

Tópicos de análise de sobrevivência

Seja T uma variável aleatória não negativa representando o tempo de ocorrência de algum evento de interesse. Supomos também que T seja contínua.

A distribuição de probabilidade da variaável aleatória T pode ser especificada de 3 modos diferentes:

- a) Pela função de sobrevivência
- b) Pela fdp.
- c) Pela função de risco (hazard function)

Definição:

a) A função de sobrevivência é definida por

$$S(t) = P[T > t], \quad t > 0.$$

b) A fdp de T é definida por

$$f(t) = \lim_{\Delta t \rightarrow 0^+} \frac{P[t \leq T \leq t + \Delta t]}{\Delta t}.$$

c) A função de risco (hazard function) especifica a taxa instantânea de falha em $T = t$ condicional a sobrevivência no tempo $T = t$, definida por

$$\lambda(t) = \lim_{\Delta t \rightarrow 0^+} \frac{P[t \leq T \leq t + \Delta t | T > t]}{\Delta t},$$

de modo que

$$\lambda(t) = \frac{f(t)}{S(t)}.$$

Assim,

$$f(t) = \lambda(t)S(t).$$

Interpretação:

$$\begin{aligned}\lambda(t)\Delta t &\approx P[t \leq T < t + \Delta t | T > t] \\ &= P[\text{Morte em } [t, t + \Delta t) | \text{Sobreviver ate o tempo } t].\end{aligned}$$

Observamos que

$$\begin{aligned}\int_0^t \lambda(u)du &= \int_0^t \frac{f(u)}{1 - F(u)}du = -\log[1 - F(u)]|_0^t \\ &= -\log[1 - F(t)] = -\log(S(t)),\end{aligned}$$

onde $F(t) = 1 - S(t)$ é a f.d.

Temos então a relação:

$$S(t) = \exp\left\{-\int_0^t \lambda(u)du\right\},$$

de modo que

$$f(t) = \lambda(t) \exp\left\{-\int_0^t \lambda(u)du\right\}.$$

Tipos de censuras

T_1, \dots, T_N uma a.a. da f.d. $F(\cdot)$.

Dados de sobrevivência são censurados dada a limitação do tempo de análise ou a limitação de custo. Para dados médicos é comum a perda de pacientes pelas mais diversas causas.

Censura do tipo I

Sendo t_c fixado (tempo de censura), em lugar de T_1, \dots, T_n , observa-se somente

$$Y_i = \begin{cases} T_i, & \text{se } T_i \leq t_c, \\ t_c, & \text{se } T_i > t_c. \end{cases}$$

Note que Y tem massa positiva $P[T > t_c] > 0$ em $Y = t_c$.

Censura do tipo II

Seja $r < n$ fixado e $T_{(1)}, \dots, T_{(n)}$ as estatísticas de ordem correspondentes a T_1, \dots, T_n . O experimento termina depois da ocorrência da r -ésima falha, de modo que a amostra observada é $T_{(1)}, \dots, T_{(r)}$. Portanto, observamos

$$Y_i = \begin{cases} T_{(i)}, & i=1, \dots, r, \\ T_{(r)}, & i=r+1, \dots, n. \end{cases}$$

Censuras do tipo 1 e 2 ocorrem em geral na indústria.

Censura aleatória

L_1, \dots, L_n v.a. iid com f.d. $H(\cdot)$. L_i tempo de censura correspondente a T_i .
Observa-se

$$(Y_1, \delta_1), \dots, (Y_n, \delta_n),$$

where

$$Y_i = \min(T_i, L_i)$$

com

$$\delta_i = I(T_i \leq L_i), \quad i = 1, \dots, n.$$

Suposição importante: T_i e L_i são independentes.

Controle:

6.2532787, 3.1666603, 3.8574731, 1.5204410, 6.2007783, 13.7953171,
6.0151210, 8.1982002, 4.9077456, 2.5740268, 0.1553647, 3.6454795,
1.1961790, 0.5703925, 5.1219489

Tratamento:

0.040216554, 0.145055999, 0.100801694, 0.228209581, 0.484319718,
0.680433042,
0.272605316, 0.002199762, 0.149156341, 0.608479438, 0.270311250,
0.011081122,
1.116012546, 0.326174937, 0.062484456

Exemplo 1. Tempos de sobrevivência (em semanas) d pacientes com hepatite

controle: 1+, 2+, 3, 3, 3+, 5+, 5+, 16+,16+,16+,16+,16+,16+,16+

Esteróide: 1, 1, 1, 1+, 4+, 5, 7, 8, 10, 10+, 12+, 16+, 16+, 16+

Exemplo 2. Tempo de reincidência de cancer na bexiga

T_i : 3, 5, 6, 7, 8, 9, 10, 10, 10+, 12, 15, 15+, 18, 19, 20, 22, 25, 28, 30, 40, 45+

Modelo mais adequado? Exponencial, Weibull. Log-Normal

Dados vacinação sarampo no Haiti

Modelo tobit-normal, tobit-log-normal, log-potência-normal, excesso de zeros.

Modelo tobit com excesso de zeros.

2. Modelos paramétricos

1. Distribuição exponencial

Temos:

$$\lambda(t) = \lambda > 0, \quad t > 0,$$

so that

$$\int_0^t \lambda(u) du = \lambda t$$

e

$$S(t) = \exp\left\{-\int_0^t \lambda(u) du\right\} = e^{-\lambda t}.$$

de modo que

$$f(t) = -\frac{dS(t)}{dt} = \lambda e^{-\lambda t}, \quad t > 0.$$

Também

$$E[T] = \frac{1}{\lambda}, \quad Var(T) = \frac{1}{\lambda^2}.$$

Também é possível trabalhar com a parametrização

$$f(t) = \frac{1}{\lambda} e^{-\frac{t}{\lambda}},$$

$t > 0, \lambda > 0$. Neste caso,

$$E[T] = \lambda, \quad Var[T] = \lambda^2.$$

Para amostra t_1, \dots, t_n completa, temos o MLE $\hat{\lambda} = \bar{t}$ e pelo TLC,

$$\sqrt{n}(\hat{\lambda} - \lambda) \rightarrow N(0, \lambda^2).$$

Para construir IC e testes pode-se usar também

$$V = \frac{2 \sum_{i=1}^n T_i}{\lambda} \sim \chi_{2n}^2 \quad (\text{Verificar}).$$

Dadas $X \sim Exp(\lambda_1)$ e $Y \sim Exp(\lambda_2)$ indepedentes, temos

$$\begin{aligned} P[X < Y] &= \int_0^{\infty} P[X < Y | X = t] \lambda_1 e^{-\lambda_1 t} dt \\ &= \int_0^{\infty} P[t < Y] \lambda_1 e^{-\lambda_1 t} dt \\ &= \int_0^{\infty} e^{-\lambda_2 t} \lambda_1 e^{-\lambda_1 t} dt \\ &= \lambda_1 \int_0^{\infty} e^{-(\lambda_1 + \lambda_2)t} dt \\ &= \frac{\lambda_1}{\lambda_1 + \lambda_2}. \end{aligned}$$

Pode ser generalizado para o caso de mais que duas exponenciais.

Distribuição de Weibull

É uma generalização da distribuição Weibull com função de sobrevivência dada por

$$S(t) = e^{-(\lambda t)^\alpha}, \quad \alpha > 0, \quad \lambda > 0.$$

Temos

$$\int_0^t \lambda(u)du = (\lambda t)^\alpha, \quad \text{e} \quad \lambda(t) = \alpha \lambda (\lambda t)^{\alpha-1}.$$

Portanto, a fdp é dada por

$$f(t) = \alpha \lambda (\lambda t)^{\alpha-1} \exp^{-(\lambda t)^\alpha}, \quad t > 0.$$

Temos:

1. $\lambda(t)$ crescente para $\alpha > 1$
2. $\lambda(t)$ decrescente para $\alpha < 1$
3. $\lambda(t)$ constante para $\alpha = 1$ (exponencial).

Distribuição valor-extremo (VE)

$$S(t) = \exp[-\exp(\frac{x - \mu}{\sigma})], \quad x \in R.$$

Note que se $Y \sim Weibull(\alpha, \lambda)$, então $X = \log(Y)$ tem distribuição V.E

Distribuição log-normal

$T \sim \text{Normal}(\mu, \sigma^2)$ se $\log(T) \sim N(\mu, \sigma^2)$.

Função de Sobrevida:

$$\begin{aligned}S(t) &= 1 - F(t) = 1 - P[\log(T) < \log(t)] \\&= 1 - \Phi\left(\frac{\log(t) - \mu}{\sigma}\right),\end{aligned}$$

onde $\Phi(\cdot)$ é a fdp da $N(0, 1)$.

A fdp é dada por

$$f(t) = \frac{1}{\sqrt{2\pi\sigma^2 t}} e^{-\frac{(\log(t)-\mu)^2}{2\sigma^2}}.$$

A função de risco ($f(t)/S(t)$) tem forma complicada.
É necessário trabalhar computacionalmente.

Modelo Pareto

Para este modelo temos

$$S(t) = \left(\frac{a}{t}\right)^\alpha I_{[a,\infty)}(t), \quad \alpha > 0, \quad a > 0,$$

de modo que

$$f(t) = \frac{\alpha a^\alpha}{t^{\alpha+1}} I_{[a,\infty)}(t),$$

e

$$\lambda(t) = \frac{\alpha}{t} I_{[a,\infty)}(t).$$

Note que a fdp acima pode ser escrita como

$$f(t) = \frac{\alpha a^\alpha}{(t+a)^{\alpha+1}} I_{[0,\infty)}(t),$$

por transformação de variáveis.

Este modelo é usado em Turnbull et al. (1976). Bem como o modelo exponencial.

O modelo Pareto acima pode ser obtido como mistura das distribuições exponencial e gama. Ou seja, sendo

$$X \sim Exp(\theta),$$

com fdp

$$f_{T|\theta}(t) = \theta e^{-\theta t}, \quad \theta > 0$$

e

$$g(\theta) = \frac{\lambda}{\Gamma(p)} (\lambda \theta)^{p-1} e^{-\lambda \theta}, \theta > 0, \lambda > 0, p > 0,$$

temos que

$$f(t) = \int_0^\infty \theta e^{-\theta t} \frac{\lambda}{\Gamma(p)} (\lambda \theta)^{p-1} e^{-\lambda \theta}.$$

Pode-se então implementar o modelo Pareto como uma mistura das distribuições exponencial e gama.

Estimação por máxima verossimilhança

Consideramos primeiramente uma representação geral para a verossimilhança. Suponhamos que as variáveis T_i e L_i são continuas com funções de distribuição $F_\theta(\cdot)$ e $H_\eta(\cdot)$, e que esta última não envolve θ . A densidade conjunta de (t_i, δ_i) , denotada por $g_{\delta_i}(t_i)$ será dada por

$$g_{\delta_i}(t_i) = \begin{cases} f_\theta(t_i)[1 - H_\eta(t_i)], & \text{se } \delta_i = 1, \\ h_\eta(t_i)[1 - F_\theta(t_i)], & \text{se } \delta_i = 0. \end{cases}$$

$$i = 1, \dots, n.$$

Deste modo, segue que a função de verossimilhança pode ser escrita como

$$L(\theta|t, \delta) = \prod_{i=1}^n [f_\theta(t_i)]^{\delta_i} [1 - F_\theta(t_i)]^{1-\delta_i} [h_\eta(t_i)]^{1-\delta_i} [1 - H_\eta(t_i)]^{\delta_i}.$$

Igulando o escore a zero temos as equações

$$\frac{\partial \log L(\theta)}{\partial \theta_i} = 0, \quad i = 1, \dots, k.$$

Pelas condições de regularidade do EMV,

$$\sqrt{n}(\hat{\theta} - \theta) \rightarrow N(0, I^{-1}(\theta)),$$

e pelo método delta

$$\sqrt{n}(S_{\hat{\theta}} - S_{\theta}) \rightarrow N(0, I^{-1}(\theta)(\frac{\partial S_{\theta}(t)}{\partial \theta})^2),$$

onde

$$I(\theta) = \int_0^\infty \left(\frac{\partial \log S_\theta(t)}{\partial \theta} \right)^2 S_\theta(t) h(u) du$$
$$+ \int_0^\infty \left(\frac{\partial \log f_\theta(u)}{\partial \theta} \right)^2 f_\theta(u) [1 - H(u)] du.$$

Assumindo esquema de censuras aleatórias (observar que este esquema inclui censura do tipo I, com $L_i = t_c$), com amostra observada $(t_1, \delta_1), \dots, (t_n, \delta_n)$, de modo que a verossimilhança para uma observação (assumindo T_i independente de L_i) é dada por

$$L(\theta|t_i, \delta_i) = \begin{cases} f(t_i), & \text{se } \delta_i = 1, \\ S(t_i), & \text{se } \delta_i = 0, \end{cases}$$

ou seja,

$$L(\theta|t_i, \delta_i) = f^{\delta_i}(t_i)S^{1-\delta_i}(t_i),$$

de modo que para a amostra observada

$$\mathbf{t} = (t_1, \dots, t_n)', \quad \delta = (\delta_1, \dots, \delta_n)',$$

temos a função de verossimilhança

$$\begin{aligned} L(\theta | \mathbf{t}, \delta) &= \prod_{i=1}^n L(t_i, \delta_i) \\ &= \prod_{i \in C} f(t_i) \prod_{i \in C^0} S(t_i), \end{aligned}$$

onde C^0 corresponde a sobseparações censuradas e C as não censuradas.

Para o modelo log-normal, usamos a transformação $Y = \log(T) \sim N(\mu, \sigma^2)$ e ai calculamos os estimadores de MV para μ e σ^2 e usamos o principio da invariância do EMV.

O modelo tobit

o modelo tobit foi proposto por Tobin (1956) e corresponde a um modelo censurado a esquerda de zero (ou algum limite de deteção mínimo - LDM). Formalmente, o modelo tobit pode ser formulado como

$$y_i = \begin{cases} 0 & \text{se } w_i \leq 0, \\ w_i; & \text{caso contrário,} \end{cases}$$

onde a variável latente é $w_i = \mathbf{x}'_i \beta + \epsilon_i$, com $\epsilon_i \sim N(0, \sigma^2)$, $i = 1, \dots, n$. Consequentemente, denotamos as respostas observadas por y_i , o valor das k variáveis explanatórias para a i -ésima observação por $\mathbf{x}_i \in R^k$, os parâmetros de regressão por $\beta = (\beta_0, \beta_1, \dots, \beta_k)'$ e o i -ésimo termo residual por ϵ_i .

Temos a função de verossimilhança

$$L_N(\beta, \sigma^2) = \prod_{i=1}^n [1 - \Phi\left(\frac{1}{\sigma} \mathbf{x}'_i \beta\right)]^{1-\delta_i} \left[\left(\frac{1}{\sigma}\phi\left(\frac{1}{\sigma}(y_i - \mathbf{x}'_i \beta)\right)\right]^{\delta_i},$$

com ϕ e Φ sendo a fdp e a fda da $N(0,1)$.

Podemos ter uma representação geral para a verossimilhança para o modelo tobit

A função de log-verossimilhança para o modelo tobit (para $T=c$) para a situação onde o erro ϵ_i segue uma função de distribuição F , pode ser escrita como

$$\ell(\theta; Y) = \sum_i (1 - I_i) \ln[F\left(\frac{c - \mu}{\sigma}\right)] + \sum_i I_i \left\{ -\ln(\sigma) + \ln\left(f\left(\frac{y_i - \mu}{\sigma}\right)\right) \right\}$$

onde $f = F'$, e

$$I_i = \begin{cases} 1, & \text{se } y_i > c, \\ 0, & \text{se } y_i \leq c. \end{cases}$$

Verificar no artigo (*Tobit power-normal model, CS-TM*) o uso do modelo potência-normal com o modelo tobit.

O estimador de MV, $\hat{\theta}$ maximiza a função de verossimilhança $L(\mathbf{t}, \delta)$ se sob condições de regularidade temos

$$\hat{\theta} \xrightarrow{a} N(\theta, I_F(\theta)),$$

onde $I_F(\theta)$ é a matriz de informação de Fisher de θ , que é consistentemente estimada por

$$i(\hat{\theta}) = -\frac{1}{n} \left\{ \frac{\partial^2 \log L(\mathbf{t}, \delta)}{\partial \theta \partial \theta'} \right\}_{|\hat{\theta}}.$$

Para testar $H_0 : \theta = \theta_0$, podemos usar as estatísticas

1. Wald:

$$(\hat{\theta} - \theta_0)' \mathbf{I}_F(\theta_0) (\hat{\theta} - \theta_0) \sim \chi_p^2$$

sob H_0 .

2. Razão de verossimilhanças.

$$-2 \log\left(\frac{L(\hat{\theta})}{L(\theta)}\right) \sim \chi_p^2,$$

under H_0 .

3. Escore

$$\frac{\partial}{\partial \theta} \log L(\theta_0)' \mathbf{I}_F(\theta_0) \frac{\partial}{\partial \theta} \log L(\theta_0) \sim \chi_p^2,$$

que não envolve o EMV. Usamos $L(\mathbf{y}, \delta) = L(\theta)$.

Inferência no modelo exponencial

$$\begin{aligned} L(\theta) &= \prod_{i \in C} f(t_i) \prod_{i \in C^0} S(t_i) \\ &= \theta^{n_u} \exp\left\{-\theta \sum_{i=1}^n t_i\right\}, \end{aligned}$$

de modo que

$$\log L = n_u \log(\theta) - \theta \sum_{i=1}^n t_i.$$

The EMV é então dado por

$$\hat{\theta} = \frac{n_u}{\sum_{i=1}^n t_i}.$$

Também

$$i(\theta) = \frac{n_u}{\theta^2}.$$

Também, para $S = \sum_{i=1}^n T_i$ no caso não cesurado,

$$f_S(t) = \frac{\theta^n}{\Gamma(n)} t^{n-1} e^{-\theta t},$$

de modo que

$$2\theta \sum_{i=1}^n T_i \sim \chi_{2n}^2,$$

de modo que

$$\frac{2n\theta}{\hat{\theta}} \sim \chi_{2n}^2,$$

que pode ser usada na construção de ICs e testes.

Para censura do tipo II,

$$\begin{aligned} \sum_{i=1}^n Y_i &= T_{(1)} + T_{(2)} + \cdots + T_r + (N - r)T_{(r)} \\ &= nT_{(1)} + (n - 1)[T_{(2)} - T_{(1)}] + \cdots + (N - r + 1)[T_{(r)} - T_{(r-1)}]. \end{aligned}$$

Temos que $nT_{(1)}$, $(n - 1)[T_{(2)} - T_{(1)}]$, ..., $(N - r + 1)[T_{(r)} - T_{(r-1)}]$ são iids com $Exponencia(\theta)$.

EMV para Weibull

$$S(t) = e^{-\{(\lambda t)^\alpha\}} = e^{-\gamma t^\alpha},$$

$$f(t) = \gamma \alpha t^{\alpha-1} e^{-\gamma t^\alpha},$$

$$\text{com } \gamma = \lambda^\alpha.$$

Sendo $\theta = (\alpha, \gamma)'$,

Verossimilhança:

$$L(\theta|t, \delta) = (\gamma\alpha)^{n_u} \left(\prod_{C^c} t_i^{\alpha-1} \right) e^{-\{\gamma \sum_{i=1}^n t_i^\alpha\}}.$$

Métodos iterativos necessários para maximização.

Condicionais determinam conjunta (marginais)

Let

$$\mathbf{Z} \sim N(\mu, \Sigma),$$

onde

$$\mathbf{Z} = \begin{pmatrix} X \\ Y \end{pmatrix} \quad \mu = \begin{pmatrix} 0 \\ 0 \end{pmatrix}$$
$$\Sigma = \begin{pmatrix} 1 & 0.5 \\ 0.5 & 1 \end{pmatrix}.$$

Então

$$X|Y \sim N(0.5 * y, 0.75)$$

$$Y|X \sim N(0.5 * x, 0.75).$$

Função de distribuição empírica

Ex: Amostra X:1,3,7,10

$$F_n(t) = \begin{cases} 0, & \text{se } t < 1, \\ 1/4, & \text{se } 1 \leq t < 3, \\ 2/4, & \text{se } 3 \leq t < 7, \\ 3/4, & \text{se } 7 \leq t < 10, \\ 1, & \text{se } t \geq 10 \end{cases}$$

$S_n(t) = 1 - F_n(t)$: função de sobreivência empírica.

Represente S_n para a amostra acima!!!!

$$S_n(5) = 1 - F_n(5) = 1 - 2/4 = 2/4.$$

$$S_n(t) = \begin{cases} 1, & \text{se } 0 \leq t < 1, \\ 3/4, & \text{se } 1 \leq t < 3, \\ 2/4, & \text{se } 3 \leq t < 7, \\ 1/4, & \text{se } 7 \leq t < 10, \\ 0, & \text{se } t \geq 10 \end{cases}$$

Estimador de Kaplan-Meier:

$$S_n(1) = (1 - 1/4) = 0.75$$

$$S_n(3) = (1 - 1/4)(1 - 1/3) = (0.75)(2/3) = 0.5$$

$$S_n(7) = (1 - 1/4)(1 - 1/3)(1 - 1/2) = (0.75)(2/3)(0.5) = 0.25$$

$$S_n(10) = (1 - 1/4)(1 - 1/3)(1 - 1/2)(1 - 1) = (0.75)(2/3)(0.5)(0) = 0.$$

Portanto, sendo

n_i : número de indivíduos em risco em (imediatamente antes de) t_i , temos

$$S_n = \prod_{i,t_i < t} \left(1 - \frac{1}{n_i}\right).$$

time	n.risk	n.event	survival	std.err	lower 95% CI	upper 95% CI
1	4	1	0.75	0.217	0.4259	1
3	3	1	0.50	0.250	0.1877	1
7	2	1	0.25	0.217	0.0458	1
10	1	1	0.00	NaN	NA	NA

Como para o caso sem censura

$$\sqrt{n}(S_n(t) - S(t)) \longrightarrow N(0, S(t)F(t)),$$

de modo que um estimador consistente para $\widehat{Var}[S_n(t)]$ é dado por

$$\widehat{Var[S_n(t)]} = \frac{S_n(t)F_n(t)}{n}.$$

Assim, da Tabela acima,

$$\widehat{Var[S_n(1)]} = \frac{.75 * .25}{4} = 0.0469,$$

de modo que

$$MSE(S_n(1)) = \sqrt{(0.0469)} = 0.217.$$

No caso geral, com censura

$$Var[\widehat{S_{KM}}(t)] = (S_{KM}(t))^2 \sum_{i; t_i < t} \frac{d_i}{n_i(n_i - d_i)}$$

onde d_i é o número defalhas em t_i e n_i o número de individuos em risco.
Assim,

$$Var[\widehat{S_{KM}}(1)] = (S_{KM}(1))^2 \frac{1}{4 * 3} = ((0.75)^2)/12 = 0.0469.$$

Comparação de dois grupos com K-M

```
require(survival)
```

```
ts=c(1,2,3,3,3,5,5,16,16,16,16,16,16,16,16,16,16,1,1,1,1,4,5,7,8,10,10,12,16,16,16)
```

```
cs=c(0,0,1,1,0,0,0,0,0,0,0,0,0,0,1,1,1,0,0,1,1,1,1,0,0,0,0,0)
```

```
grupos=c(rep(1,15),rep(2,14))
```

```
ekm=survfit(Surv(ts,cs)~grupos)
```

```
summary(ekm)
```

```
plot(ekm,lty=c(2,1),xlab="Ts",ylab="StE")
```

```
survdiff(Surv(ts,cs)~grupos,rho=0)
```

Comparação entre Empírico e paramétrico

1. Modelo Exponencial:

$$S_\lambda(t) = e^{-\lambda t}, \quad \frac{\partial S_\lambda(t)}{\partial \lambda} = te^{-\lambda t},$$

de modo que

$$\sqrt{n}(S_{\hat{\lambda}}(t) - S(t)) \rightarrow N(0, \lambda^2 t^2 e^{-2\lambda t}).$$

Como X_1, \dots, X_n são iids, $I(X_i > t)$ são Bernoullis indepedenteds com probabilidade de sucesso $p = P(X_i > t)$, de modo que pela LFGN e TLC,

$$\sqrt{n}(S_n(t) - S(t)) \rightarrow N(0, S(t)(1 - S(t))),$$

de modo que

$$e_{E,MV} = \frac{\lambda^2 t^2 e^{-2t\lambda}}{e^{-\lambda t}(1 - e^{-\lambda t})} = \frac{\lambda^2 t^2 e^{-t\lambda}}{(1 - e^{-\lambda t})}$$

Para $t = 1$, temos as eficiências

λ	1	2	3	4	5
$S(t)$	0.58	0.63	0.47	0.30	0.17

Considere $t_{(1)}, \dots, t_{(k)}$, os tempos distintos de falhas

d_i : número de falhas em $t_{(i)}$,

n_i : número de indivíduos em risco no instante do $t_{(i)}$ (-ésima falha);

O estimador de Kaplan-Meier para o caso de não haver empates pode ser escrito como

$$S_{KM}(t_i) = \prod_{i; t_{(i)} < t} \left(1 - \frac{d_i}{n_i}\right) = \prod_{i; t_{(i)} < t} (1 - \hat{q}_i),$$

Comparação de dois grupos pelo KM.

Tratamento: 1+,2+,3,3,3+,5+,5+,16+,16+,16+,16+,16+,16+,16+,16+

Controle: 1,1,1,1+,1+,4,5,7,8,10,10+,12+,16+,16+,16+

Usando o KM no R, temos para o Grupo Controle

time	n.risk	n.event	survival	std.err	lower 95% CI	upper 95% CI
3.000	13.000	2.000	0.846	0.100	0.671	1.000

Note que $S(3) = (1 - 2/13) = 1 - 0.154 = .846..$

Grupo Tratamento

time	n.risk	n.event	survival	std.err	lower 95% CI	upper 95% CI
1	14	3	0.786	0.110	0.598	1.000
5	9	1	0.698	0.128	0.488	0.999
7	8	1	0.611	0.138	0.392	0.952
8	7	1	0.524	0.143	0.306	0.896
10	6	1	0.437	0.144	0.229	0.832

Note que

$$S(1) = (1 - 3/14) = 0.786.$$

$$S(5) = (0.786)(1 - 1/9) = 0.698, \dots$$

Para comparar os grupos temos a tabela

`survdiff(formula = Surv(ts, cs) ~ grupos, rho = 0)`

	N	Observed	Expected	$(O - E)^2/E$	$(O - E)^2/V$
grupos=1	15	2	4.81	1.64	3.67
grupos=2	14	7	4.19	1.89	3.67

Conclusão: Chisq= 3.7 com 1 degrees of freedom, p= 0.0555

Resultado do enfoque Bayesiano Para comparar dois grupos com modelo Exponencial

Parâmetro bt

mean	sd	$MCerror$	$val2.5pc$	median	$val97.5pc$	start	sample
1.795	0.8977	0.03451	0.1785	1.751	3.695	11001	110000

De acordo com o enfoque Bayesiano existe diferença significativa entre os grupos (5%). Note que o teste log-rank não deteta diferença.

Teste "logrank" para comparar funções de sobrevida $S_1(t)$ e $S_2(t)$.

Considere tempos de falhas conjuntos

$$t_1 < \dots < t_k.$$

Sejam

d_j : número de falhas em t_j .

n_j : número de indivíduos em risco em t_j .

Similarmente define-se n_{ij} e d_{ij} , na amostra $i = 1, 2$.

Define-se uma estatística baseada na média e variância de d_{2j}

$$E[d_{2j}] = n_{2j} \frac{d_j}{n_j},$$

$$Var[d_{2j}] = n_{2j}(n_j - n_{2j})d_j(n_j - d_j)n_j^{-2}(n_j - 1)^{-1}.$$

Distribuição de d_{2j} :

$$\frac{\binom{n_{1j}}{d_{1j}} \binom{n_{2j}}{d_{2j}}}{\binom{n_j}{d_j}}.$$

Define-se aproximação normal (sob H_0) para distribuição normalizada de d_{2j} ,
 $j = 1, \dots, k$.

Os resultados a seguir são apresentados em Lima (tese de mestrado).

Considere

$$X \sim Exp(\theta) \text{ e } L \sim Exp(\mu).$$

Assim,

$$S(t) = 1 - F(t) = e^{-\theta t} \text{ and } H(t) = e^{-\mu t}.$$

Conforme estabelecido em Lima,

$$\begin{aligned} Var[\hat{S}_{KM}] &= \frac{1}{n}[S(t)]^2 \int_0^t \frac{f(u)}{[1 - H(u)]S(u)^2} du \\ &= \frac{1}{n}e^{-2\theta t}(e^{-(\theta+\mu)t} - 1) \frac{\theta}{\theta + \mu}. \end{aligned}$$

Para o EMV,

$$Var[\hat{S}_{MV}] = \frac{1}{n} I_F^{-1}(\theta) \left\{ \frac{\partial S(t)}{\partial \theta} \right\} = \frac{1}{n} \theta t^2 (\theta + \mu) e^{-2\theta t},$$

de modo que

$$\begin{aligned} EAR_{KM,EM} &= (\theta + \mu)^2 t^2 (e^{(\theta+\mu)t} - 1)^{-1} \\ &= (1 + \rho)^2 (\theta t)^2 (e^{(1+\rho)\theta t} - 1)^{-1}, \end{aligned}$$

onde $\rho = \mu/\theta$. Eficiências variam de 0.19 a 0.64.

Modelo de Regressão de Cox

Seja

$$\lambda(t, \mathbf{x}) = e^{\mathbf{x}'\beta} \lambda_0(t),$$

onde $\beta = (\beta_1, \dots, \beta_p)'$ é o vetor de coeficientes de regressão. Note que a função de risco baseline $\lambda_0(t)$, é constante para todos os pacientes.

Para o modelo Weibull, temos

$$\lambda_0(t) = \alpha\lambda^\alpha t^{\alpha-1},$$

que é constante para todos os pacientes. Ou seja o modelo Weibull tem a propriedade dos riscos proporcionais.

Considerando os tempos de falha: t_1, \dots, t_k , temos

$$P[morte \text{ em } [t_i, t_i + \Delta t] | R_i] = \sum_{j \in R_i} \lambda_0(t_i) e^{\beta' \mathbf{x}_j} \Delta_t.$$

e

$$P[morte \text{ de } (i) \text{ em } t_i] = \lambda_0(t_i) e^{\beta' \mathbf{x}_j}$$

Assim,

$$P[morte \text{ de } (i) \text{ no tempo } t_i | morte \text{ em } t_i]$$

$$= \frac{e^{\beta' \mathbf{x}_i}}{\sum_{j \in R_i} e^{\beta' \mathbf{x}_j}}.$$

Temos então a função de verossimilhança

$$L_c(\beta) = \prod_{i=1}^n \left(\frac{e^{\beta' \mathbf{x}_j}}{\sum_{j \in R_i} e^{\beta' \mathbf{x}_j}} \right)^{\delta_i},$$

que pode ser considerada como uma verossimilhança usual, com derivada primeira levando ao escore e segunda a observacao observada.

Tomando $l(\beta) = \log(L(\beta))$ e derivando com respeito a β , temos o escore

$$\mathbf{U}(\beta) = \sum_{i=1}^n \delta_i [\mathbf{x}_i - \frac{\sum_{j \in R_i} \mathbf{x}_j e^{\beta' \mathbf{x}_j}}{\sum_{j \in R_i} e^{\beta' \mathbf{x}_j}}],$$

que deve ser resolvida por métodos numéricos.

Exemplo: Dados sobre 4 pacientes:

PACIENTE	<i>t</i>	Status	<i>x</i> (fumante)
P1	2	1	1
P2	3	1	0
P3	5	0	0
P4	8	1	1

Modelo de Cox:

$$\lambda(t, x) = \lambda_0 e^{\beta_1 FUMANTE}.$$

Temos então o risco de cada paciente:

PACIENTE	risco
P1	$\lambda_0(t)e^{\beta_1}$
P2	$\lambda_0(t)e^0$
P3	$\lambda_0(t)e^0$
P4	$\lambda_0(t)e^{\beta_1}$

Verossimilhança:

$$\begin{aligned}L(\beta) &= \left[\frac{\lambda_0(t)e^{\beta_1}}{\lambda_0(t)e^{\beta_1} + \lambda_0(t)e^0 + \lambda_0(t)e^0 + \lambda_0(t)e^{\beta_1}} \right] \\&\quad \times \left[\frac{\lambda_0(t)e^0}{\lambda_0(t)e^0 + \lambda_0(t)e^0 + \lambda_0(t)e^{\beta_1}} \right] \\&\quad \times \left[\frac{\lambda_0(t)e^{\beta_1}}{\lambda_0(t)e^{\beta_1}} \right].\end{aligned}$$

Então temos a função de verossimilhança

$$L(\beta) = \frac{e_1^\beta}{2e_1^\beta + 2} \times \frac{1}{e_1^\beta + 2},$$

Tomando log, obtemos

$$l(\beta) = \log(L(\beta)) = \beta_1 - \log(2e_1^\beta + 2) - \log(2 + e^{\beta_1}).$$

Derivando com respeito a beta, obtemos

$$1 - \frac{2e_1^\beta}{2e_1^\beta + 2} - \frac{e_1^\beta}{e_1^\beta + 2} = 0,$$

que leva a equação ($y = e_1^\beta$),

$$\frac{y}{1+y} + \frac{y}{2+y} = 1,$$

Ou seja,

$$y^2 - 2 = 0, \longrightarrow y = \sqrt{2} \longrightarrow \hat{\beta}_1 = \log(\sqrt{2}).$$

Uma outra configuração:

PACIENTE	<i>t</i>	Status	<i>x</i> (fumante)
----------	----------	--------	--------------------

P1	2	1	1
P2	3	1	0
P3	5	0	1
P4	8	0	0

Modelo de Cox:

$$\lambda(t, x) = \lambda_0 e^{\beta_1 FUMANTE}.$$

Verossimilhança:

$$\begin{aligned} L(\beta) &= \left[\frac{\lambda_0(t)e^{\beta_1}}{\lambda_0(t)e^{\beta_1} + \lambda_0(t)e^0 + \lambda_0(t)e^0 + \lambda_0(t)e^{\beta_1}} \right] \\ &\quad \times \left[\frac{\lambda_0(t)e^0}{\lambda_0(t)e^0 + \lambda_0(t)e^0 + \lambda_0(t)e^{\beta_1}} \right] \\ &= \frac{e^{\beta_1}}{2 + 2e^{\beta_1}} \times \frac{1}{e^{\beta_1}}. \end{aligned}$$

Assim, sendo $y = e^{\beta_1}$, temos

$$l = \log(L(y)) = y - \log(y + 1) - \log(y + 2),$$

que, derivando com relação a y , leva a equação

$$\frac{1}{1+y} + \frac{1}{2+y} = 1,$$

ou seja,

$$y^2 + y - 1 = 0.$$

ou

$$y = \frac{-1 + \sqrt{5}}{2}.$$

G1 (T)	G1 (X)	G2(T)	G2(X)	G1(T)	G1(X)	G2(T)	G2(X)
6	2.31	1	2.8	10+	2.7	8	2.32
6	2.31	1	2.8	10+	2.7	8	2.32
6	4.06	1	5	11+	2.6	8	3.26
6	2.38	2	4.91	17+	2.16	11	3.49
7	4.43	2	4.91	19+	2.05	11	2.12
10	2.96	3	4.01	20	2.01	12	1.50
13	2.88	4	4.36	25+	1.78	12	3.06
16	3.6	4	2.42	32+	2.2	15	2.3
22	2.32	5	3.49	32+	2.53	17	2.95
23	2.57	5	3.97	34+	1.47	22	2.73
6+	3.2	8	3.52	35+	1.45	23	1.97
9+	2.8	8	3.05				

Birnbaum and Saunders (1969) fizeram algumas suposições sobre o processo de fadiga, que são elas:

1. Material é submetido a um ciclo de tensão e força;
2. Crescimento de fissura que excede cero nível de resistência denotado por w ;
3. A sequência de tensão imposta ao material é uma variável aleatória que só depende da fissural atual causada pela tensão no repectivo ciclo;

4. A extensão incremental da fissura representada por X_i resultante da aplicação da i-ésima oscilação de carga é uma variável aleatória que só depende da fissura atual causada pela tensão neste ciclo.

5. a extensão da fissura durante o ciclo j , é

$$Y_{j+1} = X_{jm+1} + \cdots + X_{jm+m}, \quad j = 0, 1, \dots,$$

onde X_{jm+i} é a extensão da fissura após a i-ésima oscilação de carga do ciclo $(j + 1)$.

6. A extensão total da fissura, Y_j devido apóis n ciclos pela seguinte variável aleatória

$$W_n = \sum_{j=1}^n Y_j = \sum_{j=1}^n X_{jm+i},$$

com fda

$$H_n(w) = P[W_n \leq w], \quad n = 1, 2, \dots$$

Definiremos como N o número de ciclos necessários até que ocorra uma falha. A fda da v.a. N pode ser expressa por

$$P[N \leq n]P\left[\sum_{j=1}^n Y_j > w\right] = P[W_n > w] = 1 - H_n(w).$$

Considerando Y'_j 's v.a.i.i.d. pelo uso do TLC temos

$$\begin{aligned} P[N \leq n] &= P\left[\sum_{j=1}^n \frac{Y_j - \mu}{\sigma\sqrt{n}} > \frac{w - n\mu}{\sigma\sqrt{n}}\right] \\ &= 1 - P\left[\sum_{j=1}^n \frac{Y_j - \mu}{\sigma\sqrt{n}} \leq \frac{w - n\mu}{\sigma\sqrt{n}}\right] \\ &\approx 1 - \Phi\left(\frac{w - n\mu}{\sigma\sqrt{n}}\right) = \Phi\left(\frac{\mu\sqrt{n}}{\sigma} - \frac{w}{\sigma\sqrt{n}}\right). \end{aligned}$$

Assim, substituindo n por t onde T é a v.a. tempo de falha e definindo

$$\alpha = \frac{\sigma}{\sqrt{\mu w}} \quad e \quad \beta = \frac{w}{n},$$

temos que a fda de T é dada por

$$F(t; \alpha, \beta) = \Phi\left[\frac{1}{\alpha}\left(\sqrt{\frac{t}{\beta}} - \sqrt{\frac{\beta}{t}}\right)\right],$$

$$t > 0, \alpha > 0, \beta > 0.$$

Note que β é a mediana da distribuição, isto é,

$$F(\beta; \alpha, \beta) = \Phi(0) = 0.5.$$

Derivando a FDA acima com respeito a t temos a fdp

$$f(t; \alpha, \beta) = \frac{1}{\sqrt{2\pi}} \frac{t^{3/2}(t + \beta)}{2\alpha\sqrt{\beta}} \exp\left[-\frac{1}{2\alpha^2}\left(\frac{t}{\beta} + \frac{\beta}{t} - 2\right)\right], \quad t > 0.$$

Pode-se mostrar que se $T \sim BS(\alpha, \beta)$, então

$$Z = \frac{1}{\alpha} \left[\sqrt{\frac{T}{\beta}} - \sqrt{\frac{\beta}{T}} \right] \sim N(0, 1).$$

Reciprocamente, se $Z \sim N(0, 1)$, então

$$T = \frac{\beta}{4} [\alpha Z + \sqrt{\alpha^2 Z^2 + 4}]^2 \sim BS(\alpha, \beta).$$