

Análise de Sobrevivência

Camila Borelli Zeller
Lupércio França Bessegato
Departamento de Estatística/UFJF

Roteiro Geral



1. Conceitos básicos
2. Técnicas não-paramétricas
3. Modelos probabilísticos
4. Modelos de regressão paramétricos
5. Modelo de regressão de Cox
6. Extensões do modelo de Cox
7. Referências

Análise de Sobrevivência - 2017

2

Modelos Probabilísticos

Roteiro do Módulo



3. Modelos probabilísticos:
 - a) Introdução
 - b) Modelos em análise de sobrevivência
 - c) Estimativa dos parâmetros dos modelos
 - d) Intervalos de confiança e testes de hipóteses
 - e) Escolha do modelo
 - f) Exemplos

Análise de Sobrevivência - 2017

4

Introdução

Técnicas Não Paramétricas



- Técnicas não paramétricas:
 - √ Fáceis de entender
 - √ Não permitem inclusão de covariáveis na análise
- Estratificação:
 - √ Simplicidade dos cálculos e facilidade de entendimento
 - √ Análise com várias covariáveis gera um número muito grande de estratos que podem conter poucas observações

Análise de Sobrevivência - 2017

7

Modelos de Regressão



(Apropriados para dados de sobrevivência)

- Modelos Paramétricos:
 - √ São mais eficientes e menos flexíveis
 - $$Y = \log(T) = \beta_0 + \beta_1 + \dots + \beta_p + \sigma W$$
 - W: erros com distribuição especificada
 - √ Classe denominada tempo de vida acelerado é muito utilizada
 - Tempo de vida obedece à seguinte relação:

$$Y = \log(T) = \mu + \sigma W$$

- μ : parâmetro de locação
- σ : parâmetro de escala

Análise de Sobrevivência - 2017

8

- Modelos Semi-paramétricos:
- 

- √ Modelo de riscos proporcionais de Cox
- √ Formado por dois elementos: um paramétrico e outro não-paramétrico
- √ Flexibilidade
- √ Permite incorporação de covariáveis dependentes do tempo

Análise de Sobrevivência - 2017

9

Modelos em Análise de Sobrevivência

Distribuições



- Adotadas para se ajustar a distribuição do tempo de sobrevivência T:
 - √ Exponencial
 - √ Weibull
 - √ Log-normal
 - √ Log-logística
 - √ Etc.

Análise de Sobrevivência - 2017

11

Distribuição Exponencial



- Densidade: $f(t) = \alpha \exp\{-\alpha t\}$
 - √ $t \geq 0$ e $\alpha > 0$
- Função de sobrevivência: $S(t) = \exp\{-\alpha t\}$
- Parâmetro:
 - √ α : representa a queda da função de sobrevivência ao longo do tempo

Análise de Sobrevivência - 2017

12


- Função de risco:

$$\lambda(t) = \frac{\alpha \exp\{-\alpha t\}}{\exp\{-\alpha t\}} = \alpha$$

- √ Constante e igual a α
- Função de risco acumulado
$$\Lambda(t) = -\ln S(t) = \alpha t$$
 - √ É uma função linear no tempo

Análise de Sobrevivência - 2017

13



• Exponencial – Esperança e Variância:

$$E[T] = \frac{1}{\alpha}$$

$$\text{Var}[T] = \frac{1}{\alpha^2}$$

• Função quantílica:

$$F(t_p) = p, \quad 0 < p < 1$$

$$1 - \exp\{-\alpha t_p\} = p$$

$$t_p = -\frac{\ln(1-p)}{\alpha}$$

• Mediana:

$$t_{med} = -\frac{\ln(1-0,5)}{\alpha} = \frac{\ln(2)}{\alpha}$$

√ $F(t_{med}) = 0,5$

Análise de Sobrevivência - 2017 15

• Exponencial – Média e mediana:

$$E[T] = \frac{1}{\alpha} \quad t_{med} = \frac{\ln(2)}{\alpha}$$

√ Tempo de sobrevivência é assimétrico
 - Tempo mediano é mais usual que tempo médio
 √ $t_{med} < E[T]$, para qualquer valor de α
 √ $E[T]$ e t_{med} são inversamente proporcionais ao risco

Análise de Sobrevivência - 2017 16

Exemplo

• Sobrevivência ao diagnóstico de Aids

√ Coorte completa entre 1986 e 2000
 - Óbitos: 90
 - Censuras: 103

√ Modelagem:
 - Tempo entre diagnóstico de Aids e a morte segue uma distribuição exponencial
 ▪ Estimativa: $\alpha = 0,000497$

Análise de Sobrevivência - 2017 17

- Encerramento de acompanhamento: $t = 3.500$ dias
 - √ Espera-se que cerca de 20% dos pacientes ainda estejam vivos
 - √ Sobrevivência teórica adotada – Exponencial:


$$\hat{S}_e(3500) = \exp\{-(0,000497)(1500)\} = 0,17561$$
 - Sobrevivência teórica tende a zero
 - (Aconteceria se tempo de estudo se prolongasse até que todos os pacientes fossem acompanhados até o óbito)
- Função de risco é constante:

$$\lambda(t) = 0,000497$$

Análise de Sobrevivência - 2017

18

√ Coorte de Aids – Modelo paramétrico exponencial



Tempo médio de sobrevivência:

$$E[T] = \frac{1}{\alpha} = \frac{1}{0,000497} = 2.012 \text{ dias}$$

Tempo mediano de sobrevivência:

$$t_{med} = \frac{\ln(2)}{\alpha} = \frac{\ln(2)}{0,000497} = 1.394 \text{ dias}$$

Sobrevivência ao tempo médio:

$$S(E[T]) = \exp -1 = 0,3679$$

SEMPRE!!! (qualquer exponencial)

Análise de Sobrevivência - 2017

19

• Exponencial – Comentários:

- √ Simplifica a modelagem
 - É expressa por um único parâmetro
- √ Suposição de risco constante é pouco plausível na maioria dos fenômenos da saúde
 - Diz-se que a distribuição não tem memória
- √ Pode ser uma aproximação válida quando o tempo de acompanhamento é curto o suficiente para se considerar constante o risco no período
 - Risco de acidentes domésticos em crianças de 4 a 6 anos
- √ Utilizada em alguns estudos de tempos de vida e em remissão de doenças crônicas e infecciosas

Análise de Sobrevivência - 2017

20

Distribuição de Weibull

- Densidade: $f(t) = \gamma \alpha^\gamma t^{\gamma-1} \exp\{-(\alpha t)^\gamma\}$
 - √ $t \geq 0, \alpha \text{ e } \gamma > 0$
- Função de sobrevivência: $S(t) = \exp\{-(\alpha t)^\gamma\}$
- Parâmetros:
 - √ α : parâmetro de escala (mesma unidade de t)
 - √ γ : parâmetro de forma (adimensional)
- A exponencial é uma caso especial da Weibull ($\gamma=1$)

Análise de Sobrevivência - 2017

21

- Função de risco: $\lambda(t) = \gamma \alpha^\gamma t^{\gamma-1}$
 - √ Função potência
 - √ Risco não é constante ao longo do tempo
 - A função de risco é monótona
 - √ Parâmetro de forma da função de risco
 - Modela a variação do risco no tempo
 - $\gamma < 1$: função de risco decresce
 - $\gamma > 1$: função de risco cresce
 - $\gamma = 1$: função de risco constante
- Função de risco acumulado: $\Lambda(t) = -\ln S(t) = (\alpha t)^\gamma$

23

• Weibull – Forma típica das funções

- Flexibilidade de formas da distribuição
- Parâmetro de forma γ :
 - $\gamma < 1$: função de risco decresce
 - $\gamma > 1$: função de risco cresce
 - $\gamma = 1$: função de risco constante

24

- Exponencial – Esperança e Variância:
 - $E[T] = \frac{1}{\alpha} \Gamma\left(1 + \frac{1}{\gamma}\right)$
 - $\text{Var}[T] = \frac{1}{\alpha^2} \left[\Gamma\left(1 + \frac{2}{\gamma}\right) - \Gamma^2\left(1 + \frac{1}{\gamma}\right) \right]$
 - $\Gamma(k) = \int_0^\infty x^{k-1} e^{-x} dx$
- Função quantílica: $F(t_p) = p, 0 < p < 1$

$$1 - \exp\{-(\alpha t_p)^\gamma\} = p$$

$$t_p = \frac{[-\ln(1-p)]^{1/\gamma}}{\alpha}$$
- Mediana: $t_{med} = \frac{[-\ln(1-0,5)]^{1/\gamma}}{\alpha} = \frac{[\ln(2)]^{1/\gamma}}{\alpha}$
 - √ $F(t_{med}) = 0,5$

25

Weibull – Comentários

- Para a maioria dos fenômenos de saúde
 - √ É plausível supor que o risco não é constante no tempo
- Função mais utilizada na modelagem paramétrica em saúde
- Muito flexível
 - √ O parâmetro γ modela a variação do risco no tempo

27

Distribuição Lognormal

- Densidade: $f(t) = \frac{1}{\sqrt{2\pi}\sigma} \exp\left\{-\frac{1}{2}\left(\frac{\ln(t) - \mu}{\sigma}\right)^2\right\}$
 $\sqrt{t > 0, -\infty < \mu < \infty \text{ e } \sigma > 0}$
- Função de sobrevivência: $S(t) = \Phi\left(\frac{-\ln(t) + \mu}{\sigma}\right)$
 $\sqrt{\Phi}$: função de distribuição acumulada da normal padrão
- Parâmetros:
 $\sqrt{\text{O logaritmo dos dados de uma lognormal têm distribuição normal.}}$

30

- Função de risco: $\lambda(t) = \frac{f(t)}{S(t)}$
 $\sqrt{\text{A função de risco não é monótona como as da distribuição de Weibull}}$
- Função de risco acumulado:

$$\Lambda(t) = -\ln S(t)$$

$$= -\ln\left[\Phi\left(\frac{-\ln(t) + \mu}{\sigma}\right)\right]$$

32

Lognormal – Forma típica das funções

Densidade

Sobrevivência

Risco

Risco Acumulado

• Comportamento da função de risco:

- Crescem, atingem um valor máximo e depois decrescem

33

- Lognormal – Esperança e Variância:

$$E[T] = \exp\left\{\mu + \frac{\sigma^2}{2}\right\}$$

$$\text{Var}[T] = \exp\{2\mu + \sigma^2\} (\exp\{\sigma^2\} - 1)$$
- Função quantílica:
 $F(t_p) = p, 0 < p < 1$
 $P\{T \leq t_p\} = p$
 $\sqrt{z_p}$: 100p% percentil da normal padrão
 $P\{\ln(T) \leq \ln(t_p)\} = \Phi\left(\frac{\ln(t_p) - \mu}{\sigma}\right)$
 $t_p = \exp\{\mu + z_p \sigma\}$
- Mediana: $t_{med} = \exp\{\mu\}$
 $\sqrt{F(t_{med}) = 0,5}$

34

Lognormal – Comentários



- Muito utilizada para caracterizar tempo de vida de indivíduos
 - √ Tempo de vida de pacientes com leucemia
- $\ln(T) \sim N(\mu, \sigma^2)$
 - √ μ : média do logaritmo do tempo de sobrevivência
 - √ σ : desvio padrão do logaritmo do tempo de sobrevivência

Análise de Sobrevivência - 2017

36

Estimação dos Parâmetros dos Modelos

Estimação de Parâmetros



- Parâmetros do modelo devem ser estimados a partir das observações amostrais
 - √ Determinação do modelo para responder as perguntas de interesse

Análise de Sobrevivência - 2017

40

Métodos de Estimação



- Método de Mínimos Quadrados:
 - √ Inadequado para estudo de tempo de sobrevida
 - √ Censura não é incorporada no processo de estimação

Análise de Sobrevivência - 2017

41

- Método de Máxima Verossimilhança:
 - √ Opção apropriada para dados censurados
 - √ Incorpora a censura
 - √ Relativamente simples de ser entendido
 - √ Possui boas propriedades para grandes amostras

42

Análise de Sobrevivência - 2017

Método da Máxima Verossimilhança

- Exemplo de Motivação:
 - √ Dados oriundos de população binomial com parâmetros 10 e p_0 .
 - p_0 : constante e desconhecido
 - Função de probabilidade de X:

$$f(x; p_0) = P(X = x) = \binom{10}{x} p_0^x (1 - p_0)^{10-x}$$
 - Observa-se $X = 3$
 - √ Objetivo:
 - Basear-se no dado disponível para estimar o valor verdadeiro do parâmetro

44

Análise de Sobrevivência - 2017

- Considerando $p_0 = 1/2$. (p_0 é desconhecido)
 - √ Probabilidade de gerar o dado que realmente observamos ($X = 3$) é:

$$P(X = 3) = f(3; 0,5) = \binom{10}{3} (0,5)^3 (0,5)^7 \approx 0,117$$
- Podemos calcular esta probabilidade sob a condição que $p_0 = p$, $0 \leq p \leq 1$

$$L(p; 3) = \binom{10}{3} (p)^3 (1 - p)^7, p \in [0, 1]$$
 - √ $L(\cdot)$ é denominada função de verossimilhança.

45

Análise de Sobrevivência - 2017

Princípio da Máxima Verossimilhança

- Usamos como nossa estimativa de p_0 o valor de p que faz $L(p; 3)$ o maior possível

46

Análise de Sobrevivência - 2017

Função de Log-Verossimilhança

- A função log é crescente
 - ✓ Valor de p que maximiza $L(p; 3)$ é o mesmo que maximiza $\log L(p; 3)$
 - ✓ Em geral, é conveniente maximizar $\log L(p; 3)$ ao invés de $L(p; 3)$
 - ✓ No exemplo, a função de log-verossimilhança é definida como:

$$l(p; 3) \stackrel{\text{def}}{=} \ln L(p; 3)$$

$$= 3 \ln p + 7 \log(1 - p) + \ln \binom{10}{3}$$

47

$$l(p; 3) = 3 \ln p + 7 \ln(1 - p) + \ln \binom{10}{3}$$

48

✓ Pode-se calcular o ponto máximo da função
– ponto no domínio em que a derivada é zero

$$\hat{p} = \frac{3}{10}$$

49

- Estimativa é determinada pelo valor de X
 - ✓ Se tivéssemos observado $X = k$, teríamos a estimativa

$$\hat{p} = \frac{k}{10}$$

- No exemplo:
 - ✓ Estimador de máxima verossimilhança é:

$$\hat{p} = \frac{X}{10}$$

50

Máxima Verossimilhança – Procedimento de Estimação



- Baseado nos resultados observados, entre todas as distribuições definidas pelos possíveis valores de seus parâmetros, qual é aquela com maior probabilidade de ter gerado tal amostra?
 - √ A função de verossimilhança avalia o quanto os dados apoiam, concordam ou suportam cada valor possível do parâmetro a ser estimado

Análise de Sobrevivência - 2017

51

Função de Verossimilhança – Definição



- Suponha T uma variável aleatória com distribuição de probabilidades $f(t; \theta)$, em que θ é um único parâmetro desconhecido.
 - √ Sejam t_1, t_2, \dots, t_n os valores observados de uma certa população de interesse.
 - √ A função de verossimilhança para θ é expressa por:

$$L(\theta; t_1, t_2, \dots, t_n) = f(t_1; \theta) f(t_2; \theta) \dots f(t_n; \theta)$$

$$= \prod_{i=1}^n f(t_i, \theta)$$

Análise de Sobrevivência - 2017

52

Estimador de Máxima Verossimilhança



- O estimador de máxima verossimilhança (EMV) de θ é o valor $\hat{\theta}$ que maximiza a função de verossimilhança $L(\theta; \mathbf{t})$

$$L(\hat{\theta}; \mathbf{t}) = \max_{\theta \in \Theta} L(\theta; \mathbf{t})$$

- √ Valor de θ que maximiza a probabilidade da amostra observada ocorrer.
- √ No caso discreto, o EMV é um estimador que maximiza a probabilidade de ocorrência dos valores da amostra

Análise de Sobrevivência - 2017

53

Exemplo – Distribuição de Bernoulli



- Seja X uma variável aleatória de Bernoulli
 - √ Função de probabilidade:

$$f(x; p) = \begin{cases} p^x(1-p)^{1-x} & , x = 0, 1 \\ 0 & , \text{ caso contrário} \end{cases}$$

p é o parâmetro desconhecido a ser estimado

Análise de Sobrevivência - 2017

54

- Função de verossimilhança da amostra

$$L(p; \mathbf{x}) = p^{x_1}(1-p)^{1-x_1} p^{x_2}(1-p)^{1-x_2} \dots p^{x_n}(1-p)^{1-x_n}$$

$$= \prod_{i=1}^n p^{x_i}(1-p)^{1-x_i}$$

$$= p^{\sum_{i=1}^n x_i} (1-p)^{\sum_{i=1}^n (1-x_i)}$$

$$= p^{\sum_{i=1}^n x_i} (1-p)^{n-\sum_{i=1}^n x_i}$$

- Função de log-verossimilhança

$$l(p; \mathbf{x}) = \sum_{i=1}^n x_i \ln(p) + \left(n - \sum_{i=1}^n x_i \right) \ln(1-p)$$

55

- Estimativa de máxima verossimilhança da amostra \mathbf{x} :

$$\hat{p} = \frac{\sum_{i=1}^n x_i}{n}$$

- Estimador de máxima verossimilhança para amostras de Bernoulli

√ Proporção de sucessos na amostra

$$\hat{p} = \bar{X}$$

56

Exemplo

- Bernoulli com parâmetro p desconhecido

√ Duas amostras de $n = 20$ com $\sum_{i=1}^{20} x_i = 8$ e $\sum_{i=1}^{20} x_i = 11$

Pontos de máxima verossimilhança correspondentes à proporção de sucessos de cada amostra

$$\hat{p}_1 = \frac{8}{20} = 0,40$$

$$\hat{p}_2 = \frac{11}{20} = 0,55$$

57


√ Duas amostras de $n = 40$ com $\sum_{i=1}^{20} x_i = 16$ e $\sum_{i=1}^{20} x_i = 22$

Pontos de máxima verossimilhança correspondentes à proporção de sucessos de cada amostra

$$\hat{p}_1 = \frac{16}{40} = 0,40$$

$$\hat{p}_2 = \frac{22}{40} = 0,55$$

58



Exemplo

- Amostra para estimar prevalência de hipertensão
 - √ 10% dos indivíduos da amostra são hipertensos
 - √ É muita baixa a plausibilidade de a proporção de hipertensos na população ser 90%
 - √ Quanto mais próximo de 10% maior a verossimilhança
 - Máxima verossimilhança

Análise de Sobrevivência - 2017

Função de Verossimilhança

- Dados não censurados:
 - √ Contribuição de cada observação:
 - Função de densidade de probabilidade
 - √ Função de verossimilhança:

$$L(\theta; t_1, t_2, \dots, t_n) \propto \prod_{i \in O} f(t_i, \theta)$$

O: conjunto das observações de desfecho

Análise de Sobrevivência - 2017

- Dados censurados à direita:
 - √ Contribuição de cada observação:
 - Informa que o tempo de sobrevivência é maior que o tempo observado
 - Contribuição para $L(\theta)$ é sua função de sobrevivência (não é sua função de densidade!)
 - √ Função de verossimilhança:

$$L(\theta) \propto \prod_{i \in O} f(t_i, \theta) \prod_{i \in D} S(t_i, \theta)$$

O: conjunto das observações de desfecho
D: conjunto das observações que sofreram censura à direita

Análise de Sobrevivência - 2017

- Dados censurados à esquerda:
 - √ Contribuição de cada observação:
 - Sabemos somente que o tempo de sobrevivência é menor que o tempo observado
 - Contribuição para $L(\theta)$ é sua função de distribuição acumulada:

$$F(t; \theta) = 1 - S(t; \theta)$$
 - √ Função de verossimilhança:

$$L(\theta) \propto \prod_{i \in O} f(t_i, \theta) \prod_{i \in D} S(t_i, \theta) \prod_{i \in E} [1 - S(t_i; \theta)]$$
 - O : conjunto das observações de desfecho
 - E : conjunto observações com censura à esquerda
 - D : conjunto das observações com censura à direita

65

- Dados com censura intervalar:
 - √ Contribuição de cada observação:
 - Sabemos que o tempo de sobrevivência está dentro de um intervalo entre t^- e t^+ .
 - Contribuição para $L(\theta)$ é a probabilidade de ocorrência de desfecho nesse intervalo de tempo:

$$S(t^-; \theta) - S(t^+; \theta)$$
 - √ Função de verossimilhança:

$$L(\theta) \propto \prod_{i \in O} f(t_i, \theta) \prod_{i \in D} S(t_i, \theta) \prod_{i \in E} [1 - S(t_i; \theta)] \prod_{i \in I} [S(t_i^-; \theta) - (t_i^+; \theta)]$$
 - O : conjunto das observações de desfecho
 - D : conjunto das observações com censura à direita
 - E : conjunto observações com censura à esquerda
 - I : conjunto das observações com censura intervalar

66

Truncamentos

- São usadas probabilidades condicionais na construção da verossimilhança
 - √ Probabilidade de observação de um evento está condicionada à probabilidade do indivíduo ser incluído no estudo
 - Probabilidade de inclusão no estudo de indivíduos com tempo de sobrevivência muito pequeno é menor do que a de indivíduos com tempo de sobrevivência grande
- Janela temporal do estudo:
 - √ (t_E, t_D)

67

- Truncamentos à esquerda:
 - √ Probabilidade de o evento ocorrer condicionado ao fato de o indivíduo ter sobrevivido ao estudo
 - √ Contribuição de indivíduo para a verossimilhança é ponderada pela sobrevivência no início do estudo

$$\frac{f(t)}{S(t_E)}$$

68

- Truncamentos à direita:
 - √ Contribuição individual para a verossimilhança é ponderada pela probabilidade acumulada de ocorrência do evento

$$\frac{f(t_i)}{1 - S(t_i)}$$

69

Estimadores de Máxima Verossimilhança – Dados Censurados

- Forma geral da verossimilhança
 - √ considerados os mecanismos de censura à direita: $L(\theta) = \prod_{i \in O} f(t_i, \theta) \prod_{i \in D} S(t_i, \theta)$
 - √ ou $L(\theta) = \prod_{i=1}^n [f(t_i, \theta)]^{\delta_i} [S(t_i, \theta)]^{1-\delta_i}$
 - √ Estimadores de máxima verossimilhança são os valores de θ que maximizam $L(\theta)$ ou, equivalentemente, $l(\theta) = \ln(L(\theta))$.

70

- √ Estimadores de máxima verossimilhança são encontrados resolvendo-se o sistema de equações

$$U(\theta) = \frac{\partial \ln(\theta)}{\partial \theta} = \frac{\partial l(\theta)}{\partial \theta} = 0$$
- √ A função de verossimilhança pode também ser expressa em termos da função de risco:

$$L(\theta) = \prod_{i=1}^n [\lambda(t_i, \theta)]^{\delta_i} S(t_i, \theta)$$

71

Distribuição Exponencial

- √ Suponha uma amostra de n itens de uma população exponencial, em que $r \leq n$ são desfechos e os demais ($r - n$) são censuras

$$\begin{aligned} L(\alpha) &= \prod_{i=1}^n [f(t_i, \alpha)]^{\delta_i} [S(t_i, \alpha)]^{1-\delta_i} \\ &= \prod_{i=1}^n [\alpha \exp\{-\alpha t_i\}]^{\delta_i} [\exp\{-\alpha t_i\}]^{1-\delta_i} \\ &= \prod_{i=1}^n (\alpha)^{\delta_i} \exp\{-\alpha t_i\} \\ &= \alpha^{\sum_{i=1}^n \delta_i} \exp\{-\alpha \sum_{i=1}^n t_i\} \end{aligned}$$

72

√ Função da log-verossimilhança:

$$l(\alpha) = \ln \left(\alpha^{\sum_{i=1}^n \delta_i} \exp\{-\alpha \sum_{i=1}^n t_i\} \right)$$

$$= \sum_{i=1}^n \delta_i \ln(\alpha) - \alpha \sum_{i=1}^n t_i$$

√ Estimador de máxima verossimilhança:

$$\frac{\partial l(\alpha)}{\partial \alpha} = \frac{\sum_{i=1}^n \delta_i}{\alpha} - \sum_{i=1}^n t_i \quad \frac{\partial l(\alpha)}{\partial \alpha} = 0 \Rightarrow \hat{\alpha} = \frac{r}{\sum_{i=1}^n t_i}$$

$$= \frac{r}{\alpha} - \sum_{i=1}^n t_i \quad \hat{\alpha} = \frac{\text{total desfechos}}{\text{tempo total sob teste}}$$

Se não houver censuras $\hat{\alpha} = \frac{n}{\sum_{i=1}^n t_i} = \frac{1}{\bar{x}}$

Análise de Sobrevivência - 2017 73

Exemplo

- Sobrevivência ao diagnóstico de Aids
 - √ Pacientes com tempo de observação menor que 90 dias
 - Óbitos: 15
 - Censuras: 6
 - √ Suposição:
 - Tempo entre diagnóstico de Aids e a morte segue uma distribuição exponencial

Análise de Sobrevivência - 2017 74

- Estimação do parâmetro α da exponencial:

$$\hat{\alpha} = \frac{\text{total de desfechos}}{\sum_{i=1}^n t_i} = \frac{15}{1012} = 0,0148$$
 - √ Taxa de mortalidade por pessoa-tempo
 - 0,015 morte por pessoa-mês
 - 17,8 mortes por 100 pessoas/ano
- Tempo médio de sobrevivência:

$$\hat{E}[T] = \frac{1}{\hat{\alpha}} = 67,5 \text{ meses}$$

Análise de Sobrevivência - 2017 75

- Função de Sobrevivência estimada


$$\hat{S}_e(t) = \exp\{-\hat{\alpha}t\} = \exp\{0,0148t\}$$
- Estimativa da probabilidade de um paciente estar vivo depois de 16 dias do diagnóstico de Aids
 - √ Paramétrica – Exponencial:

$$\hat{S}_e(16) = \exp\{-(0,0148)(16)\} = 0,7891$$
 - √ Não Paramétrica – Kaplan-Meier

$$\hat{S}_{KM}(16) = 0,9524$$
 - √ As estimativas são bastante diferentes
 - A suposição de distribuição exponencial é adequada aos dados?

Análise de Sobrevivência - 2017 76

• Estimativas paramétrica e não paramétrica



- Exponencial está afastada dos dados?
 - Ela é adequada à situação? Risco constante?
- As distribuições de Weibull ou Lognormal seriam mais próximas dos dados?
 - Como estimar seus parâmetros?
- O risco é constante?

Análise de Sobrevivência - 2017 77

Modelos Paramétricos de Sobrevivência

- Parametrização dos modelos no R
 - Exponencial:
 - Parâmetro α : $\alpha = \exp\{-\text{Intercept}\}$
 - Weibull:
 - Parâmetro α : $\alpha = \exp\{-\text{Intercept}\}$
 - Parâmetro γ : $\hat{\gamma} = \frac{1}{\text{scale}}$

Análise de Sobrevivência - 2017 78

Modelos Paramétricos de Regressão

- Parametrização dos modelos Weibull no R:
 - Na presença de covariáveis, os parâmetros de regressão β ficam com o sinal inverso ao que aparece na saída do pacote

Análise de Sobrevivência - 2017 79

Modelo Exponencial:

```
# Exponencial
>>
> sobreviv.e<-survreg(Surv(tempo, status)~1,data = ipec90, dist='exponential')
> sobreviv.e
```

Saída:

```
> sobreviv.e
Call:
survreg(formula = Surv(tempo, status) ~ 1, data = ipec90, dist = "exponential")
Coefficients:
(Intercept)
 4.211634
Scale fixed at 1
Loglik(model)= -78.2 Loglik(intercept only)= -78.2
n= 21
```

Estimação parâmetro:

```
> alfa.exp<-exp(-sobrev.e$coefficients[1]) #(na forma alpha tau)
> alfa.exp
(Intercept)
0.01482213
```

Sobrevivência estimada: $\hat{S}_e(t) = \exp\{-0,01482 t\}$

Análise de Sobrevivência - 2017 80

Outras Distribuições

- Tempos de sobrevivência com distribuição de Weibull ou Lognormal:
 - √ Construção da verossimilhança é feita da mesma forma
 - (substitui-se funções de densidade e sobrevivência)
 - √ Equações não podem ser resolvidas analiticamente
 - √ Necessário utilizar métodos iterativos de solução
 - Por exemplo, método de Newton-Raphson

83

√ Modelo Weibull:

```
# Weibull
> sobrev.w<-survreg(Surv(tempo, status)~1,data = ipec90, dist='weibull')
> sobrev.w
```

√ Saída:

```
> sobrev.w<-survreg(Surv(tempo, status)~1,data = ipec90, dist='weibull')
> sobrev.w
Call:
survreg(formula = Surv(tempo, status) ~ 1, data = ipec90, dist = "weibull")
Coefficients:
(Intercept)
 4.157605
Scale= 0.5156146
Loglik(model)= -74.4 Loglik(intercept only)= -74.4
n= 21
```

√ Estimação parâmetro:

```
> alfa.weib<-exp(-sobre.w$coefficients[1])
> gama.weib<-1/sobre.w$scale
> cbind(gama.weib, alfa.weib)
      gama.weib  alfa.weib
(Intercept)  1.939433  0.01564499
```

√ Sobrevivência estimada: $\hat{S}_w(t) = \exp\{- (0,01564 t)^{1,9394}\}$

84

√ Modelo Log-normal:

```
# Lognormal
> sobrev.ln <- survreg(Surv(tempo, status)~1,data = ipec90, dist='lognorm')
> sobrev.ln
```

√ Saída:

```
> sobrev.ln
Call:
survreg(formula = Surv(tempo, status) ~ 1, data = ipec90, dist = "lognorm")
Coefficients:
(Intercept)
 3.893372
Scale= 0.6425924
Loglik(model)= -73.8 Loglik(intercept only)= -73.8
n= 21
```

√ Estimação parâmetro:

```
> mi.ln <- sobrev.ln$coefficients[1]
> sigma.ln <- sobrev.ln$scale
> cbind(mi.ln, sigma.ln)
      mi.ln  sigma.ln
(Intercept) 3.893372 0.6425924
```

√ Sobrevivência estimada: $\hat{S}_{ln}(t) = \Phi\left[\frac{-\ln(t)-3,8934}{0,6426}\right]$

85

• Curva de Sobrevivência

√ Estimativas paramétricas e não paramétrica

- Exponencial está afastada dos dados
- Weibull e Lognormal estão mais próximas
 - Weibull se afasta para tempos de sobrevivência mais longos

86

• **Função de Risco**
 √ Modelos Weibull e Lognormal

Qual das funções de risco representam o problema mais adequadamente?
 Que critérios adotar para escolher o modelo?

Análise de Sobrevivência - 2017 87

Intervalos de Confiança e Testes de Hipóteses

Intervalos de Confiança

- Construção de intervalos de confiança para parâmetros e quantidades de interesse
 - √ Método de máxima verossimilhança.
- Distribuição assintótica do EMV $\hat{\theta}$:
 - √ Para grandes amostras:

$$\hat{\theta}^{as} \sim N(\theta, \text{Var}(\hat{\theta}))$$
 - √ $\hat{\text{Var}}(\hat{\theta})$: variância de $\hat{\theta}$:
 - Em geral, depende de θ .

Análise de Sobrevivência - 2017 89

√ Intervalo aproximado de $(1 - \alpha)100\%$ de confiança para θ :

$$\hat{\theta} \pm z_{\alpha/2} \text{ep}(\hat{\theta})$$

- $\text{ep}(\hat{\theta})$: erro padrão de $\hat{\theta}$:

Análise de Sobrevivência - 2017 91

Testes de Hipóteses



- Seja um modelo com vetor de parâmetros

$$\theta = (\theta_1, \theta_2, \dots, \theta_p)'$$
 - √ Deseja-se testar hipóteses relacionadas a este vetor ou a algum de seus subconjuntos
- Testes utilizados:
 - √ Teste da Razão de Verossimilhanças
 - √ Teste de Wald
 - √ Teste Escore

Análise de Sobrevivência - 2017

94

Teste da Razão de Verossimilhanças



- Compara os valores da log-verossimilhança maximizada sem restrição e sob H_0
 - √ Hipótese:
 - $H_0: \theta = \theta_0$.
 - √ Estatística de teste:
$$RV = 2 \ln \left[\frac{L(\hat{\theta}_0)}{L(\hat{\theta})} \right] = 2 \left[\ln L(\hat{\theta}) - L(\hat{\theta}_0) \right]$$

$$= 2[l(\hat{\theta}) - l(\hat{\theta}_0)]$$
 - √ Distribuição amostral: $RV \stackrel{as.}{\sim} \chi_{gl}^2$
 - gl: diferença entre o número de parâmetros não especificados em H_0 e H_1

Análise de Sobrevivência - 2017

95

Teste de Wald



- Baseado na distribuição assintótica de θ :
 - √ Em geral, usado para testar hipóteses relativas a um único parâmetro θ_j .
 - √ Hipótese:
 - $H_0: \theta = \theta_0$.
 - √ Estatística de teste:
$$W = \frac{(\hat{\theta} - \theta_0)^2}{\text{Var}(\hat{\theta})} \stackrel{as.}{\sim} \chi_1^2$$
 - ou, equivalentemente
$$\frac{\hat{\theta} - \theta_0}{\text{ep}(\hat{\theta})} \stackrel{as.}{\sim} N(0, 1)$$

Análise de Sobrevivência - 2017

96

Escolha do Modelo

Escolha do Modelo Probabilístico



- Especificação do modelo
 - √ É de extrema importância na análise paramétrica de dados de tempo de sobrevivência
- Em muitas situações:
 - √ Não há evidências de testes anteriores de que um modelo se ajusta bem aos dados
 - √ Solução para essas situações é basicamente empírica

Análise de Sobrevivência - 2017

100

Proposta empírica:



- √ Ajustar modelos probabilísticos
 - Comparação entre valores estimados e observados para decidir qual deles “melhor explica os dados amostrais”
- √ Técnicas gráficas:
 - Forma simples e eficiente para selecionar o “melhor” modelo para ser usado por um conjunto de dados
 - Ferramenta exploratória para escolha de distribuições candidatas
- √ Teste de hipóteses:
 - Pode ser usado teste de hipóteses para modelos encaixados

Análise de Sobrevivência - 2017

101

Métodos Gráficos



1. Comparação do modelo proposto com o estimador de Kaplan-Meier:
 - √ Ajuste do modelo proposto aos dados
 - √ Obtenção da estimativa de Kaplan-Meier
 - √ Comparação gráfica da função de sobrevivência do modelo paramétrico
 - √ Quanto mais próximo o modelo paramétrico estiver da curva do Kaplan-Meier, melhor o modelo


Análise de Sobrevivência - 2017

102

Comparação das curvas de sobrevivência




- √ Estimativas paramétricas e não paramétrica



- Exponencial está afastada dos dados
- Weibull e Lognormal estão mais próximas
 - Weibull se afasta para tempos de sobrevivência mais longos

Análise de Sobrevivência - 2017

103



- Comentários:
 - √ Modelo exponencial parece não ser adequado aos dados:
(Curva encontra-se um tanto afastada da reta $y = x$)
 - √ Modelo de Weibull ou log-normal possivelmente é adequado aos dados
(acompanham mais de perto a reta $y = x$)
- Análise de Sobrevivência - 2017

- Comparação do modelo proposto com o estimador de Nelson-Aalen:
 - √ Ajuste do modelo proposto aos dados
 - √ Obtenção da estimativa de Nelson-Aalen para a função de risco acumulado
 - √ Comparação gráfica das funções de sobrevivência ou de risco acumulado obtidas
 - √ Gráficos envolvendo função de sobrevivência ou a função de risco acumulado são úteis para discriminar modelos
- Análise de Sobrevivência - 2017

- Função de risco acumulado:
- $$\Lambda(t) = -\ln[S(t)]$$
- √ Modelo exponencial:
$$\hat{\Lambda}(t) = \hat{\alpha}t$$
 - √ Modelo de Weibull:
$$\hat{\Lambda}(t) = (\hat{\alpha}t)^{\hat{\gamma}}$$
 - √ Modelo Lognormal:
$$\hat{\Lambda}(t) = -\ln \left[\Phi \left(\frac{-\ln(t) + \hat{\mu}}{\hat{\sigma}} \right) \right]$$
- Análise de Sobrevivência - 2017

2. Linearização da função de sobrevivência:

√ Ideia básica:

- Construção de gráficos que sejam aproximadamente lineares caso o modelo proposto seja apropriado
- Violações da linearidade podem ser verificadas visualmente

√ Utiliza-se gráfico de transformação de linearização

• Linearização do modelo exponencial

$$S(t) = \exp\{-\alpha t\}$$

$$-\ln[S(t)] = \alpha t$$

√ Gráfico de $-\ln[\hat{S}_{KM}]$ vs. tempo deve ser aproximadamente linear se o modelo for adequado

• Linearização do modelo de Weibull

$$S(t) = \exp\{-(\alpha t)^\gamma\}$$

$$-\ln S(t) = (\alpha t)^\gamma$$

$$\ln[-\ln[S(t)]] = \gamma \ln(\alpha) + \gamma \ln(t)$$

√ gráfico de $\ln[-\ln[\hat{S}_{KM}]]$ vs. tempo deve ser aproximadamente linear, se o modelo for adequado

√ Indicação a favor do modelo exponencial

- Se além de linear o gráfico passar pela origem e tiver inclinação igual a 1.

• Linearização do modelo Lognormal


$$S(t) = \Phi\left(\frac{-\ln(t) + \mu}{\sigma}\right)$$

$$\Phi^{-1}[S(t)] = \frac{-\ln(t) + \mu}{\sigma}$$

√ gráfico de $\Phi^{-1}[\hat{S}_{KM}]$ vs. $\ln(\text{tempo})$ deve ser aproximadamente linear, se o modelo for adequado

- Intercepto: μ/σ
- Inclinação: $1/\sigma$

- Gráficos linearizados da sobrevivência
 - √ Modelos exponencial, Weibull e lognormal



Análise de Sobrevivência - 2017

113

- Comentários:

- √ Modelos de Weibull e Log-normal não mostram afastamentos marcantes de uma reta
- √ Observa-se desvio para modelo Exponencial
- √ Não há discriminação entre os modelos de Weibull e Lognormal
 - Principal razão pode ser tamanho amostral pequeno

Análise de Sobrevivência - 2017

114

Análise Gráfica – Comentários

- Avaliação da qualidade de ajuste do modelo
 - √ Análises gráficas são mais indicadas que testes formais de qualidade global de ajuste
 - √ Testes formais
 - Para amostras pequenas: tendem a ter baixo poder
 - Para amostras grandes: tendem a rejeitar o modelo
 - √ Se nenhum desses modelos for adequado
 - Podem ser necessários modelos mais flexíveis envolvendo mais de dois parâmetros
 - Ex.: gama generalizada

Análise de Sobrevivência - 2017

115

- Usar métodos gráficos para descartar modelos claramente inadequados

- √ Gráficos não discriminam modelos, mas indicam que eles são igualmente bons
 - Tamanho amostral pequeno ou pequena quantidade de desfechos
- √ Ajustes razoáveis de diferentes modelos para o mesmo conjunto de dados
 - Em especial, nos intervalos de tempo que concentram maior número de observações
 - Apresentam resultados semelhantes das quantidade de interesse

Análise de Sobrevivência - 2017

116

- √ Presença de componente subjetivo na interpretação de técnicas gráficas
 - Conclusões podem diferir para diferentes analistas
- Análise de resíduos é mais adequada para demonstrar que um modelo paramétrico é melhor



117

Análise de Sobrevivência - 2017

Comparação de Modelos – Teste de Hipóteses



Outra maneira de discriminar modelos

- √ Hipóteses
 - H_0 : modelo de interesse é adequado
 - H_1 : modelo de interesse não é adequado
- Comparação de modelos encaixados:
 - √ Modelo com maior número de parâmetros contém todos os parâmetros do modelo menor
 - √ Identificar um modelo generalizado tal que modelo de interesse seja seu caso particular

118

Análise de Sobrevivência - 2017

- Ajustes para realizar o teste:
 - √ Obtenção da log-verossimilhança do modelo generalizado (modelo maior):

$$l(\theta_G) = \ln[L(\theta_G)]$$
 - √ Obtenção da log-verossimilhança do modelo de interesse (modelo menor):

$$l(\theta_M) = \ln[L(\theta_M)]$$
- Estatística de teste:
 - √ Razão de verossimilhanças: $RV = 2 \left[l(\hat{\theta}_G) - l(\hat{\theta}_M) \right]$
 - √ Distribuição amostral:

$$RV \sim \chi_{gl}^2$$
 - gl: diferença entre quantidade de parâmetros dos dois modelos



119

Análise de Sobrevivência - 2017

- Comparação modelos
 - √ Weibull (maior) vs. Exponencial(menor)
 - √ Logaritmos da verossimilhança:


```
> sobrev.e$loglik[2]
[1] -78.1745
> sobrev.w$loglik[2]
[1] -74.39242
```
 - √ Razão de Verossimilhanças:

$$RV = 2 \left[l(\hat{\theta}_G) - l(\hat{\theta}_M) \right] = 2[78,1745 - 74,3942] = 7,5642$$
 - √ p-valor: $P \{ \chi_1^2 > 7,5642 \} = 0,0059$

```
> 1 - pchisq(7.5642, 1)
[1] 0.005953908
```

 - Rejeita-se H_0 : modelo exponencial é adequado
- Condução do teste – comando **anova**:


```
> anova(sobrev.e, sobrev.w)
Terms Resid. Df  -2*LL Test Df Deviance Pr(>Chi)
1      1      20 156.3490    NA      NA      NA
2      1      19 148.7848    =    7.564177 0.005953983
```
- √ Resultado indica inadequação do modelo exponencial



120

Análise de Sobrevivência - 2017

- No contexto de Análise de Sobrevivência, teste da razão de verossimilhanças é em geral utilizado com a distribuição gama generalizada.
 - √ Apresenta os modelos exponencial, de Weibull, lognormal e gama como modelos encaixados
- Para ajuste do modelo gama generalizado:


```
> library(flexsurv)
> flexsurvreg(formula, data,
               dist='gengamma')
```

121

- No exemplo:
 - √ Ajuste do modelo gama generalizado (3 parâmetros)

```
> library(flexsurv)
> sobrev.gama<-flexsurvreg(Surv(tempo, status)~1,data = ipec90,dist='gengamma')
> sobrev.gama
Call:
flexsurvreg(formula = Surv(tempo, status) ~ 1, data = ipec90, dist = "gengamma")
Estimates:
      est      L95%      U95%      se
mu      3.802    3.055    4.548    0.381
sigma   0.656    0.453    0.950    0.124
Q       -0.318   -2.642    2.006    1.186
N = 21, Events: 15, Censored: 6
Total time at risk: 1012
Log-likelihood = -73.8024, df = 3
AIC = 153.6048
```

122

- Logaritmos das verossimilhanças:


```
> sobrev.gama$loglik
[1] -73.8024
> sobrev.e$loglik[2]
[1] -78.1745
> sobrev.w$loglik[2]
[1] -74.39242
> sobrev.ln$loglik[2]
[1] -73.89893
```
- Teste da Razão das Verossimilhanças

	I(θ)	Razão	GL	p-valor
Gama generalizada	-73,80			
Exponencial	-78,17	2(78,17-73,80)=8,74	2	0,013
Weibull	-74,39	2(74,39-73,80)=1,18	1	0,277
Log-normal	-73,84	2(73,84-73,80)=0,08	1	0,777

 - √ Resultados indicam adequação dos modelos de Weibull e Log-normal

123

- Importante:
 - √ No R, a função **anova** não funciona com objeto **flexsurvreg**

124

AIC – Akaike Information Criterion

- Medida de qualidade relativa de um modelo estatístico para um conjunto de dados
 - √ Estimativa da informação perdida ao se usar um modelo para representar o processo de geração dos dados
 - √ Considera o ‘trade-off’ entre a bondade do ajuste e a complexidade do modelo
 - √ Não informa nada no sentido absoluto
 - O AIC não informa nada se todos os modelos candidatos não se ajustarem bem aos dados

Análise de Sobrevivência - 2017

125

- Critério de Informação de Akaike: 

$$AIC = 2 \left[p - l(\hat{\theta}_M) \right]$$

√ Correção para amostras finitas

$$AIC_c = AIC + \frac{2p(p+1)}{n-p-1}$$

√ Decisão:

– Prefere-se o modelo com o menor valor de AIC

√ No exemplo

Modelo	$l(\theta)$	AIC
Gama generalizada	-73,80	$2[3 - (-73,80)] = 153,6$
Exponencial	-78,17	$2[1 - (-78,17)] = 158,3$
Weibull	-74,39	$2[2 - (-74,39)] = 152,8$
Log-normal	-73,84	$2[2 - (-73,84)] = 151,7$

Análise de Sobrevivência - 2017

126

- Comentários: 

- √ Recomenda-se usar o AIC para selecionar modelos quando o número de observações (n) é maior que pelo menos 40 vezes o número de parâmetros (p)
 - (Burham e Anderson, 2002)
- √ O AICc é recomendado para pequenas amostras e respostas com distribuição normal
 - Aumenta consideravelmente a probabilidade de escolha do modelo adequado. (Davison, 2001)
 - Deve-se considerar arriscado usar para distribuições não normais um critério que foi desenvolvido para distribuição normal

Análise de Sobrevivência - 2017

127

Exemplo de Aplicação

Modelos Paramétricos de Sobrevida



- Parametrização dos modelos no R

- √ Exponencial:

- Parâmetro $\alpha = \exp\{-\text{Intercept}\}$

- √ Weibull:

- Parâmetro $\alpha = \exp\{-\text{Intercept}\}$

- Parâmetro $\hat{\gamma} = \frac{1}{\text{scale}}$

Análise de Sobrevida - 2017

129

Exemplo



- Pacientes com câncer de bexiga

- √ Tempo de reincidência de pacientes com câncer de bexiga submetidos a procedimento cirúrgico com laser

- √ 20 pacientes

- √ Modelos analisados:

- Exponencial

- Weibull

- Log-normal

Análise de Sobrevida - 2017

130

- Tempo (em meses):

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



Análise de Sobrevida - 2017

131

- Carregamento dos dados:



```
> library(survival)
> library(flexsurv)
>
> # Exemplo 3.1 - Câncer de Bexiga
>
> tempos <- c(3, 5, 6, 7, 8, 9, 10, 10, 12, 15, 15, 18, 19, 20, 22, 25, 28, 30,
+ 40, 45)
> cens <- c(1, 1, 1, 1, 1, 1, 1, 0, 1, 1, 0, 1, 1, 1, 1, 1, 1, 1, 1, 0)
> sobrevida.cancer <- Surv(tempos, cens)
> class(sobrevida.cancer)
>
[1] "Surv"
> str(sobrevida.cancer)
Surv [1:20, 1:2] 3 5 6 7 8 9 10 10+ 12 15 ...
- attr(*, "dimnames")=List of 2
..$ : NULL
..$ : chr [1:2] "time" "status"
- attr(*, "type")= chr "right"
```

Análise de Sobrevida - 2017

132

• Estimativas de máxima verossimilhança: 

√ Modelo exponencial:

```
> (ajuste.e <- survreg(sobrevida.cancer ~ 1, dist = 'exponential'))
Call:
survreg(formula = sobrevida.cancer ~ 1, dist = "exponential")
```

Coefficients:
(Intercept)
3.016111

Scale fixed at 1

Loglik(model)= -68.3 Loglik(intercept only)= -68.3
n= 20

√ Estimativa parâmetro:

```
> (alfa.exp <- exp(-ajuste.e$coefficients[1]))
(Intercept)
0.04899135
```

$$\hat{\alpha} = \exp\{-\hat{\beta}_0\}$$

$$= \exp\{-3,016111\}$$

$$= 0,04899135$$

√ Sobrevivência estimada: $\hat{S}_e(t) = \exp\{-0,04899t\}$

Análise de Sobrevivência - 2017 133

• Estimativas de máxima verossimilhança: 

√ Modelo Weibull:

```
> (ajuste.w <- survreg(sobrevida.cancer ~ 1, dist = 'weibull'))
Call:
survreg(formula = sobrevida.cancer ~ 1, dist = "weibull")
```

Coefficients:
(Intercept)
3.060529

Scale= 0.647922

Loglik(model)= -66.1 Loglik(intercept only)= -66.1
n= 20

√ Estimativa parâmetro:

```
> # estimativa dos parâmetros
> alfa.weib <- exp(-ajuste.w$coefficients[1])
> gama.weib <- 1/ajuste.w$scale
> cbind(alfa.weib, gama.weib)
      alfa.weib gama.weib
(Intercept) 0.04686288  1.543396
```

$$\hat{\alpha} = \exp\{-\beta_0\}$$

$$= \exp\{-3,060529\}$$

$$= 0,04686288$$

$$\hat{\gamma} = 1/\hat{\sigma}$$

$$= 1/0,647922$$

$$= 1,543396$$

Análise de Sobrevivência - 2017 134

√ Sobrevivência estimada: 

$$\hat{S}_w(t) = \exp\{-(0,04686t)^{1,5433}\}$$

Análise de Sobrevivência - 2017 135

• Estimativas de máxima verossimilhança: 

√ Modelo Lognormal:

```
> (ajuste.ln <- survreg(sobrevida.cancer ~ 1, dist = 'lognorm'))
Call:
survreg(formula = sobrevida.cancer ~ 1, dist = "lognorm")
```

Coefficients:
(Intercept)
2.717176

Scale= 0.7648167

Loglik(model)= -65.7 Loglik(intercept only)= -65.7
n= 20

√ Estimativa parâmetro:

```
> # estimativa dos parâmetros
> mi.ln <- ajuste.ln$coefficients[1]
> sigma.ln <- ajuste.ln$scale
> cbind(mi.ln, sigma.ln)
      mi.ln sigma.ln
(Intercept) 2.717176 0.7648167
```

$$\hat{\mu} = 2,717176$$

$$\hat{\sigma} = 0,7648167$$

Análise de Sobrevivência - 2017 136

√ Sobrevida estimada:

$$\hat{S}_{ln}(t) = \Phi \left[\frac{-\ln(t) - 2,7172}{0,7648} \right]$$


Análise de Sobrevida - 2017 137

- Estimativas da função de sobrevivência:
 - √ Modelo exponencial: $\hat{S}_e(t) = \exp\{-0,04899t\}$
 - √ Modelo de Weibull: $\hat{S}_w(t) = \exp\{-(0,04686t)^{1,5433}\}$
 - √ Modelo Log-normal: $\hat{S}_{ln}(t) = \Phi \left[\frac{-\ln(t) - 2,7172}{0,7648} \right]$
- Valores estimados para $t = 10$:
 - √ Exponencial: $\hat{S}_e(t) = \exp\{-(0,04899)(10)\} = 0,612$
 - √ Weibull: $\hat{S}_w(t) = \exp\{-(0,04686 \times 10)^{1,5433}\} = 0,732$
 - √ Log-normal: $\hat{S}_{ln}(t) = \Phi \left[\frac{-\ln(10) - 2,7172}{0,7648} \right] = 0,708$

√ São bem próximas as estimativas obtidas pelos modelos de Weibull e Log-normal



Análise de Sobrevida - 2017 138

- Estimativas da função de sobrevivência:
 - √ Modelo exponencial: $\hat{S}_e(t) = \exp\{-0,04899t\}$
 - √ Modelo de Weibull: $\hat{S}_w(t) = \exp\{-(0,04686t)^{1,5433}\}$
 - √ Modelo Log-normal: $\hat{S}_{ln}(t) = \Phi \left[\frac{-\ln(t) - 2,7172}{0,7648} \right]$
- Valores estimados para $t = 10$:
 - √ Exponencial: $\hat{S}_e(t) = \exp\{-(0,04899)(10)\} = 0,612$
 - √ Weibull: $\hat{S}_w(t) = \exp\{-(0,04686 \times 10)^{1,5433}\} = 0,732$
 - √ Log-normal: $\hat{S}_{ln}(t) = \Phi \left[\frac{-\ln(10) - 2,7172}{0,7648} \right] = 0,708$

√ São bem próximas as estimativas obtidas pelos modelos de Weibull e Log-normal



Análise de Sobrevida - 2017 139

- Comparação das estimativas da sobrevivência para os tempos de reincidência:
 - √ Estimador Kaplan-Meier e função de sobrevivência dos modelos exponencial, Weibull e log-normal



Análise de Sobrevida - 2017 140

• Comparação das sobrevivências:

```
> # estimativa de Kaplan-Meier
> e.km <- survfit(sobrevida.cancer-1)
> tempo.km <- e.km$time
> s.km <- e.km$surv
> # estimativas modelos paramétricos
> s.e <- exp(-alfa.exp*tempo.km)
> s.w <- exp(-(alfa.weib*tempo.km)^gama.weib)
> s.ln <- pnorm((-log(tempo.km)+ mi.ln)/sigma.ln)
> # comparação das estimativas
> cbind(tempo.km,s.km,s.e,s.w,s.ln)
tempo.km      s.km      s.e      s.w      s.ln
[1,]          3 0.95000000 0.8633164 0.95274148 0.98283934
[2,]          5 0.90000000 0.7827384 0.89897484 0.92624322
[3,]          6 0.85000000 0.7453152 0.86839357 0.88685752
[4,]          7 0.80000000 0.7096812 0.83609525 0.84337638
[5,]          8 0.75000000 0.6757509 0.80253272 0.79781416
[6,]          9 0.70000000 0.6434428 0.76809812 0.75169629
[7,]         10 0.65000000 0.6126794 0.73313414 0.70611769
[8,]         12 0.59583333 0.5554947 0.66278292 0.61931883
[9,]         15 0.54166667 0.4795676 0.55966698 0.50475984
[10,]        18 0.48148148 0.4140186 0.46346069 0.41042396
[11,]        19 0.42129630 0.3942241 0.43345774 0.3831769
```


√ Estimativas Weibull e lognormal bem próximas

• Escolha do modelo – Método Gráfico:

√ Gráfico das estimativas da sobrevivência obtidas pelo estimador de Kaplan-Meier vs. estimativas das sobrevivências a partir dos modelos paramétricos

```
> par(mfrow=c(1,3))
> # Exponencial
> plot(s.km, s.e, pch = 16, ylim = range(c(0.0, 1)), xlim = range(c(0, 1)),
+ xlab = "S(t): Kaplan-Meier", ylab="S(t): exponencial")
> abline(0, 1, lty = 1)
> # Weibull
> plot(s.km, s.w, pch = 16, ylim = range(c(0.0, 1)), xlim = range(c(0, 1)),
+ xlab = "S(t): Kaplan-Meier", ylab="S(t): Weibull")
> abline(0, 1, lty = 1)
> # Log-normal
> plot(s.km, s.ln, pch = 16, ylim = range(c(0.0, 1)), xlim = range(c(0, 1)),
+ xlab = "S(t): Kaplan-Meier", ylab = "S(t): log-normal")
> abline(0, 1, lty = 1)
```

• Comparação gráfica: KM vs. modelos



- Modelo exponencial parece não ser adequado aos dados
 - √ Curva afastada da reta
- Modelos Weibull e lognormal mais próximos da reta
 - √ acompanham mais de perto a reta $y = x$
 - √ Indicação de que um desses modelos possa ser adequado aos dados

• Gráficos linearizados dos modelos

√ Comandos

```
> par(mfrow=c(1,3))
> inv.km <- qnorm(s.km)
> plot(tempo.km, -log(s.km), pch=16, xlab="tempos", ylab="-log(S(t))")
> plot(log(tempo.km), log(-log(s.km)), pch=16, xlab="log(tempos)", ylab="log(-log(S(t)))")
> plot(log(tempo.km), inv.km, pch=16, xlab="log(tempos)", ylab=expression(Phi^-1 * (S(t))))
> par(mfrow = c(1, 1))
```

- Gráficos linearizados dos modelos

- Modelos exponencial e Weibull não se afastam da reta de forma marcante
 - Exponencial apresenta desvio
- Resultados anteriores são confirmados
- Tamanho amostral pequeno pode ser principal razão de não haver discriminação entre os modelos de Weibull e lognormal

Análise de Sobrevivência - 2017

- Curvas estimadas pelos modelos vs. KM

√ Comandos

```
> par(mfrow=c(1,2))
> plot(e.km, conf.int=F, xlab="Tempos", ylab="S(t)")
> lines(c(0,tempo.km),c(1,s.w), lty=2)
> legend(25,0.8,lty=c(1,2),c("Kaplan-Meier", "Weibull"),bty="n",cex=0.8)
> plot(e.km, conf.int=F, xlab="Tempos", ylab="S(t)")
> lines(c(0,tempo.km),c(1,s.ln), lty=2)
> legend(25,0.8,lty=c(1,2),c("Kaplan-Meier", "Log-normal"),bty="n",cex=0.8)
```

Análise de Sobrevivência - 2017

- Curvas estimadas dos modelos vs. KM

- Ambos modelos apresentam ajustes satisfatórios

Análise de Sobrevivência - 2017

- Curvas estimadas dos modelos:

```
> par(mfrow=c(1,1))
> plot(e.km, conf.int=F, xlab="Tempos", ylab="S(t)")
> lines(c(0,tempo.km),c(1,s.w), lty=2)
> lines(c(0,tempo.km),c(1,s.ln), lty=3)
> lines(c(0,tempo.km),c(1,s.e), lty=4)
> legend(25,0.8,lty=c(1,2,3,4),c("Kaplan-Meier", "Weibull", "Log-normal", "Exponencial"), bty="n",cex=0.8)
```

- Curvas Weibull e Lognormal se afastam para maiores tempos

Análise de Sobrevivência - 2017

- Teste da razão de verossimilhança:
 - ✓ H_0 : modelo de interesse é adequado
 - ✓ H_1 : modelo gama generalizada (3 parâmetros)
 - modelo de interesse é caso particular
- Ajuste da gama generalizada:

```

> # Gama-generalizada
> ajuste.gama <- flexsurvreg(sobrevida.cancer ~ 1, dist = 'gengamma')
> ajuste.gama$loglik
[1] -65.69074
    
```

149

- Teste da razão de verossimilhanças:
- Modelos de interesse:
 - ✓ Exponencial, Weibull e log-normal
- Cálculo manual

```

> # TRV - manual
> modelos <- c("Exponencial", "Weibull", "Log-normal")
> loglik <- c(ajuste.gama$loglik, ajuste.e$loglik[2],
ajuste.w$loglik[2],
+ ajuste.ln$loglik[2])
> LR <- -2*(loglik[-1] - loglik[1])
> g <- 3 - c(1, 2, 2)
> p.valor <- 1 - pchisq(LR, g)
> data.frame(modelos, loglik[-1], LR, g, p.valor)
modelos loglik.l. LR g p.valor
1 Exponencial -68.27389 5.16630281 2 0.07553559
2 Weibull -66.13336 0.88523500 1 0.34677185
3 Log-normal -65.73990 0.09831756 1 0.75385805
    
```

150

- Logaritmos da verossimilhança:

```

> ajuste.gama$loglik
[1] -65.69074
> ajuste.e$loglik[2]
[1] -68.27389
> ajuste.w$loglik[2]
[1] -66.13336
> ajuste.ln$loglik[2]
[1] -65.73990
    
```

- Teste da Razão de Verossimilhanças

	$\ln(\theta)$	Razão	GL	p-valor
Gama generalizada	-65,69			
Exponencial	-68,27	$2(68,27-65,69)=5,16$	2	0,075
Weibull	-66,13	$2(66,13-65,69)=0,88$	1	0,348
Log-normal	-65,74	$2(65,74-65,69)=0,10$	1	0,752

✓ Resultados indicam adequação dos modelos de Weibull e Log-normal

151

- Teste da razão de verossimilhanças:
- ✓ Weibull e exponencial

```

> anova(ajuste.e, ajuste.w)
Terms Resid. Df -2*LL Test Df Deviance Pr(>Chi)
1 1 19 136.5478 NA NA NA
2 1 18 132.2667 = 1 4.281068 0.03853913
    
```

RV

✓ Modelo exponencial é rejeitado em relação ao Weibull (geral)

152

• Critério de Informação de Akaike:

$$AIC = 2 \left[p - l(\hat{\theta}_M) \right]$$

✓ Correção para amostras finitas

$$AIC_c = AIC + \frac{2p(p+1)}{n-p-1}$$

✓ Prefere-se o modelo com o menor valor de AIC

✓ No exemplo

Modelo	$l(\hat{\theta})$	AIC
Gama generalizada	-65,69	$2[3 - (-65,69)] = 137,38$
Exponencial	-68,27	$2[1 - (-68,27)] = 138,54$
Weibull	-66,13	$2[2 - (-66,13)] = 136,26$
Log-normal	-65,74	$2[2 - (-65,74)] = 135,48$

✓ Confirmam o descarte do modelo exponencial

• Critério de informação de Akaike

✓ Cálculo manual

```
> modelos <- c("Gama", "Exponencial", "Weibull", "Log-normal")
> loglik <- c(ajuste.gama$loglik, ajuste.e$loglik[2], ajuste.w$loglik[2],
+ ajuste.ln$loglik[2])
> gl <- c(3, 1, 2, 2)
> aic <- 2*(gl - loglik)
> data.frame(modelos, aic)
  modelos  aic
1     Gama 137.3815
2 Exponencial 138.5478
3   Weibull 136.2667
4 Log-normal 135.4798
```

✓ Comandos

```
> # comando
> AIC <- c(ajuste.gama$AIC, extractAIC(ajuste.e)[2], extractAIC(ajuste.w)[2],
+ extractAIC(ajuste.ln)[2])
> data.frame(modelos, AIC)
  modelos  AIC
1     Gama 137.3815
2 Exponencial 138.5478
3   Weibull 136.2667
4 Log-normal 135.4798
```

• Comentários:

✓ Recomenda-se usar o AIC para selecionar modelos quando o número de observações (n) é maior que pelo menos 40 vezes o número de parâmetros (p)

- (Burham e Anderson, 2002)

✓ O AICc é recomendado para pequenas amostras e respostas com distribuição normal

- Aumenta consideravelmente a probabilidade de escolha do modelo adequado. (Davison, 2001)

- Deve-se considerar arriscado usar para distribuições não normais um critério que foi desenvolvido para distribuição normal

• Curvas de sobrevivência estimadas:

- Modelos Weibull e log-normal


- Estimador de Kaplan-Meier

✓ Comandos:

```
# Curvas de Sobrevivência Estimadas

par(mfrow=c(1,2))
plot(e.km, conf.int=F, xlab="Tempos", ylab="S(t)")
lines(c(0,tempo.km),c(1,s.w), lty=2)
legend(25,0.8,lty=c(1,2),c("Kaplan-Meier", "Weibull"),bty="n",cex=0.8)
plot(e.ln, conf.int=F, xlab="Tempos", ylab="S(t)")
lines(c(0,tempo.km),c(1,s.ln), lty=2)
legend(25,0.8,lty=c(1,2),c("Kaplan-Meier", "Log-normal"),bty="n",cex=0.8)
```

• Curvas de sobrevivência estimadas:




✓ Ambos os modelos apresentam ajustes satisfatórios

Análise de Sobrevivência - 2017

158

• Comparação das curvas estimadas sobrevivência



Análise de Sobrevivência - 2017

159

• Estimativa para o tempo médio:

✓ Modelo Log-normal:

$$\begin{aligned} \hat{E}(T) &= \exp\left\{\mu + \frac{\sigma^2}{2}\right\} \\ &= \exp\left\{2,72 + \frac{0,76^2}{2}\right\} \\ &= 20,263 \text{ meses} \end{aligned}$$

✓ Modelo de Weibull

$$\begin{aligned} \hat{E}(T) &= \frac{1}{\alpha} \Gamma\left(1 + \frac{1}{\gamma}\right) \\ &= \frac{1}{0,0468} \Gamma\left(1 + \frac{1}{1,54}\right) \\ &= 19,206 \text{ meses} \end{aligned}$$

Análise de Sobrevivência - 2017

160

✓ Estimativa variância EMV's – Lognormal

```
> ajuste.ln$var
      (Intercept)  Log(scale)
(Intercept) 0.031061677 0.002706896
Log(scale) 0.002706896 0.030119031
```

$$\widehat{\text{Var}}(\hat{\mu}) = 0,031061677$$

$$\widehat{\text{Var}}(\log \hat{\sigma}) = 0,030119031$$

$$\widehat{\text{Cov}}(\hat{\mu}, \log \hat{\sigma}) = 0,002706896$$

✓ Estimativa variância $\hat{\sigma}$:

$$\widehat{\text{Var}}(\hat{\mu}) = 0,0311$$

$$\begin{aligned} \widehat{\text{Var}}(\hat{\sigma}) &= \widehat{\text{Var}}(\ln \hat{\sigma})(\hat{\sigma})^2 \\ &= (0,0311)(0,7648)^2 \\ &= 0,0176 \end{aligned}$$

$$\widehat{\text{Cov}}(\hat{\mu}, \hat{\sigma}) = 0,0027$$

Análise de Sobrevivência - 2017

161

• Estimativa de $\widehat{\text{Var}}[\hat{E}(T)]$:

√ Modelo Log-normal:

```
> ajuste.ln$var
      (Intercept)  Log(scale)
(Intercept) 0.031061677 0.002706896
Log(scale) 0.002706896 0.030119031
```

$$\widehat{\text{Var}}(\hat{\mu}) = 0,0311$$

$$\widehat{\text{Var}}(\hat{\sigma}) = \widehat{\text{Var}}(\ln \hat{\sigma})(\hat{\sigma})^2 = (0,0311)(0,7648)^2 = 0,0176$$

$$\widehat{\text{Cov}}(\hat{\mu}, \hat{\sigma}) = 0,0027$$

√ Estimativa :

$$\widehat{\text{Var}}[\hat{E}(T)] = \widehat{\text{Var}}(\hat{\mu}) \left[\exp \left\{ \hat{\mu} + \frac{\hat{\sigma}^2}{2} \right\} \right]^2 + \widehat{\text{Var}}(\hat{\sigma}) \left[\hat{\sigma} \exp \left\{ \hat{\mu} + \frac{\hat{\sigma}^2}{2} \right\} \right]^2 + 2\widehat{\text{Cov}}(\hat{\mu}, \hat{\sigma}) \left[\exp \left\{ \hat{\mu} + \frac{\hat{\sigma}^2}{2} \right\} \right] \left[\hat{\sigma} \exp \left\{ \hat{\mu} + \frac{\hat{\sigma}^2}{2} \right\} \right]$$

$$= (0,031)(20,263)^2 + (0,0176)[(0,76)(20,263)]^2 + 2(0,00207)(0,76)(20,263)^2 = 18,2$$

Análise de Sobrevivência - 2017 162

• Intervalo de 95% de confiança para $E[T]$:

$$\hat{E}[T] \pm z_{\alpha/2} \sqrt{\widehat{\text{Var}}[\hat{E}(T)]} = 20,263 \pm 1,96 \sqrt{18,2}$$

$$[11,901; 28,625]$$

Análise de Sobrevivência - 2017 163

• Estimativa de $\widehat{\text{Var}}[\hat{E}(T)]$:

√ Modelo de Weibull:

- Nesse caso, a estimativa é mais complicada pois aparece a derivada da função gama
- Envolve a função digama

Análise de Sobrevivência - 2017 164

• Estimativa para o tempo mediano:

√ Modelo Log-normal: $\hat{t}_{0,5} = \exp\{\hat{\mu}\} = \exp\{2,72\} = 15,18$ meses

√ Variância do estimador do tempo mediano

$$\text{Var}(\hat{t}_{0,5}) = \text{Var}(\mu) [\exp\{\hat{\mu}\}]^2$$

$$\hat{e}p(\hat{t}_{0,5}) = \sqrt{0,031} \exp\{2,72\} = 2,675$$
 meses

√ Intervalo com 95% de confiança para o tempo mediano

$$\hat{t}_{0,5} \pm z_{\alpha/2} \hat{e}p(\hat{t}_{0,5}) = 15,18 \pm (1,96)(2,675)$$

$$[9,94; 20,42]$$

Análise de Sobrevivência - 2017 165

- Estimativa para o tempo mediano:
 - Modelo de Weibull:
$$\hat{t}_{0,5} = \frac{[\ln(2)]^{\frac{1}{\alpha}}}{\alpha} = \frac{[\ln(2)]^{\frac{1}{1,54}}}{0,0468} = 16,84 \text{ meses}$$
 - Interpolação linear da função de sobrevivência

tempo . km	s . km
[1,]	3 0.95000000
[2,]	5 0.90000000
[3,]	6 0.85000000
[4,]	7 0.80000000
[5,]	8 0.75000000
[6,]	9 0.70000000
[7,]	10 0.65000000
[8,]	12 0.59583333
[9,]	15 0.54166667
[10,]	18 0.48148148
[11,]	19 0.42129630

$\hat{t}_{0,5} = 17,05 \text{ meses}$

166

- Estimativa para S(20):
 - Modelo Log-normal:
$$\hat{S}_{ln}(20) = \Phi\left(\frac{-\ln(20) + \hat{\mu}}{\hat{\sigma}}\right) = \Phi\left(\frac{-\ln(20) + 2,72}{0,76}\right) = 0,3583$$
 - Estimador Kaplan-Meier: $\hat{S}_{KM}(20) = 0,361$
 - Paciente tem uma probabilidade de cerca de 36% de estar livre de reincidência 20 meses após da realização do procedimento cirúrgico

171

Comentário

- Utilizado o modelo lognormal para ilustrar o cálculo das estimativas intervalares de E(T) e t_{med} .

174

- Funções de risco estimadas dos modelos

Qual função de risco expressa melhor o problema?

175

Referências

Bibliografia



- COLOSIMO, E.; GIOLO, S. *Análise de sobrevivência aplicada*. Edgard Blücher, 2006.
- CARVALHO, M. S. *et al.* *Análise de sobrevivência: teoria e aplicações em saúde*. Fiocruz, 2011.
- KLEIN, J. P.; MOESCHBERGER, M. L. *Survival analysis: techniques for censored and truncated data*. Springer, 2003.
- KLEINBAUM, D. G. KLEIN, M. *Survival analysis: a self-learning text*. Springer, 2011.