovnanie dvoch kriviek prežívania

### Mann-Whitney vs Wilcoxonov test



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

## 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

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

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

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

Levene test

Podstata Leveneho alternatívny 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  $S_{ST}^{alt}$ :

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

$$Var_0 [S_{ST}] = Var_0 [S_{ST}^{alt}] = \frac{n_1 n_2 (n_1 + n_2 + 1)}{12}$$

**Levene test**

Ak  $n_1, n_2 \geq 10$

$$Z_L = Z_{SL}^{alt} = \frac{S_{ST}^{alt} - E_0 [S_{ST}^{alt}]}{\sqrt{Var_0^{alt} [S_{ST}]}} \sim N(0, 1)$$

# 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 pľúc 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
$\psi_{ij}$	0	1	1	0	0	1	1	0	0	1	0	0

# Testy na porovnanie dvoch kriviek prežívania

Príklad

$t_{ij}$	52	240	19	53	15	43	340	133	111	231	378	49
$\psi_{ij}$	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
$\psi_{ij}$	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**

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

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

$$Var_0 [S_W] = \frac{7 \times 5(7+5+1)}{12}$$

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

# Testy na porovnanie dvoch kriviek prežívania

Príklad

**Mann-Whitney test**

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

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

$$Var_0 [S_{MW}] = n_1 n_2 (n + 1) / 12 = 37.91667$$

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

**Siegel-Tukey test**

$t_{ij}$	52	240	19	53	15	43	340	133	111	231	378	49
$\psi_{ij}$	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	-	-

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

$$E_0 [S_{ST}] = \frac{5(7+5+1)}{2}, \quad Var_0 [S_W] = \frac{7 \times 5(7+5+1)}{12}$$

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

## Testy na porovnanie kriviek prežívania

Prehľad testov

### Testované hypotézy

- nulová 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)
  - $S_i(t) \stackrel{st}{<} S_j(t)$  (J,C,L testy)
  - $S_i(t) \stackrel{st}{>} S_j(t)$  (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

$\stackrel{st}{<}$  a  $\stackrel{st}{>}$  stochasticky menší, resp. stochasticky väčší

## 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

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

## Testy na porovnanie viacerých kriviek prežívania

Kruskall-Wallisov test

### Rozptyl $S_{KW}$ :

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

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

### Kruskall-Wallisov test

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

## 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

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



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*

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

*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*

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

*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 diskordantných dvojíc medzi  $(x_1, y_1), \dots, (x_n, y_n)$

*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

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

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



## Testy na porovnanie viacerých kriviek prežívania

Zovšeobecnený Kendallov korelačný koeficient

Poradovú alternatívu 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

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

## Testy na porovnanie viacerých kriviek 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  $\tau$  nazývame **zovšeobecnený Kendallov korelačný koeficient**

## Testy na porovnanie viacerých kriviek 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 krviniek (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  $\tau$ ,  $\tilde{\tau}$  a  $R_S$ . Otestujte nezávislosť medzi počtom bielych krviniek a časmi do zlyhania.

## Testy na porovnanie viacerých kriviek 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

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

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

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

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

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

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

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

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

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

## Testy na porovnanie viacerých kriviek 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

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

## Testy na porovnanie viacerých kriviek 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

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

## Testy na porovnanie viacerých kriviek 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 poradie veličín  $X_1, \dots, X_n$
- nech  $Q_1, \dots, Q_n$  sú poradie veličín  $Y_1, \dots, Y_n$

### Spearmanova štatistika

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

## Testy na porovnanie viacerých kriviek 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  $R_S = \frac{1}{\sqrt{(n-1)\text{Var}[S_N]}} (S_N - E [S_N])$ ,  $E [R_S] = 0$ ,

$$\text{Var} [R_S] = \frac{1}{n-1}$$

## Testy na porovnanie viacerých kriviek 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

## Testy na porovnanie viacerých kriviek 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,  $M_k = 0$
- $L_i - M_i \in \langle -n, n \rangle$
- $\bar{R}_i$  je priemerné poradie pre  $i$ -ty výber

### Le štatistika

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

## Testy na porovnanie viacerých kriviek 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

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

## Testy na porovnanie viacerých kriviek prežívania

Zovšeobecnenia

### Test odklonu 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

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

## Testy na porovnanie viacerých kriviek prežívania

Príklad

### Example (pokrač.)

Nech  $t_{ij}, i = 1, \dots, n_j, j = 1, 2$  sú časy do zlyhania (úmrtia) od diagnostiky nádoru pľúc 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
$\psi_{ij}$	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 kriviek prežívania

Príklad

### Example (pokrač.)

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 krviniek (white blood cells counts, WBC) vzrastá 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)  $S_1(t) \stackrel{st}{>} S_2(t) \stackrel{st}{>} S_3(t)$ , c)  $S_1(t) \stackrel{st}{<} S_2(t) \stackrel{st}{<} S_3(t)$ .

Stanislav Katina

Vybrané kapitoly z analýzy prežívania

## Testy na porovnanie viacerých kriviek prežívania

Príklad

Rozdeľme AG-pozitívnych pacientov do troch skupín nasledovne

- Skupina 1:  $WBC \geq 100000, n_1 = 3, (1, 1, 65)$
- 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 kriviek 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

## Formulácie sčítacím procesom

- $(X_i, \delta_i)$  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  $N_i(t) = I(\{T_i \leq t, \delta(x) = 1\})$
- 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  $t$

## 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**

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

Potom asymptoticky

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

## Tarone a Ware (1977) trieda váh

- 1 konštantný rozdiel v **logitovej** škále  $f(p) = \ln \frac{p}{1-p}$ , potom váhy  $W(t) = 1$
- 2 konštantný rozdiel v **aritmetickej** škále:  $f(p) = p$ , potom váhy  $W(t) = \left( \frac{1/\bar{Y}(t)}{1-1/\bar{Y}(t)} \right)^{-1} = \bar{Y}^2(t)/(\bar{Y}(t) - 1) \approx \bar{Y}(t)$
- 3 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 zapísať ako  $W(t) = g(\bar{Y}(t)/n)$

**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)

*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**

$$\text{Var}_0[T(W, t)] = \sum_{j=0}^t W_j^2 \frac{n_{1j}}{n_j} \left( 1 - \frac{n_{1j}}{n_j} \right) \frac{d_j(n_j - d_j)}{n_j - 1}$$

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

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



## Testy na porovnanie dvoch kriviek prežívania

Zovšeobecnený Wilcoxon test

Za platnosti  $H_0$  platí

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

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

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 združenom výbere zlyhaní,  $l_j$  je počet cenzúr z intervalu ( $R_j, R_{j+1}$ )

## 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

$d_1 = \dots = d_L = 1, l_1 = \dots = l_{L-1} = 0, l_L = r_1 + r_2$ .

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

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

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

## 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)  $2 \times 2$**  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 šanci**
- **rozptyl**  $\text{Var}_0[S_W^{(c)}] = \frac{l d n_1 n_2}{n_1 + n_2 - 1}$

## Testy na porovnanie dvoch a viac kriviek prežívania

Kontingenčné tabuľky

$KT 2 \times 2$

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

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

$\chi^2$  **test nezávislosti** (alebo **homogenity**) pre  $KT 2 \times 2$

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

kde  $a$  je početnosť v prvej bunke KT



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

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

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

## Testy na porovnanie dvoch kriviek prežívania

Prehľad testov

Pre každé  $t_{(i)}$ ,  $1 \leq i \leq L$ , môžeme dáta zapísať do KT  $2 \times 2$

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  $d = \sum_{j:t_j \leq t_{(i)}} d_j$

## 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  $t$
- $\theta$  neznáma konštanta proporcionality rizík

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

## 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 minulosti 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

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

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

## 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  $t_{(i)}$  nám dá nasledovný vzťah

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

## Testy na porovnanie dvoch kriviek prežívania

Prehľad testov

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

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

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

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

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

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

## Testy na porovnanie dvoch kriviek prežívania

Príklad

### Example

Majme dáta 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

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

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

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

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

## Testy na porovnanie dvoch kriviek prežívania

Prehľad testov

Majme váhy  $w_i$  asociované s KT v čase  $t_i$ , potom

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

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

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

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

## 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  $w_i = \hat{S}_{pooled}(t_i) = \prod_{j:t_j \leq t_i} \frac{n_j - d_j + 1}{n_j + 1}$ ,  $Q = Q_P$ , ide o **Peto-Peto test** (Peto a Peto, 1972; Prentice, 1978).

Stanislav Katina

Vybrané kapitoly z analýzy prežívania

## Testy na porovnanie 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

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

$U$  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

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  $t_{(i)}$ ,  $1 \leq i \leq l$ , môžeme dáta zapísať 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 case $t_{(i)}$	$a_{1i}$	$a_{2i}$	...	$a_{ji}$	...	$a_{ki}$	$a_i$
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 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  $k - 1$**

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

stredné hodnoty v časoch  $t_{(i)}$

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

kovariancie v časoch  $t_{(i)}$

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

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

Stanislav Katina

Vybrané kapitoly z analýzy prežívania

## Testy na porovnanie viacerých kriviek 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

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

$$\mathbf{v} = \sum_{i=1}^l \mathbf{v}(t_{(i)})$$

Testovacia štatistika

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

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

Stanislav Katina

Vybrané kapitoly z analýzy prežívania

## Testy na porovnanie viacerých kriviek prežívania

Prehľad testov

V prípade pridania váh, bude platiť

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

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

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

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

Stanislav Katina

Vybrané kapitoly z analýzy prežívania

## Testy na porovnanie viacerých kriviek 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 kriviek prežívania

Test trendu

Test nulovej hypotézy oproti stochasticky usporiadanej alternatíve je *testom trendu*, kde testujeme zoradený vzťah medzi  $k$  funkciami 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 kriviek prežívania

Test trendu

Testovacia štatistika

$$Q_{trend} = \frac{[U_{trend}]^2}{\mathbf{w}_*^T \mathbf{V}_* \mathbf{w}_*} \sim \chi_1^2,$$

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  $k \times k$

# Testy na porovnanie viacerých kriviek prežívania

Test trendu

Testovaciu štatistiku  $Q_{trend}$  budeme potom písať 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

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

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

# Testy na porovnanie viacerých kriviek prežívania

Príklad

## Example

Majme experiment (Thomas et al, 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.). Zaujímá 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 cenzúra,  $n_0 = \#$  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+	117
1.5	10	43+	44+	45+	67	68+	136	136	150	150	150
0	9	73+	74+	75+	76	76	76+	99	166	246+	

# Testy na porovnanie viacerých kriviek 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

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

dávka	udalosť v $t_{(1)}$	bez udalosti 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	

$$\mathbf{V}(t_{(1)}) = \begin{bmatrix} \frac{8 \times (24-8) \times 1 \times (24-1)}{24^2(24-1)} = 0.222 & -\frac{8 \times 7 \times 1 \times 23}{24^2 \times 23} = -0.097 \\ -0.097 & \frac{7 \times (24-7) \times 1 \times 23}{24^2 \times 23} = 0.207 \end{bmatrix}$$

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

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

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

Ak  $\mathbf{w}^* = (0.0, 1.5, 2.0)^T$ , potom

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

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

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



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)
## odhady pre obe skupiny zvlast
# median, priemerny cas prezivania, rozsahy, pocty zlyhani
kmfit.aml <- survfit(Surv(cas,status)~skupina, data=aml)
print(kmfit.aml, show.rmean=TRUE)
## odhady v jednotlivych casoch
# fcia prezivania, 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)
```




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

Príklad 1 (pokrač.):

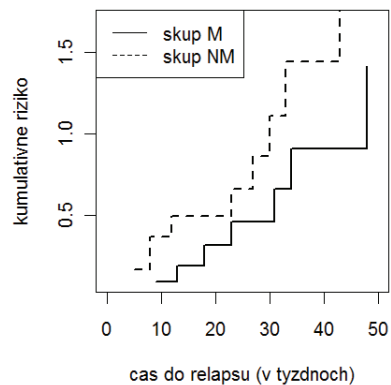
```
skup <- as.numeric(aml$skupina)
cas1 <- kmfit.aml.1$time; cas2 <- kmfit.aml.2$time;
CAS <- c(cas1,cas2)
## kumulativne riziko (KM a NA)
# (pocitane rovnako ako v priklade 2, handout 1)
LAM.KM <- c(Lambda.KM.1,Lambda.KM.2)
par(mfcol=c(1,2)) # nastavenie poctu podokien
## obrazok (limitacia osi-argument xlim,ylim, kde beriem do
## uvahy rozsah zdruzeneho vektora kum.rizik)
## KM odhad kum.rizika (podobne aj NA odhad)
plot(CAS,LAM.KM,xlab="cas do relapsu (v tyzdnoch)",
ylab="kumulativne 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 kumulativne riziko pre AML data")
legend("topleft",c("skup M","skup NM"),lty=c(1,2))
```



KM kumulatívne riziko pre AML data



NA kumulatívne riziko pre AML data

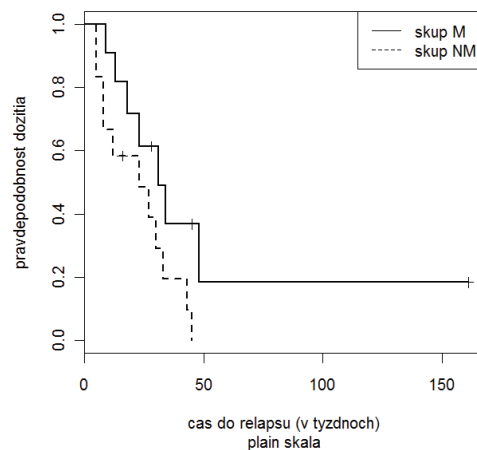


## Príklad 1 (pokrač.):

```
## odhady funkcie prezivania pre kazdu skupinu zvlast
kmfit.aml.1<-survfit(Surv(cas[skup == 1],status[skup == 1])~1)
kmfit.aml.2<-survfit(Surv(cas[skup == 2],status[skup == 2])~1)
## obrazok (hrubka ciary lwd, conf.int kresli IS)
plot(kmfit.aml.1,xlab="cas do relapsu (v tyzdnoch)",
ylab="pravdepodobnost dozitia",conf.int=FALSE,lwd=2)
lines(kmfit.aml.2,lty=2,lwd=2)
legend("topright",c("skup M","skup NM"),lty=c(1,2))
title(main="Krivky prezivania a IS",sub="plain skala")
```



Krivky prezivania a IS



## Príklad 2:

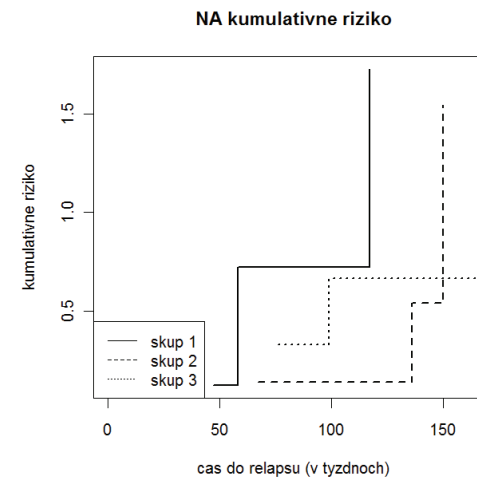
```
## odhady funkcie prezivania pre kazdu skupinu zvlast
## data z prednasky
konc1 <- c(41,41,47,47,47,58,58,58,100,117)
status1 <- c(0,0,1,0,0,1,1,1,0,1)
konc2 <- c(43,44,45,67,68,136,136,150,150,150)
status2 <- c(0,0,0,1,0,1,1,1,1,1)
konc3 <- c(73,74,75,76,76,76,99,166,246)
status3 <- c(0,0,0,1,1,0,1,1,0)
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]
survdif(formula = Surv(data.all, status.all)~skup.all)
# Peto test rho = 1
survdif(formula = Surv(data.all, status.all)~skup.all,rho=1)
```





## 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))
```



## Príklad 2 (pokrač.):

```
## odhady funkcie prezivania pre kazdu skupinu zvlast
kmfit.1 <- survfit(Surv(konc1,status1)~1)
kmfit.2 <- survfit(Surv(konc2,status2)~1)
kmfit.3 <- survfit(Surv(konc3,status3)~1)
## obrazok (hrubka ciary lwd, conf.int kresli IS)
plot(kmfit.1,xlab="cas do zlyhania",ylab="pravdepodobnost
dozitia",conf.int=FALSE,lwd=2)
lines(kmfit.2,lty=2,lwd=2)
lines(kmfit.3,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")
```

