

Análise de Sobrevida Aplicada à Saúde

Lupércio França Bessegato
Dep. Estatística/UFJF

Introdução

Roteiro

1. Conceitos Básicos
2. Técnicas Não Paramétricas
3. Modelos Probabilísticos e Inferência
4. Modelos de Regressão Paramétricos
5. Modelos de Regressão de Cox
6. Extensões do Modelo de Cox
7. Tópicos Adicionais
8. Referências

Análise de Sobrevida Aplicada à Saúde -- 2014

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 Sobrevida Aplicada à Saúde -- 2014

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 Aplicada à Saúde -- 2014

- 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 Aplicada à Saúde -- 2014

Distribuições do Tempo de Sobrevivência

Distribuições

- Adotadas para se ajustar a distribuição do tempo de sobrevivência T:

- √ Exponencial

- √ Weibull

- √ Log-normal

- √ Log-logística

- √ Etc.

Análise de Sobrevivência Aplicada à Saúde -- 2014

Distribuição Exponencial

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

Análise de Sobrevivência Aplicada à Saúde -- 2014

- Função de risco:

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

\checkmark Constante e igual a α

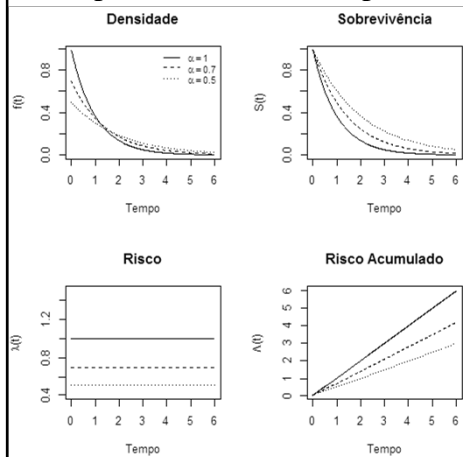
- Função de risco acumulado

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

\checkmark É uma função linear no tempo

Análise de Sobrevivência Aplicada à Saúde -- 2014

\checkmark Exponencial – Forma típica das funções



Função de risco

- \checkmark Paralela ao eixo do tempo
- Quanto maior o risco α :
- \checkmark Mais rapidamente decai a sobrevivência
- \checkmark Maior a inclinação da reta do risco acumulado

Análise de Sobrevivência Aplicada à Saúde -- 2014

- 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:

$$\checkmark F(t_{med}) = 0,5$$

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

Análise de Sobrevivência Aplicada à Saúde -- 2014

- 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 Aplicada à Saúde -- 2014

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 Aplicada à Saúde -- 2014

- 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 Aplicada à Saúde -- 2014

√ 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 Aplicada à Saúde -- 2014

• 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 Sobrevida Aplicada à Saúde -- 2014

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 ($\gamma=1$)

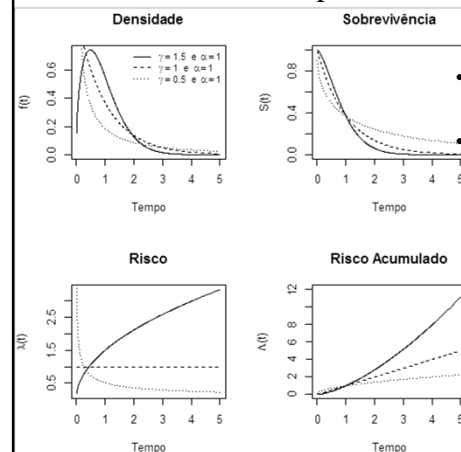
Análise de Sobrevida Aplicada à Saúde -- 2014

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

Análise de Sobrevida Aplicada à Saúde -- 2014

• Weibull – Forma típica das funções



Análise de Sobrevida Aplicada à Saúde -- 2014

• 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

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

Análise de Sobrevivência Aplicada à Saúde -- 2014

Weibull – Comentários

- Para a maioria dos fenômenos de saúde
 $\sqrt{\text{É plausível supor que o risco não é constante no tempo}}$
- Função mais utilizada na modelagem paramétrica em saúde
- Muito flexível
 $\sqrt{\text{O parâmetro } \gamma \text{ modela a variação do risco no tempo}}$

Análise de Sobrevivência Aplicada à Saúde -- 2014

Distribuição Lognormal

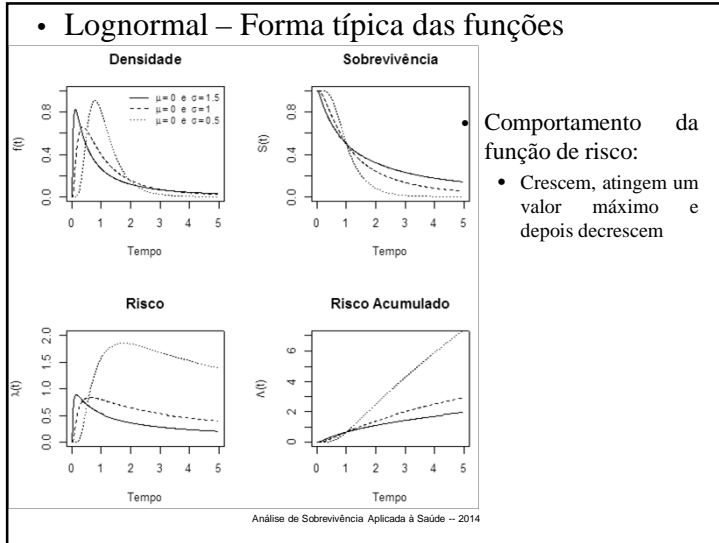
- Densidade: $f(t) = \frac{1}{\sqrt{2\pi}\sigma} \exp\left\{-\frac{1}{2} \left(\frac{\ln(t) - \mu}{\sigma}\right)^2\right\}$
 $\sqrt{t > 0, -\infty < \mu < \infty \text{ e } \sigma > 0}$
- Função de sobrevivência: $S(t) = \Phi\left(\frac{-\ln(t) + \mu}{\sigma}\right)$
 $\sqrt{\Phi: \text{função de distribuição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

Análise de Sobrevivência Aplicada à Saúde -- 2014

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

Análise de Sobrevivência Aplicada à Saúde -- 2014



• 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:

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

$$P\{T \leq t_p\} = p$$

√ 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: $t_{med} = \exp\{\mu\}$

$$\sqrt{F(t_{med})} = 0,5$$

Análise de Sobrevivência Aplicada à Saúde -- 2014

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 Aplicada à Saúde -- 2014

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 Aplicada à Saúde -- 2014

Métodos de Estimação

- Método de Mínimos Quadrados:
 - √ Inadequado para estudo de tempo de sobrevivência
 - √ Censura não é incorporada no processo de estimação
- Método de Máxima Verossimilhança:
 - √ Opção apropriada para dados censurados
 - √ Incorpora a censura
 - √ Relativamente simples de ser entendido
 - √ Possui boas propriedades para grandes amostras

Análise de Sobrevivência Aplicada à Saúde -- 2014

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

- Não conhecemos p_0 , mas podemos considerar o cenário em $p_0 = 1/2$.
 - √ Sob esta particular condição, a 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 $p_0 = p$

$$L(p; 3) = \binom{10}{3} (p)^3 (1 - p)^7, p \in [0, 1]$$

- √ Essa função é denominada função de verossimilhança e denotamos por $L(p; 3)$

Princípio da Máxima Verossimilhança

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




Toma-se o valor do parâmetro que torna mais provável o dado observado

$$P(X = 3) = f(3; 0, 3) = \binom{10}{3} (0, 3)^3 (0, 7)^7 \approx 0, 267$$

Função de Log-Verossimilhança

- Como o log é uma função crescente, o 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 $L(p; 3)$
 - √ Assim, em nosso exemplo, a função de log-verossimilhança é definida como:


$$\begin{aligned} l(p; 3) &\stackrel{\text{def}}{=} \ln L(p; 3) \\ &= 3 \ln p + 7 \log(1 - p) + \ln \binom{10}{3} \end{aligned}$$



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

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

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



- A estimativa é determinada pelo valor de X
√ Se tivéssemos observado $X = k$, teríamos a estimativa $\hat{p} = \frac{k}{10}$
- Em nosso exemplo, o estimador de máxima verossimilhança é?

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

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 Aplicada à Saúde -- 2014

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:

$$\begin{aligned} L(\theta; t_1, t_2, \dots, t_n) &= f(t_1; \theta) f(t_2; \theta) \dots f(t_n; \theta) \\ &= \prod_{i=1}^n f(t_i, \theta) \end{aligned}$$

Estimador de Máxima Verossimilhança

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

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

- √ 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

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

- Função de verossimilhança da amostra

$$\begin{aligned} L(p; \mathbf{x}) &= p^{x_1}(1-p)^{1-x_1} p^{x_2}(1-p)^{1-x_2} \dots p^{x_n}(1-p)^{1-x_n} \\ &= \prod_{i=1}^n p^{x_i}(1-p)^{1-x_i} \\ &= p^{\sum_{i=1}^n x_i} (1-p)^{\sum_{i=1}^n (1-x_i)} \\ &= p^{\sum_{i=1}^n x_i} (1-p)^{n-\sum_{i=1}^n x_i} \end{aligned}$$

- Função de log-verossimilhança

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


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

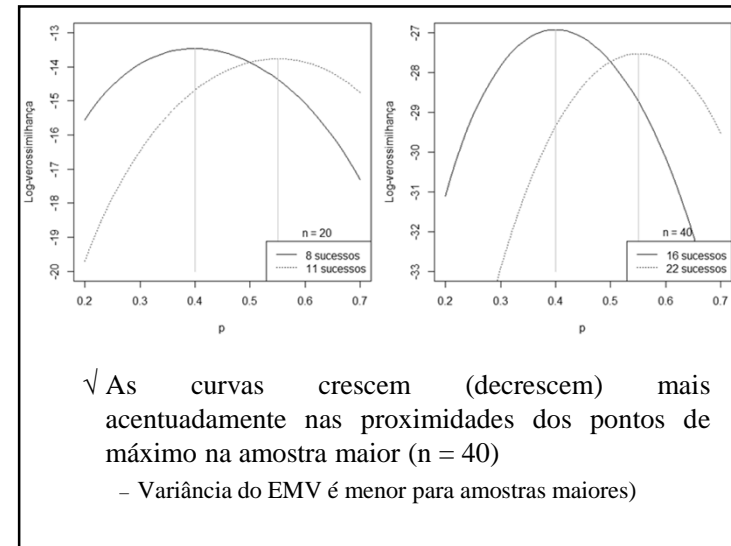
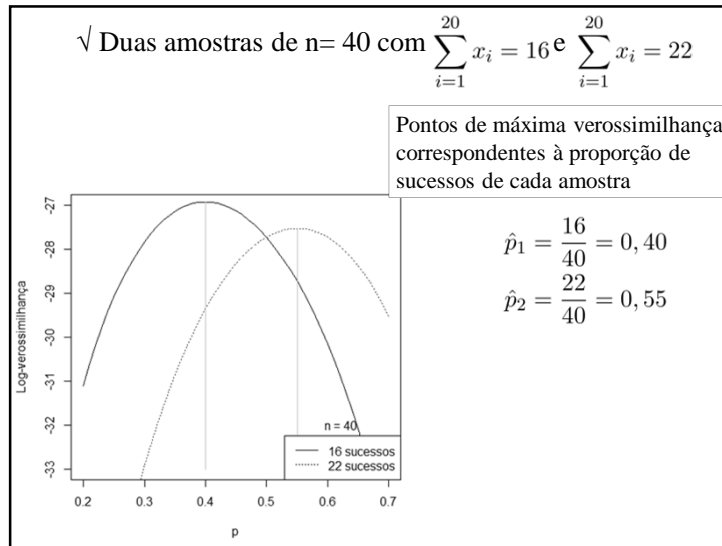
$$\hat{p} = \frac{\sum_{i=1}^n x_i}{n}$$

- Estimador de máxima verossimilhança para amostras de Bernoulli $\hat{p} = \bar{X}$
 √ Proporção de sucessos na amostra

Exemplo

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





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

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

• 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 Aplicada à Saúde -- 2014

• 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 das observações que sofreram censura à esquerda

D : conjunto das observações que sofreram censura à direita

Análise de Sobrevivência Aplicada à Saúde -- 2014

• 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 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 que sofreram censura à direita

E : conjunto das observações que sofreram censura à esquerda

I : conjunto das observações que sofreram censura intervalar

Análise de Sobrevivência Aplicada à Saúde -- 2014

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, $l(\theta) = \ln(L(\theta))$.

Análise de Sobrevivência Aplicada à Saúde -- 2014

√ Os 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:

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

Análise de Sobrevivência Aplicada à Saúde -- 2014

Distribuição Exponencial

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

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

Análise de Sobrevivência Aplicada à Saúde -- 2014

√ Função da log-verossimilhança:

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

√ Estimador de máxima verossimilhança:

$$\begin{aligned} \frac{\partial l(\alpha)}{\partial \alpha} &= \frac{\sum_{i=1}^n \delta_i}{\alpha} - \sum_{i=1}^n t_i & \frac{\partial l(\alpha)}{\partial \alpha} = 0 &\Rightarrow \hat{\alpha} = \frac{r}{\sum_{i=1}^n t_i} \\ &= \frac{r}{\alpha} - \sum_{i=1}^n t_i & \hat{\alpha} &= \frac{\text{total desfechos}}{\text{tempo total sob teste}} \end{aligned}$$

Se não houver censuras

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

Análise de Sobrevivência Aplicada à Saúde -- 2014

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 Aplicada à Saúde -- 2014

- 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 Aplicada à Saúde -- 2014

- 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 Aplicada à Saúde -- 2014

- 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 Aplicada à Saúde -- 2014

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 Aplicada à Saúde -- 2014

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 Aplicada à Saúde -- 2014

√ Modelo Exponencial:

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

√ Saída:

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

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

Análise de Sobrevivência Aplicada à Saúde -- 2014

Outras Distribuições

- Tempos de sobrevivência com distribuição de Weibull ou Lognormal:
 - √ A 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)

Análise de Sobrevivência Aplicada à Saúde -- 2014

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

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

Análise de Sobrevivência Aplicada à Saúde -- 2014

√ 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: $\hat{S}_m(t) = \Phi \left[\frac{-\ln(t) - 3.8934}{0.6426} \right]$

Análise de Sobrevivência Aplicada à Saúde -- 2014

• 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

Análise de Sobrevivência Aplicada à Saúde -- 2014

• 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 Aplicada à Saúde -- 2014

Intervalos de Confiança

• Intervalos de Confiança e Testes de hipóteses:

√ Método de máxima verossimilhança permite a construção de intervalos de confiança para os parâmetros e quantidades de interesse.

• Distribuição assintótica do EMV $\hat{\theta}$:

√ Para grandes amostras: $\hat{\theta}^{as} \sim N(\theta, \text{Var}(\hat{\theta}))$

√ $\text{Var}(\hat{\theta})$: variância de $\hat{\theta}$:

- Em geral, depende de θ .

Análise de Sobrevivência Aplicada à Saúde -- 2014

√ 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 Aplicada à Saúde -- 2014

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 Aplicada à Saúde -- 2014

Teste da Razão de Verossimilhanças

- Compara os valores da log-verossimilhança maximizada sem restrição e sob H_0

√ Hipótese:

- $H_0: \theta = \theta_0$.

$$\begin{aligned} \text{√ Estatística de teste: } RV &= 2 \ln \left[\frac{L(\hat{\theta}_0)}{L(\hat{\theta})} \right] = 2 \left[\ln L(\hat{\theta}) - L(\hat{\theta}_0) \right] \\ &= 2[l(\hat{\theta}) - l(\hat{\theta}_0)] \end{aligned}$$

√ 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 Aplicada à Saúde -- 2014

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 Aplicada à Saúde -- 2014

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 Aplicada à Saúde -- 2014

- 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 Aplicada à Saúde -- 2014


Métodos Gráficos

1. Comparação do modelo proposto com o estimador de Kaplan-Meier:
 - √ Ajusta-se o modelo proposto ao conjunto de dados
 - √ Obter a estimativa de Kaplan-Meier para a sobrevivência
 - √ Comparam-se graficamente as funções de sobrevivência obtidas
 - √ Quanto mais próximo o modelo paramétrico estiver da curva do Kaplan-Meier, melhor o modelo

Análise de Sobrevivência Aplicada à Saúde -- 2014

- 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 Aplicada à Saúde -- 2014

• Comparação entre os valores estimados

$$\sqrt{(S_{km}, S_{paramétrico})}$$



Análise de Sobrevivência Aplicada à Saúde -- 2014

• 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 Aplicada à Saúde -- 2014

• Comparação do modelo proposto com o estimador de Nelson-Aalen:

- √ Ajusta-se o modelo proposto ao conjunto de dados
- √ Obter a estimativa de Nelson-Aalen para a a função de risco acumulado
- √ Comparam-se graficamente as 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 Aplicada à Saúde -- 2014

• Funções de sobrevivência e de risco acumulado:

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

• Risco acumulado:

√ 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 Aplicada à Saúde -- 2014

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

- Modelo exponencial $-\ln S(t) = \alpha t$
- Modelo Weibull

Análise de Sobrevivência Aplicada à Saúde -- 2014

• 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

Análise de Sobrevivência Aplicada à Saúde -- 2014

• Linearização do modelo de Weibull

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

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

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

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

√ Indicação a favor do modelo exponencial

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

Análise de Sobrevivência Aplicada à Saúde -- 2014

• Linearização do modelo Lognormal

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

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


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

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

Análise de Sobrevivência Aplicada à Saúde -- 2014

- Gráficos linearizados da sobrevivência

- √ Modelos exponencial, Weibull e lognormal



- 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
 - Tamanho amostral pequeno pode ser a principal razão

Análise de Sobrevivência Aplicada à Saúde -- 2014

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 Aplicada à Saúde -- 2014

- Métodos gráficos devem ser usados para descartar modelos claramente inadequados

- √ Há situações em que os gráficos apresentados não discriminam modelos, mas indicam que eles são igualmente bons

- Tamanho amostral pequeno ou pequena quantidade de desfechos

- √ Diferentes modelos com ajustes razoáveis 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 Aplicada à Saúde -- 2014

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

Análise de Sobrevivência Aplicada à Saúde -- 2014

Comparação de Modelos – Teste de Hipóteses

- Outra forma 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
 - √ Deve-se identificar um modelo generalizado tal que o modelo de interesse seja caso particular

Análise de Sobrevivência Aplicada à Saúde -- 2014

- 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: $RV = 2 [l(\hat{\theta}_G) - l(\hat{\theta}_M)]$
 - √ Distribuição amostral: $RV \sim \chi_{gl}^2$
 - gl: diferença entre o número de parâmetros dos dois modelos

Análise de Sobrevivência Aplicada à Saúde -- 2014

- 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:

$$RV = 2 [l(\hat{\theta}_G) - l(\hat{\theta}_M)] = 2[78,1745 - 74,3942] = 7,5642$$
 - √ 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

Análise de Sobrevivência Aplicada à Saúde -- 2014

No contexto de Análise de Sobrevivência este teste é usualmente realizado utilizando-se a distribuição gama generalizada.

√ Apresenta os modelos exponencial, de Weibull, lognormal e gama como modelos encaixados

Para ajuste do modelo gama generalizado no R:

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

- 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 =
"gendgamma")
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
```

- Logaritmos da verossimilhança:

```
> sobrev.gama$loglik
[1] -73.8024
> sobrev.es$loglik[2]
[1] -78.1745
> sobrev.w$loglik[2]
[1] -74.39242
> sobrev.ln$loglik[2]
[1] -73.83833
```

- Teste da Razão da Verossimilhança – Resultados

	$l(\theta)$	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

- Comandos em R:

√ A função **anova** não funciona com objeto **flexsurvreg**

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 Sobrevida Aplicada à Saúde -- 2014

- 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 Sobrevida Aplicada à Saúde -- 2014

- 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 Sobrevida Aplicada à Saúde -- 2014

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 Aplicada à Saúde -- 2014

✓ **Modelo Exponencial:**

```

Exponencial
ajuste.e<-survreg( sobrevida.cancer ~1,dist='exponential')
ajuste.e
    
```

✓ **Saída:**

```

> ajuste.e
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
    
```

✓ **Estimação parâmetro:**

```

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

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

Análise de Sobrevivência Aplicada à Saúde -- 2014

✓ **Modelo Weibull:**

```

#Weibull
ajuste.w<-survreg(sobrevida.cancer~1,dist='weibull')
ajuste.w
    
```

✓ **Saída:**

```

> ajuste.w
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
    
```

✓ **Estimação parâmetro:**

```

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

✓ **Sobrevivência estimada:** $\hat{S}_w(t) = \exp\{-(0,04686t)^{1,5433}\}$

Análise de Sobrevivência Aplicada à Saúde -- 2014

✓ **Modelo Log-normal:**

```

#Log-normal
ajuste.ln<-survreg(sobrevida.cancer~1,dist='lognorm')
ajuste.ln
    
```

✓ **Saída:**

```

> ajuste.ln
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
    
```

✓ **Estimação parâmetro:**

```

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

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

Análise de Sobrevivência Aplicada à Saúde -- 2014

- 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: $\hat{S}_e(10) = \exp\{-(0,04899)(10)\} = 0,612$
 - ✓ Weibull: $\hat{S}_w(10) = \exp\{-(0,04686 \times 10)^{1,5433}\} = 0,732$
 - ✓ Log-normal: $\hat{S}_{ln}(10) = \Phi\left[\frac{-\ln(10)-2,7172}{0,7648}\right] = 0,708$

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

Análise de Sobrevivência Aplicada à Saúde -- 2014

- Comparação das estimativas da sobrevivência:
 - √ Estimador Kaplan-Meier e modelos Exponencial, Weibull e log-normal
 - Comandos em R:

```

> # Estimativa de Kaplan-Meier
> e.km<-survfit(sobrevida.cancer~1)
> tempo.km<-e.km$time
> s.km<-e.km$surv
> # Comparação de Estimativas
> 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)
> cbind(tempo.km,s.km,s.e,s.w,s.ln)
    
```

Análise de Sobrevida Aplicada à Saúde -- 2014

- Estimativas da sobrevivência para os tempos de reincidência:

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	0.38317692
[12,]	20	0.36111111	0.3753760	0.40461041	0.35784922
[13,]	22	0.30092593	0.3403401	0.35056108	0.31248031
[14,]	25	0.24074074	0.2938212	0.27891623	0.25592025
[15,]	28	0.18055556	0.2536607	0.21851514	0.21065456
[16,]	30	0.12037037	0.2299851	0.18419003	0.18556452
[17,]	40	0.06018519	0.1409071	0.07154720	0.10195229
[18,]	45	0.06018519	0.1102934	0.04229094	0.07714984

Análise de Sobrevida Aplicada à Saúde -- 2014

- 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


√ Comandos:

```

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")
lines(c(0,1), c(0,1), type="l", 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")
lines(c(0,1), c(0,1), type="l", 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")
lines(c(0,1), c(0,1), type="l", lty=1)
    
```

Análise de Sobrevida Aplicada à Saúde -- 2014

- Estimativa Kaplan-Meier vs. Modelos



Análise de Sobrevida Aplicada à Saúde -- 2014

- Comentários:

- Modelo exponencial parece não ser adequado aos dados:

- (Curva encontra-se um tanto afastada da reta $y = x$)

- Indicação de que os modelos de Weibull ou log-normal é possivelmente adequado aos dados

- (acompanham mais de perto a reta $y = x$)

Análise de Sobrevivência Aplicada à Saúde -- 2014


- Gráficos linearizados para os modelos:

- Comandos:

```
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))))
```

Análise de Sobrevivência Aplicada à Saúde -- 2014

- Gráficos linearizados para os modelos Exponencial, Weibull e Log-normal



Análise de Sobrevivência Aplicada à Saúde -- 2014

- Comentários:

- Modelos de Weibull e Log-normal não mostram afastamentos marcantes de uma reta

- Observa-se certo desvio para modelo Exponencial

- Gráficos confirmam resultados observados anteriormente

- Tamanho amostral pequeno provavelmente é principal razão de não ter ocorrido discriminação entre os modelos de Weibull e Log-normal

Análise de Sobrevivência Aplicada à Saúde -- 2014

- Teste da razão de verossimilhança:

- √ H_0 : modelo de interesse é adequado
- √ Modelo generalizado (modelos de interesse são casos particulares: gama generalizada (3 parâmetros)
- √ Ajuste do modelo gama generalizado

```
> require(flexsurv)
> ajuste.gama<-flexsurvreg(sobrevida.cancer ~1,dist='gengamma')
> ajuste.gama
Call:
flexsurvreg(formula = sobrevida.cancer ~ 1, dist = "gengamma.orig")
Estimates:
      est      1.95%      U.95%      se
shape 4.21e-01 2.97e-03 5.97e+01 1.06e+00
scale 6.46e-02 7.20e-24 5.80e+20 1.67e+00
k      1.04e+01 8.06e-04 1.34e+05 5.03e+01
N = 20, Events: 17, Censored: 3
Total time at risk: 347
Log-likelihood = -65.69393, df = 3
AIC = 137.3879
```

Análise de Sobrevivência Aplicada à Saúde -- 2014

- 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] -65.7399
```

- Teste da Razão de Verossimilhanças–Resultados

	$\ln(\theta)$	Razão	GL	p-valor
Gama generalizada	-65,69			$> 1-pchisq(5.16,2)$ [1] 0.075774
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

Análise de Sobrevivência Aplicada à Saúde -- 2014

- Critério de Informação de Akaike:

Modelo	$\ln(\theta)$	AIC
Gama generalizada	-65,69	$2[3 - (-65,69)] = 137,4$
Exponencial	-68,27	$2[1 - (-68,27)] = 138,5$
Weibull	-66,13	$2[2 - (-66,13)] = 136,3$
Log-normal	-65,74	$2[2 - (-65,74)] = 135,5$

- √ Confirmam o descarte do modelo exponencial

Análise de Sobrevivência Aplicada à Saúde -- 2014

- Curvas de sobrevivência estimadas:

- Modelos Weibull e log-normal
- Estimador de Kaplan-Meier

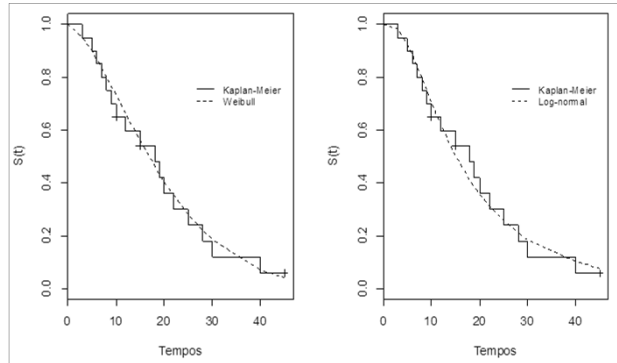
- √ Comandos:

```
# 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.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 Aplicada à Saúde -- 2014


• Curvas de sobrevivência estimadas:



✓ Ambos os modelos apresentam ajustes satisfatórios

Análise de Sobrevivência Aplicada à Saúde -- 2014

• Comparação das curvas estimadas de sobrevivência



Análise de Sobrevivência Aplicada à Saúde -- 2014

• 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 Aplicada à Saúde -- 2014

• 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
```

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

✓ Estimativa :

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

$$\begin{aligned} \widehat{\text{Var}}[\hat{E}(T)] &= \widehat{\text{Var}}(\hat{\mu}) \left[\exp\left\{\hat{\mu} + \frac{\hat{\sigma}^2}{2}\right\} \right]^2 + \widehat{\text{Var}}(\hat{\sigma}) \left[\hat{\sigma} \exp\left\{\hat{\mu} + \frac{\hat{\sigma}^2}{2}\right\} \right]^2 \\ &\quad + 2\widehat{\text{Cov}}(\hat{\mu}, \hat{\sigma}) \left[\exp\left\{\hat{\mu} + \frac{\hat{\sigma}^2}{2}\right\} \right] \left[\hat{\sigma} \exp\left\{\hat{\mu} + \frac{\hat{\sigma}^2}{2}\right\} \right] \\ &= (0,031)(20,263)^2 + (0,0176)[(0,76)(20,263)]^2 \\ &\quad + 2(0,00207)(0,76)(20,263)^2 = 18,2 \end{aligned}$$

Análise de Sobrevivência Aplicada à Saúde -- 2014

- 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 Aplicada à Saúde -- 2014

- 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 Aplicada à Saúde -- 2014

- 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

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

$$\widehat{\text{ep}}(\hat{t}_{0,5}) = \sqrt{0,031} \exp\{2,72\}$$

$$= 2,675 \text{ meses}$$

√ Intervalo com 95% de confiança para o tempo mediano

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

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

Análise de Sobrevivência Aplicada à Saúde -- 2014

- Estimativa para o tempo mediano:

√ Modelo de Weibull: $\hat{t}_{0,5} = \frac{[\ln(2)]^{\frac{1}{\gamma}}}{\alpha} = \frac{[\ln(2)]^{\frac{1}{1,54}}}{0,0468}$
 $= 16,84$ 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

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

Análise de Sobrevivência Aplicada à Saúde -- 2014

- 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

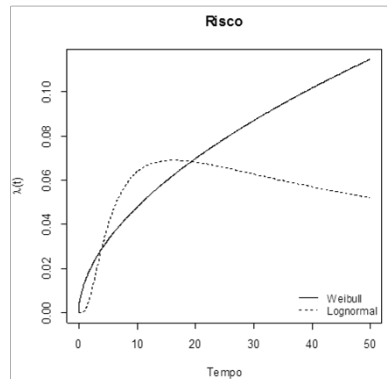
Análise de Sobrevida Aplicada à Saúde -- 2014

Comentário

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

Análise de Sobrevida Aplicada à Saúde -- 2014

- Funções de risco estimadas dos modelos



√ Qual função de risco expressa melhor o problema?

Análise de Sobrevida Aplicada à Saúde -- 2014

Modelos de Regressão Paramétricos

Covariáveis

- Variáveis que podem estar relacionadas com o tempo de sobrevivência
 - √ Ex.: Tempo até a ocorrência de Aids em pacientes infectados pelo HIV
 - Contagem de células CD4 e CD8
 - Fatores de prognóstico importantes

Análise de Sobrevivência Aplicada à Saúde -- 2014

Técnicas Não Paramétricas

- Não envolvem nenhuma estrutura paramétrica
- Vantagens:
 - √ Simplicidade e facilidade de aplicação
- Limitação:
 - √ Análise mais detalhada é inviável
 - Não permitem a inclusão direta de covariáveis
- √ Importância:
 - Descrição dos dados de sobrevivência

Análise de Sobrevivência Aplicada à Saúde -- 2014

Estratificação

- Forma simples de fazer análise mais elaborada incluindo covariáveis
 - √ Dividir dados em estratos de acordo com covariáveis
 - Usar as técnicas não paramétricas apropriadas
 - √ Vantagem:
 - Facilidade de cálculo e facilidade de entendimento
 - √ Limitação:
 - Difícil análise com muitas covariáveis (gera um número muito grande de estratos)

Análise de Sobrevivência Aplicada à Saúde -- 2014

Modelos de Regressão para Dados de Sobrevivência

- √ Forma eficiente de acomodar o efeito de covariáveis
- Classes de modelos:
 - √ Modelos paramétricos:
 - (modelos de tempo de vida acelerado)
 - Mais eficientes porém menos flexíveis
 - √ Modelos semiparamétricos:
 - (modelo de regressão de Cox)
 - São mais flexíveis
 - Fácil a incorporação de covariáveis dependentes do tempo

Análise de Sobrevivência Aplicada à Saúde -- 2014

Modelo de Regressão Linear

- ✓ Modelo mais conhecido em Estatística
- ✓ Resposta é associada com as variáveis explicativas (covariáveis) por meio de modelo linear

$$Y = \underbrace{\beta_0 + \beta_1 x}_{\text{Componente determinístico}} + \underbrace{\epsilon}_{\text{Componente estocástico}}$$

- Y: variável resposta
- x: covariável (variável explicativa, variável independente)
- β_0, β_1 : parâmetros a serem estimados
- ϵ : erro aleatório (com distribuição normal)

Análise de Sobrevida Aplicada à Saúde -- 2014

- Estrutura de um modelo de regressão:

- ✓ Componente aleatório:
 - Descreve probabilisticamente o comportamento da resposta
- ✓ Componente determinístico ou estrutural:
 - Descreve a relação entre os parâmetros da distribuição e as covariáveis

Análise de Sobrevida Aplicada à Saúde -- 2014

Modelo de Regressão de Sobrevida

- Estima efeito das covariáveis sobre o tempo de sobrevivência
 - ✓ Variável resposta: tempo até desfecho e censura
 - Em geral, o tipo de resposta e o comportamento da variáveis não permitem a utilização direta do modelo linear
 - ✓ Distribuição da resposta tende a ser assimétrica na direção dos maiores tempos de sobrevivência
 - Inapropriado o uso da distribuição normal para o comportamento estocástico

Análise de Sobrevida Aplicada à Saúde -- 2014

- Formas de modelagem estatística em análise de sobrevivência:

- ✓ Transformar a resposta para tentar retornar ao modelo linear, ou
- ✓ Modificar o modelo, usando
 - Componente determinístico não linear nos parâmetros
 - Componente estocástico com distribuição assimétrica
- ✓ As duas formas são equivalentes:
 - Usar como componente determinístico $\exp\{\beta_0 + \beta_1 x\}$ (transformação logarítmica da resposta)
 - Distribuição lognormal para os erros (há outras distribuições assimétricas disponíveis)

Análise de Sobrevida Aplicada à Saúde -- 2014

Modelo de Regressão do Risco

- Função de risco de um indivíduo no tempo t , dado o vetor de covariáveis fixas \mathbf{x} :

$$\lambda(t|\mathbf{x}) = \lambda_0(t) g(\mathbf{x}'\boldsymbol{\beta})$$

- √ $\boldsymbol{\beta}$: vetor de coeficientes a estimar
- √ $g(\cdot)$: função positiva e contínua das covariáveis
- √ $\lambda_0(t)$: risco basal de um indivíduo que possui $g(\mathbf{x}'\boldsymbol{\beta})=1$
- √ Efeito das covariáveis é aumentar ou diminuir o risco por uma quantidade proporcional em todas as durações

Análise de Sobrevida Aplicada à Saúde -- 2014

- Razão de risco de dois indivíduos:

$$\frac{\lambda_i(t|x_{i1})}{\lambda_j(t|x_{j1})} = \frac{\lambda_0(t) g(\beta_1 x_{i1})}{\lambda_0(t) g(\beta_1 x_{j1}^*)} = \frac{g(\beta_1 x_{i1})}{g(\beta_1 x_{j1}^*)}$$

- √ Função das covariáveis e não depende do tempo
- √ Diferentes indivíduos com covariáveis x_1 e x_1^* possuem riscos proporcionais

Análise de Sobrevida Aplicada à Saúde -- 2014

- Ajuste de modelo de regressão paramétrico
 - √ Necessário supor uma distribuição de probabilidade para o tempo de sobrevivência
 - √ Parâmetros da distribuição adotada definem forma dessa distribuição
 - Não confundir com os parâmetros da regressão

- Modelo de riscos proporcionais

- √ Efeito multiplicativo exponencial

$$\begin{aligned} \lambda(t|\mathbf{x}) &= \lambda_0(t) \exp\{\mathbf{x}'\boldsymbol{\beta}\} \\ &= \lambda_0(t) e^{\beta_0} e^{\beta_1 x_1} \dots e^{\beta_p x_p} \end{aligned}$$

- Efeito das covariáveis é aumentar ou diminuir o risco por uma quantidade proporcional em todas as durações

Análise de Sobrevida Aplicada à Saúde -- 2014

- √ O risco acumulado segue a mesma relação:

$$\Lambda(t|\mathbf{x}) = \Lambda_0(t) g(\mathbf{x}'\boldsymbol{\beta})$$

- √ A relação da sobrevivência é:

$$\begin{aligned} \exp\{-\Lambda(t|\mathbf{x})\} &= \exp\{-\Lambda_0(t) g(\mathbf{x}'\boldsymbol{\beta})\} = \exp\{-\Lambda_0(t)\}^{g(\mathbf{x}'\boldsymbol{\beta})} \\ S(t|\mathbf{x}) &= [S_0(t)]^{g(\mathbf{x}'\boldsymbol{\beta})} \end{aligned}$$

- Sobrevivência para as covariáveis \mathbf{x} é a sobrevivência de referência elevada a uma potência
- Ex: se o indivíduo está exposto ao dobro do risco de um indivíduo de referência, em um determinado valor de covariáveis, então a probabilidade de que o indivíduo estará vivo em qualquer tempo é o quadrado da probabilidade de o indivíduo de referência estar vivo na mesma idade

Análise de Sobrevida Aplicada à Saúde -- 2014

Estimação dos Parâmetros do Modelo

- Estimação e inferência dos efeitos das covariáveis (β 's da regressão)
- Método dos mínimos quadrados
 - √ Tem propriedades desejáveis na presença de erros com distribuição normal
 - Inadequado na ausência de normalidade e na presença de censuras
- Método da máxima verossimilhança
 - √ Adequado na presença de censura e ausência de normalidade

Análise de Sobrevida Aplicada à Saúde -- 2014

Modelo de Regressão Exponencial

- √ Usado quando se assume que o risco é constante
- √ Parâmetro α depende das covariáveis
$$\alpha(\mathbf{x}) = \exp\{\mathbf{x}'\boldsymbol{\beta}\}$$
 - β : estimativa dos efeitos das covariáveis
 - α : parâmetro que define o risco exponencial
- √ Modela o risco como uma função das covariáveis
 - Idade aumenta o risco de óbito por insuficiência renal
 - Categoria “usuário de drogas injetáveis” tem risco maior do que a categoria “transmissão sexual” para o tempo de sobrevida com Aids

Análise de Sobrevida Aplicada à Saúde -- 2014

Funções para o modelo de regressão exponencial

√ Função de risco

$$\lambda(t|\mathbf{x}) = \alpha(\mathbf{x}) = \exp\{\mathbf{x}'\boldsymbol{\beta}\}$$

√ Função de sobrevivência:

$$S(t|\mathbf{x}) = \exp\{-\alpha(\mathbf{x})t\} = \exp\{-\exp\{\mathbf{x}'\boldsymbol{\beta}\}t\}$$

Análise de Sobrevida Aplicada à Saúde -- 2014

Exemplo

- Pacientes com insuficiência renal submetidos à hemodiálise
 - √ Período: janeiro/1988 a outubro/2001
 - √ Dados: Sistema Apac
 - √ Coorte com 6.805 pacientes, no Rio de Janeiro
 - 1.603 óbitos
 - √ Objetivo:
 - Estimar o efeito da idade no risco de morte

Análise de Sobrevida Aplicada à Saúde -- 2014

• Hipótese:

√ Risco de morrer é constante ao longo do tempo
(modelo exponencial)

• Modelo: $\lambda(t|idade) = \exp\{\beta_0 + \beta_1 \times idade\}$

• Ajuste do modelo

```
> library(survival)
> dialise <- read.csv("dados/dialise.csv", header = T)
> reg.exp <- survreg(Surv(tempo, status)~idade, data = dialise,
+ dist='exponential')
> reg.exp$coefficients
(Intercept) idade
6.13552416 -0.03700427
```

– Importante: sinal do parâmetro está invertido em relação ao utilizado no texto

$$\hat{\beta}_0 = -6,136$$

$$\hat{\beta}_1 = 0,037$$

Análise de Sobrevivência Aplicada à Saúde -- 2014

• Estimativa do risco no tempo t:

$$\hat{\lambda}(t|idade) = \exp\{-6,136 + 0,037 \times idade\}$$

√ Para cada ano de vida o risco aumenta

$$\exp\{0,037\} = 1,037 \text{ vezes}$$

√ Comparação entre indivíduos com 30 e 70 anos,

$$\frac{\hat{\lambda}(t|idade = 70)}{\hat{\lambda}(t|idade = 30)} = \frac{\exp\{\hat{\beta}_0 + \hat{\beta}_1 \times 70\}}{\exp\{\hat{\beta}_0 + \hat{\beta}_1 \times 30\}}$$

$$= \exp\{0,037 \times 40\} = 4,4$$


– Risco de indivíduo em diálise morrer aos 70 anos é 4,4 vezes maior do que o de morrer aos 30

– Quaisquer dois indivíduos com diferença de 40 anos entre si gera um risco relativo estimado em 4,4

(modelo de riscos proporcionais)

Análise de Sobrevivência Aplicada à Saúde -- 2014

• Curva de sobrevivência ajustada para 30 e 70 anos



√ Indivíduo com 70 anos progride 4,4 vezes mais rápido ao longo do tempo, acelerando a uma taxa constante

Análise de Sobrevivência Aplicada à Saúde -- 2014

Modelo de Regressão de Weibull

√ $T \sim \text{Weibull}$ e o parâmetro α é modelado pelas covariáveis

$$\alpha(\mathbf{x}) = \exp\{\mathbf{x}'\boldsymbol{\beta}\}$$

– \mathbf{B}' : estimativa dos efeitos das covariáveis

– \mathbf{x}' : valores das covariáveis

√ Modela o risco e sobrevivência como funções das covariáveis

Análise de Sobrevivência Aplicada à Saúde -- 2014

• Funções para o modelo de regressão exponencial

√ Função de risco $\lambda(t|\mathbf{x}) = \gamma t^{\gamma-1} \alpha(\mathbf{x})^\gamma$
 $= \gamma t^{\gamma-1} [\exp\{\mathbf{x}'\boldsymbol{\beta}\}]^\gamma$

√ Função de sobrevivência:
 $S(t|\mathbf{x}) = \exp\{-[\alpha(\mathbf{x}) t]^\gamma\} = \exp\{-[\exp\{\mathbf{x}'\boldsymbol{\beta}\} t]^\gamma\}$

- √ Caso $\alpha = g(\mathbf{x})$ (modelo em questão)
 – Os riscos para diferentes indivíduos são proporcionais
 √ Caso γ também varie com as covariáveis [$\gamma = h(\mathbf{x})$]
 – Modelo de regressão deixa de ser de riscos proporcionais

Análise de Sobrevivência Aplicada à Saúde -- 2014

• Parâmetro γ :

- √ $\gamma > 1$: o risco aumenta no tempo
 √ $\gamma < 1$: o risco diminui no tempo
 √ $\gamma = 1$: a função de risco é constante (exponencial)

Análise de Sobrevivência Aplicada à Saúde -- 2014

Exemplo

• Pacientes com insuficiência renal submetidos à hemodiálise

- √ Período: janeiro/1988 a outubro/2001
 √ Dados: Sistema Apac
 √ Coorte com 6.805 pacientes, no Rio de Janeiro
 – 1.603 óbitos
 √ Objetivo:
 – Estimar o efeito da idade no risco de morte

Análise de Sobrevivência Aplicada à Saúde -- 2014

• Hipótese:

√ Tempo até óbito tem distribuição de Weibull

• Modelo: $\lambda(t|idade) = \gamma t^{\gamma-1} [\exp\{\beta_0 + \beta_1 \times idade\}]^\gamma$

• Ajuste do modelo

```
> dialise <- read.csv("dados/dialise.csv", header = T)
> reg.weib <- survreg(Surv(tempo, status)~idade, data = dialise,
+ dist='weibull')
> summary(reg.weib)
Call:
survreg(formula = Surv(tempo, status) ~ idade, data = dialise,
        dist = "weibull")

              Value Std. Error      z      P
(Intercept)  6.7512      0.14693  45.95 0.00e+00
idade        -0.0436      0.00224 -19.50 1.12e-84
Log(scale)   0.1987      0.02083   9.54 1.49e-21
Scale= 1.22

Weibull distribution
Loglik(model)= -7877.7  Loglik(intercept only)= -8104.2
      Chisq= 453.16 on 1 degrees of freedom, p= 0
Number of Newton-Raphson Iterations: 7
n= 6805
```

$\hat{\beta}_0 = -6,751$
 $\hat{\beta}_1 = 0,0436$
 $\hat{\sigma} = \exp\{0,1987\} = 1,22$

– Importante: inverter o sinal do parâmetro

Análise de Sobrevivência Aplicada à Saúde -- 2014

• Análise resultados

```
> summary(reg.weib)
Call:
survreg(formula = Surv(tempo, status) ~ idade, data = dialise,
        dist = "weibull")

      Value Std. Error      z      p       $\hat{\beta}_0 = -6,751$ 
(Intercept)  6.7512    0.14693  45.95 0.00e+00
idade       -0.0436    0.00224 -19.50 1.12e-84       $\hat{\beta}_1 = 0,0436$ 
Log(scale)  0.1987    0.02083   9.54 1.49e-21       $\hat{\sigma} = \exp\{0,1987\} = 1,22$ 
Scale= 1.22

Weibull distribution
Loglik(model)= -7877.7  Loglik(intercept only)= -8104.2
      Chisq= 453.16 on 1 degrees of freedom, p= 0
Number of Newton-Raphson Iterations: 7
n= 6805
```

✓ Teste de significância do parâmetro

- Efeito da idade (β_1) é significativo
- Parâmetro de forma (γ) é significativamente diferente de 1

✓ Parâmetros da distribuição do tempo: $\hat{\alpha} = \exp\{-x'\beta\}$
 $\hat{\gamma} = \frac{1}{\hat{\sigma}} = 0,820$

Análise de Sobrevida Aplicada à Saúde -- 2014

✓ Parâmetros da regressão: $\hat{\beta}_0 = -6,751$
 $\hat{\beta}_1 = 0,0436$
 $\hat{\sigma} = \exp\{0,1987\} = 1,22$

✓ Parâmetros da distribuição de T: $\hat{\alpha} = \exp\{-x'\beta\}$
 $\hat{\gamma} = \frac{1}{\hat{\sigma}} = 0,820$

• Estimativa do risco no tempo t:

$$\hat{\lambda}(t|idade) = (0,82)t^{-0,18}[\exp\{-6,751 + 0,044 \times idade\}]^{0,82}$$

✓ Para cada ano de vida o risco aumenta

$$(\exp\{0,0436\})^{0,82} = 1,036 \text{ vezes}$$

✓ Parâmetro de forma ($\gamma = 0,82$)

- O risco de morrer diminui à medida que aumenta o tempo do paciente em hemodiálise ($\gamma < 1$)

- Possível motivo:

- Baixo preparo inicial dos pacientes (hemodiálise em emergência) (excesso de óbitos no início do processo)

Análise de Sobrevida Aplicada à Saúde -- 2014

✓ Comparação entre indivíduos com 30 e 70 anos,

$$\frac{\hat{\lambda}(t|idade = 70)}{\hat{\lambda}(t|idade = 30)} = \frac{\gamma t^{\gamma-1} [\exp\{\hat{\beta}_0 + \hat{\beta}_1 \times 70\}]^\gamma}{\gamma t^{\gamma-1} [\exp\{\hat{\beta}_0 + \hat{\beta}_1 \times 30\}]^\gamma}$$

$$= \left[\frac{\exp\{-6,7512 + 0,0436 \times 70\}}{\exp\{-6,7512 + 0,0436 \times 30\}} \right]^{0,82}$$

$$= [\exp\{0,0436 \times 40\}]^{0,82} = 4,11$$

- Risco de indivíduo em diálise morrer aos 70 anos é 4,11 vezes maior do que o de morrer aos 30
- Quaisquer dois indivíduos com diferença de 40 anos entre si gera um risco relativo estimado em 4,11 (modelo de riscos proporcionais)

Análise de Sobrevida Aplicada à Saúde -- 2014

Estratificação

• Podem-se utilizar estratos na modelagem

✓ Diferentes parâmetros γ da distribuição do tempo dos subgrupos populacionais

✓ Parâmetros da regressão comuns para todo o conjunto

- Mesmo efeito das covariáveis

✓ Permite-se a variação da curva de risco basal entre os estratos

- Melhora na qualidade da estimativa do efeito das covariáveis

✓ Caso indicado:

- Pode-se estimar o efeito das covariáveis para cada estrato

Análise de Sobrevida Aplicada à Saúde -- 2014

- Causa da insuficiência renal: doença congênita
 - √ Padrão de sobrevivência pode ser muito diferente (pacientes mais jovens são mais transplantados)
- Análise dessa hipótese
 - √ Utilizar doença congênita no modelo
 - Aditivamente, como estrato e com interação entre o estrato e a idade

```
> congenita.simples <- survreg(Surv(tempo, status)~idade + congenita,
+ data = dialise, dist='weibull')
> congenita.strat <- survreg(Surv(tempo, status)~idade + strata(congenita),
+ data = dialise, dist='weibull')
> congenita.inter <- survreg(Surv(tempo, status)~idade*strata(congenita)
+ data = dialise, dist='weibull')
```

Análise de Sobrevivência Aplicada à Saúde -- 2014

• Doença congênita incluída aditivamente

```
> summary(congenita.simples)
Call:
survreg(formula = Surv(tempo, status) ~ idade + congenita, data = dialise,
        dist = "weibull")

            Value Std. Error      z      p
(Intercept)  6.7357    0.14647  45.99 0.00e+00
idade       -0.0437    0.00223 -19.58 2.20e-85
congenita    0.9781    0.27457   3.56 3.67e-04
Log(scale)  0.1971    0.02082   9.47 2.82e-21
Scale= 1.22

Weibull distribution
Loglik(model)= -7869.3  Loglik(intercept only)= -8104.2
      Chisq= 469.95 on 2 degrees of freedom, p= 0
Number of Newton-Raphson Iterations: 7
n= 6805
```

Coefficientes significativos

$$\hat{\beta}_0 = -6,7357$$

$$\hat{\beta}_{idade} = 0,0437$$

$$\hat{\beta}_{cong} = -0,9781$$

$$\hat{\sigma}_{global} = 1,22$$

$$\hat{\gamma}_{global} = \frac{1}{\hat{\sigma}} = 0,820$$

Análise de Sobrevivência Aplicada à Saúde -- 2014

Modelo Simples – Comentários

- Adaptação para compatibilização entre saída do R e o texto
 - √ Parâmetro α : $\hat{\alpha} = \exp\{-x'\beta\}$
 - √ Parâmetro γ : $\hat{\gamma} = \frac{1}{\hat{\sigma}} = \frac{1}{scale}$
- Erro padrão e teste de significância ($\gamma=1$)

$$\ln(scale) = \ln\left(\frac{1}{\hat{\gamma}}\right)$$
- O risco de morrer diminui à medida que aumenta o tempo do paciente em hemodiálise ($\gamma < 1$)
 - √ Sem distinção entre os dois grupos

Análise de Sobrevivência Aplicada à Saúde -- 2014

• Estratificação por doença congênita

```
> summary(cong.strat)
Call:
survreg(formula = Surv(tempo, status) ~ idade + strata(congenita),
        data = dialise, dist = "weibull")

            Value Std. Error      z      p
(Intercept)  6.7385    0.14645  46.01 0.00e+00
idade       -0.0434    0.00223 -19.50 1.17e-84
congenita=0  0.2047    0.02087   9.81 1.02e-22
congenita=1 -0.2716    0.11620  -2.34 1.94e-02

Scale:
congenita=0 congenita=1
      1.227      0.762

Weibull distribution
Loglik(model)= -7870.3  Loglik(intercept only)= -8097
      Chisq= 453.49 on 1 degrees of freedom, p= 0
Number of Newton-Raphson Iterations: 7
n= 6805
```

Coefficientes significativos

$$\hat{\beta}_0 = -6,7385$$

$$\hat{\beta}_{idade} = 0,0434$$

$$\hat{\gamma}_{cong=0} = \frac{1}{1,227} = 0,814$$

$$\hat{\gamma}_{cong=1} = \frac{1}{0,762} = 1,312$$

Análise de Sobrevivência Aplicada à Saúde

Modelo Estratificado – Comentários

- Efeito da doença congênita não é estimado quando a variável é usada para estratificação
- Há parâmetros de escala diferentes para cada categoria
 - √ Congênita = 0
 - O risco de morrer diminui com o tempo de hemodiálise
 - √ Congênita = 1
 - O risco de morrer aumenta com o tempo de hemodiálise

Análise de Sobrevivência Aplicada à Saúde -- 2014

• Interação entre doença congênita e idade

```
> summary(congenita.inter)
Call:
survreg(formula = Surv(tempo, status) ~ idade * strata(congenita),
        data = dialise, dist = "weibull")
```

	Value	Std. Error	z	P
(Intercept)	6.74462	0.14648	46.046	0.00e+00
idade	-0.04375	0.00223	-19.602	1.48e-85
idade:strata(congenita)congenita=1	0.00735	0.00446	1.649	9.92e-02
congenita=0	0.20041	0.02091	9.583	9.45e-22
congenita=1	-0.11184	0.15546	-0.719	4.72e-01

Interação não significativa

Log scale

Scale:

congenita=0	congenita=1
1.222	0.894

Weibull distribution

Loglik(model) = -7868.1 Loglik(intercept only) = -8097

Chisq = 457.81 on 2 degrees of freedom, p = 0

Number of Newton-Raphson Iterations: 17

n = 6805

$$\hat{\beta}_0 = -6,7446$$

$$\hat{\beta}_{idade} = 0,04375$$

$$\hat{\beta}_{(idade) \times (congenita)} = 0,040735 = 0$$

$$\hat{\gamma}_{cong=0} = \frac{1}{1,222} = 0,818$$

$$\hat{\gamma}_{cong=1} = \frac{1}{0,894} = 1,118$$

Análise de Sobrevivência Aplicada à Saúde -- 2014

Modelo Estratificado – Comentários

- Efeito da interação entre idade e a variável doença congênita não é significativa
- Há parâmetros de escala diferentes para cada categoria
 - √ Congênita = 0
 - O risco de morrer diminui com o tempo de hemodiálise
 - √ Congênita = 1
 - O risco de morrer aumenta com o tempo de hemodiálise

Análise de Sobrevivência Aplicada à Saúde -- 2014

• Resumos dos modelos – Saídas do R

	Modelos		
	cong.simples	cong.strat	cong.inter
Coefficientes (β)			
Intercept	6.7357	6.7385	6.74462
idade	-0.0437	-0.0434	-0.04375
congenita	0.9781		
idade:strata(congenita)=1			0.00735
Scale			
Global	1,22		
congenita=0		1.227	1.222
Congenita=1		0.762	0.894

Análise de Sobrevivência Aplicada à Saúde -- 2014

• Estimação dos parâmetros de forma

$$\hat{\gamma} = \frac{1}{\hat{\sigma}} = \frac{1}{\text{scale}}$$

```
> # Parâmetros de Forma
> # Modelo simples
> 1/cong.simples$scale
[1] 0.8210882
> # Modelo estratificado
> 1/cong.strat$scale
congenita=0 congenita=1
0.8148844 1.3121269
> # Modelo estratificado c/ interação
> 1/cong.inter$scale
congenita=0 congenita=1
0.8183929 1.1183291
```

Análise de Sobrevivência Aplicada à Saúde -- 2014

• Estimação dos riscos relativos

```
> # Risco Relativo
> # Modelo simples
> exp(-cong.simples$coeff[-1])^(1/cong.simples$scale)
idade congenita
1.0365145 0.4479174
> # Modelo estratificado para congenita=0
> exp(-cong.strat$coeff[-1])^(1/cong.strat$scale[1])
idade
1.035988
> # Modelo estratificado para congenita=1
> exp(-cong.strat$coeff[-1])^(1/cong.strat$scale[2])
idade
1.058581
> # Modelo estratificado com interação
> # congenita = 0
> exp(-cong.inter$coeff[2])^(1/cong.inter$scale[1])
idade
1.036457
> # Modelo estratificado com interação
> # congenita = 1
> exp(-sum(cong.inter$coeff[2:3]))^(1/cong.inter$scale[2])
congenita=1
1.041548
```

$[\exp\{\beta\}]^\gamma$

Análise de Sobrevivência Aplicada à Saúde -- 2014

• Estimativas do risco relativo ($\exp(\beta)^\gamma$)

Variáveis	Modelos		
	Simple	Estratificado	Interação
Idade	1,036		
Congênita = Não		1,034	1,036
Congênita = Sim		1,058	1,041
Congênita	0,448		
Forma (g)	0,821		
Congênita = Não		0,815	0,818
Congênita = Sim		1,312	1,118

Análise de Sobrevivência Aplicada à Saúde -- 2014

Comentários

- Parâmetro de forma (γ)
 - √ É bastante diferente para o estrato de pacientes cuja insuficiência renal foi causada por doença congênita
 - √ $\gamma_{\text{global}} \approx \gamma_{\text{congenita}=0}$
 - Somente 2% dos pacientes possuem doença congênita
- Aumento do risco de morrer para cada ano de vida
 - √ Maior no estrato dos pacientes com doença congênita
 - √ Mantém-se próximos em todos os modelos para o estrato dos pacientes sem doença congênita

Análise de Sobrevivência Aplicada à Saúde -- 2014

• Equações de risco dos modelos estimados

√ Modelo simples

$$\hat{\lambda}(t|\mathbf{x}) = (0,821)t^{0,821-1}[\exp\{-6,735 + 0,044 \times idade - 0,978 \times congenita\}]^{0,821}$$

√ Modelo estratificado

- Congênita = Não

$$\hat{\lambda}(t|\mathbf{x}) = (0,815)t^{0,815-1}[\exp\{-6,739 + 0,0433 \times idade\}]^{0,815}$$

- Congênita = Sim

$$\hat{\lambda}(t|\mathbf{x}) = (1,312)t^{1,312-1}[\exp\{-6,739 + 0,0433 \times idade\}]^{1,312}$$

Análise de Sobrevivência Aplicada à Saúde -- 2014

√ Modelo estratificado com interação

- Congênita = Não

$$\hat{\lambda}(t|\mathbf{x}) = (0,818)t^{0,818-1}[\exp\{-6,745 + 0,044 \times idade\}]^{0,818}$$

- Congênita = Sim

$$\hat{\lambda}(t|\mathbf{x}) = (1,118)t^{1,118-1}[\exp\{-6,745 + (0,044 - 0,007) \times idade\}]^{1,118}$$

Análise de Sobrevivência Aplicada à Saúde -- 2014

Exemplo

• Sobrevivência ao diagnóstico de Aids

√ Pacientes com tempo de observação menor que 193 dias

- Óbitos: 90

- Censuras: 103

√ Objetivo:

- Estimar o efeito do tratamento controlado por idade e sexo

Análise de Sobrevivência Aplicada à Saúde -- 2014

• Modelo de regressão paramétrico – Exponencial:

```
> modhiv.exp <- survreg(Surv(tempo, status)~idade, data = hiv,
+ dist='exponential')
> modhiv.exp <- survreg(Surv(tempo, status)~idade + sexo + tratam,
+ data = hiv, dist='exponential')
> summary(modhiv.exp)

Call:
survreg(formula = Surv(tempo, status) ~ idade + sexo + tratam,
data = hiv, dist = "exponential")

      Value Std. Error      z      p
(Intercept)  6.11597    0.4921 12.429 1.83e-35
idade        0.00829    0.0112  0.739 4.60e-01
sexoM       -0.19455    0.2841 -0.685 4.93e-01
tratam       1.37541    0.1920  7.164 7.83e-13

Scale fixed at 1

Exponential distribution
Loglik(model)= -743.5  Loglik(intercept only)= -774.6
Chisq= 62.3 on 3 degrees of freedom, p= 1.9e-13
Number of Newton-Raphson Iterations: 5
n= 193
```

Análise de Sobrevivência Aplicada à Saúde -- 2014

• Modelo de regressão paramétrico – Weibull:

```
> modhiv.wei <- survreg(Surv(tempo, status)~idade + sexo + tratam
+ data = hiv, dist='weibull')
> summary(modhiv.wei)

Call:
survreg(formula = Surv(tempo, status) ~ idade + sexo + tratam,
data = hiv, dist = "weibull")

      Value Std. Error      z      p
(Intercept)  6.06842    0.5674 10.695 1.07e-26
idade        0.00951    0.0130  0.731 4.65e-01
sexoM       -0.23627    0.3277 -0.721 4.71e-01
tratam      1.48608    0.2273  6.538 6.25e-11
Log(scale)  0.14185    0.0862  1.647 9.97e-02

Scale= 1.15

Weibull distribution
Loglik(model)= -742  Loglik(intercept only)= -770.3
Chisq= 56.64 on 3 degrees of freedom, p= 3.1e-12
Number of Newton-Raphson Iterations: 5
n= 193
```

Análise de Sobrevivência Aplicada à Saúde -- 2014

Modelo de Tempo de Vida Acelerado

$$Y = \ln(T) = \mathbf{x}'\beta + \sigma v$$

- ✓ Bastante utilizado na prática
- ✓ Covariáveis aceleram (desaceleram) o tempo de vida

• Distribuição para v:

- ✓ Valor extremo (T é Weibull)
- ✓ Normal (T é lognormal)
- ✓ Log-gama (T é gama)
- ✓ Logística (T é log-logística)

Análise de Sobrevivência Aplicada à Saúde -- 2014

• Modelo de tempo de vida acelerado

$$Y = \ln(T) = \mathbf{x}'\beta + \sigma v$$

• Modelo na escala original

$$T = \exp\{\mathbf{x}'\beta\} \exp\{\sigma v\}$$

- ✓ Generalização em termos paramétricos
 - Acréscimo de mais um parâmetro de forma (Ex.: gama generalizada)
- ✓ Generalização mais utilizada:
 - Modelo semiparamétrico de Cox (modelos acelerados aparecem como casos particulares)

Análise de Sobrevivência Aplicada à Saúde -- 2014

• Modelo de Vida Acelerada – Interpretação:

- ✓ Vida acelerada:
 - σv : distribuição de referência quando $\mathbf{x} = 0$
- ✓ Escala original
 - $T_0 = \exp\{\sigma v\}$: distribuição de referência na escala original
- ✓ Probabilidade de indivíduo de referência estar vivo no tempo t:

$$S_0(t) = P\{T_0 > t\} = P\left\{Y > \left(\frac{t}{\sigma}\right)\right\}$$

✓ Considerando o efeito das covariáveis

$$T \sim T_0 e^{\mathbf{x}'\beta}$$

- Covariáveis agem multiplicativamente no tempo de sobrevivência

Análise de Sobrevivência Aplicada à Saúde -- 2014

- Probabilidade de indivíduo com valores de covariáveis \mathbf{x} estar vivo no tempo t :

$$\begin{aligned} S(t|\mathbf{x}) &= P\{T > t|\mathbf{x}\} = P\{T_0 e^{\mathbf{x}'\boldsymbol{\beta}} > t\} \\ &= P\{T_0 > t e^{-\mathbf{x}'\boldsymbol{\beta}}\} \\ &= S_0(t e^{-\mathbf{x}'\boldsymbol{\beta}}) \end{aligned}$$

- √ Probabilidade de indivíduo com valor \mathbf{x} de covariáveis estar vivo no tempo t é a mesma probabilidade de indivíduo de referência estar vivo no tempo $t e^{-\mathbf{x}'\boldsymbol{\beta}}$
- √ O tempo passa mais rapidamente por um fator $e^{-\mathbf{x}'\boldsymbol{\beta}}$
 - (duas vezes mais rápido, metade mais rápido)

Análise de Sobrevivência Aplicada à Saúde -- 2014

- Modelos de tempo de vida acelerados–Inferência:
 - √ Propriedades assintóticas dos estimadores de máxima verossimilhança
 - √ Forma geral da função de verossimilhança

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

- Especificação de distribuição para T (ou para Y) determinam completamente a função de verossimilhança
- Estimadores de máxima verossimilhança e suas propriedades (construção de intervalos de confiança e testes de hipóteses)

Análise de Sobrevivência Aplicada à Saúde -- 2014

Comandos em R

m : objeto que contém resultado do ajuste

> `summary(m)`

√ `Call`: modelo ajustado

√ `Value`: parâmetros estimados

√ `Std. Error`: erro padrão do parâmetro estimado

√ `z`: estatística para estimativa dos parâmetros

√ `p`: p-valor da estatística z

√ `Scale`: Weibull = $1/g$; Exponencial = 1

√ `Loglik(model)`: log-verossimilhança modelo completo

√ `Loglik(intercept only)`: log-verossimilhança modelo nulo

√ `Number of Newton-Raphson Iterations`: estimação

√ `n`: número de observações

Análise de Sobrevivência Aplicada à Saúde -- 2014

- Ajuste dos modelos paramétricos de regressão

√ Formula = `Surv(temp, status) ~`

~ `var1 + var2 + ...` (covariáveis)

~ 1 (sem covariáveis)

~ `var1*var2` (interação entre variáveis)

~ `(var1:var2)` (somente inclui o termo de interação)

Análise de Sobrevivência Aplicada à Saúde -- 2014

- 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 Aplicada à Saúde -- 2014

Seleção de Modelos

Seleção de Modelos Paramétricos

- Para comparar modelos paramétricos aninhados
 - √ Teste da razão de verossimilhanças
 - √ Teste de Wald

Análise de Sobrevivência Aplicada à Saúde -- 2014

Teste da Razão de Verossimilhanças

- Pode ser usado para comparar modelos aninhados
(modelo com maior número de parâmetros contém todos os parâmetros do modelo menor)
 - √ Estatística de teste: $RV = 2(l_{maior} - l_{menor})$
 - √ Distribuição amostral: $RV \sim \chi_{gl}^2$
 - gl: diferença entre o número de parâmetros dos modelos

Análise de Sobrevivência Aplicada à Saúde -- 2014

Exemplo

- Dados de Aids
 - √ Aplicação:
 - Comparar modelos com distribuição exponencial e Weibull
 - √ Modelos:
 - H_0 : modhiv.exp = modhiv.wei ($\gamma = 1$)
 - √ Estatística de teste:
 - $RV = 2(l_{weibull} - l_{exponencial}) = 2[(-742) - (-743,5)] = 3$
 - √ Comando R:

```
> anova(modhiv.exp, modhiv.wei)

```

Terms	Resid. Df	-2*LL Test Df	Deviance	Pr(>Chi)
1 idade + sexo + tratam	189	1486.942	NA	NA
2 idade + sexo + tratam	188	1484.049	= 1 2.893647	0.08892942

Análise de Sobrevivência Aplicada à Saúde -- 2014

• Saída do modelo Weibull

```
> modhiv.wei
Call:
survreg(formula = Surv(tempo, status) ~ idade + sexo + tratam,
data = hiv, dist = "weibull")
Coefficients:
(Intercept)      idade      sexoM      tratam
6.068424160  0.009505648 -0.236267819  1.486083990
Scale= 1.152408
Loglik(model)= -742  Loglik(intercept only)= -770.3
Chisq= 56.64 on 3 degrees of freedom, p= 3.1e-12
n= 193
```

$$RV = 2[l_{estimado} - l_{nulo}] = 2[(-742) - (-770,3)] = 56,6$$

Análise de Sobrevivência Aplicada à Saúde -- 2014

Teste de Wald

- Testa a significância individual de covariáveis
 - √ $H_0: \beta_j = 0$ vs. $\beta_j \neq 0$
 - √ Estatística de teste: $z_j = \frac{\hat{\beta}_j}{ep(\hat{\beta}_j)}$
 - √ Distribuição amostral (sob H_0): $Z_j \sim N(0, 1)$

Análise de Sobrevivência Aplicada à Saúde -- 2014

• Modelo de regressão paramétrico – Weibull:

```
> modhiv.wei <- survreg(Surv(tempo, status)~idade + sexo + tratam,
+ data = hiv, dist='weibull')
> summary(modhiv.wei)
Call:
survreg(formula = Surv(tempo, status) ~ idade + sexo + tratam,
data = hiv, dist = "weibull")

```

	Value	Std. Error	z	p
(Intercept)	6.06842	0.5674	10.695	1.07e-26
idade	0.00951	0.0130	0.731	4.65e-01
sexoM	-0.23627	0.3277	-0.721	4.71e-01
tratam	1.48608	0.2273	6.538	6.25e-11
Log(scale)	0.14185	0.0862	1.647	9.97e-02

Único efeito significativo:
• tratamento

- Número de medicamentos antirretrovirais tem efeito protetor no risco de morte dos pacientes da coorte

Análise de Sobrevivência Aplicada à Saúde -- 2014

Qualidade do Ajuste

- Avaliação da qualidade do ajuste de um modelo paramétrico
 - √ Medida global de qualidade:
 - Função desvio (ou *deviance*)
 - Ferramenta gráfica

Análise de Sobrevida Aplicada à Saúde -- 2014

Deviance

- Pode ser utilizada para obter medida global de qualidade de ajuste do modelo:
 - √ H_0 : o modelo se ajusta aos dados
 - √ Estatística de teste: $D = 2[l_{saturado} - l_{modelo}]$
 - Modelo saturado: ajusta n parâmetros para as n observações
 - Modelo estimado
 - √ Parâmetros de perturbação são mantidos fixos
 - Parâmetros comuns aos dois ajustes e nos quais não há interesse no estimador
 - Ex. Parâmetro de forma no modelo de Weibull

Análise de Sobrevida Aplicada à Saúde -- 2014

- √ Quanto maior a *deviance* pior a qualidade do ajuste
- √ Distribuição amostral (sob H_0): $D \sim \chi^2_{(n-p-1)}$
 - Quanto menor a estatística, maior o p-valor e melhor a qualidade de ajuste
- √ Deviance – Comando no R

```
> # Deviance
>
> modhivwei.dev = sum(resid(modhiv.wei, type = "deviance")^2)
> modhivwei.dev
[1] 237.1074
> g1 = 198 - 3 - 1
> 1-pchisq(modhivwei.dev, g1)
[1] 0.01004656
```

Teste de qualidade global de ajuste também rejeita H_0

Análise de Sobrevida Aplicada à Saúde -- 2014

Conclusão – Modelo Weibull

	Value	Std. Error	z	p
(Intercept)	6.06842	0.5674	10.695	1.07e-26
idade	0.00951	0.0130	0.731	4.65e-01
sexoM	-0.23627	0.3277	-0.721	4.71e-01
tratam	1.48608	0.2273	6.538	6.25e-11
Log(scale)	0.14185	0.0862	1.647	9.97e-02

Scale= 1.15

- √ Para cada medicamento acrescido no tratamento o risco diminui em 72,5%

$$\exp\{-1,486\}^{1/1,15} = 0,275$$

Análise de Sobrevida Aplicada à Saúde -- 2014

• Conclusão – Modelo Exponencial

```
> summary(modhiv.tratam)
Call:
survreg(formula = Surv(tempo, status) ~ tratam, data = hiv, dist = "exponential")

      Value Std. Error      z      p
(Intercept)  6.23      0.173 36.02 3.41e-284
tratam      1.41      0.187  7.57 3.88e-14
Scale fixed at 1

Exponential distribution
Loglik(model) = -744  Loglik(intercept only) = -774.6
Chisq = 61.32 on 1 degrees of freedom, p = 4.9e-15
```

√ Para cada medicamento acrescido no tratamento o risco diminui em 75,6%
 $\exp\{-1,41\} = 0,244$

• Critério AIC

- √ Modelos exponencial (tratam)
- √ Modelo Weibull (idade + sexo + tratam)
- √ Modelo exponencial (idade + sexo + tratam)

```
> AIC(modhiv.tratam, modhiv.wei, modhiv.exp)
      df      AIC
modhiv.tratam  2 1491.924
modhiv.wei     5 1494.049
modhiv.exp     4 1494.942
```

$$AIC = 2 \left[p - l(\hat{\beta}_0, \hat{\beta}_{tratam}) \right]$$

$$= 2[2 - (-743.9620)]$$

$$= 1.491,924$$

– Quanto menor o valor do Critério de Informação de Akaike (AIC), melhor o ajuste do modelo aos dados

Análise Gráfica do Ajuste

- Ferramenta exploratória
 - √ Auxiliar na escolha de distribuições candidatas
- Gráficos:
 - √ $\log(\Lambda(t))$ vs. $\log(t)$
 - √ Comparação de curvas de sobrevivência
 - Estimador de Kaplan-Meier vs. Estimação paramétrica

1. Gráfico de $\log(\Lambda(t))$ vs. $\log(t)$

- √ $\log(\Lambda(t)) = \log(-\log(S(t)))$
- √ Avaliação suposição de proporcionalidade dos riscos
- √ Forma d risco
 - Weibull: esperam-se retas paralelas
 - Exponencial: inclinação igual a 1
 - Curvas coincidentes: parâmetro referente à covariável provavelmente não será significativo

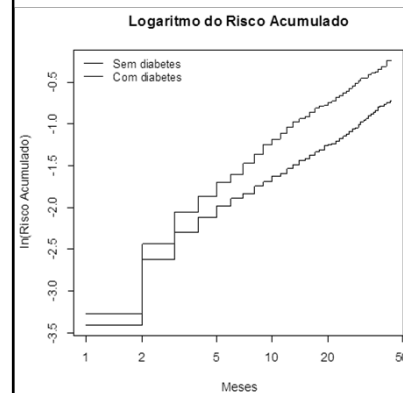
Exemplo

- Pacientes com insuficiência renal submetidos à hemodiálise
 - √ Período: janeiro/1988 a outubro/2001
 - √ Dados: Sistema Apac
 - √ Coorte com 6.805 pacientes, no Rio de Janeiro
 - 1.603 óbitos
 - √ Covariável:
 - Presença de diabetes
 - √ Modelo de regressão paramétrico de Weibull é candidato?

Análise de Sobrevivência Aplicada à Saúde -- 2014

√ Gráfico do log(Risco acumulado)

– Pacientes com e sem diabetes



- Retas paralelas
- Modelo de Weibull aparenta ser adequado

Análise de Sobrevivência Aplicada à Saúde -- 2014

2. Comparação de curvas de sobrevivências

- √ Estimativa por Kaplan-Meier vs. curvas estimadas parametricamente
- √ Quanto mais próximo o modelo paramétrico estiver da curva de sobrevivência do estimador e Kaplan-Meier, melhor o modelo


Análise de Sobrevivência Aplicada à Saúde -- 2014

Exemplo – Continuação

- Pacientes com insuficiência renal submetidos à hemodiálise
 - √ Covariável:
 - Presença ou ausência de diabetes
 - √ Objetivo:
 - Comparação de curvas de sobrevivência:
 - Estimativa não paramétrica de Kaplan-Meier
 - Estimativa do modelo de regressão exponencial
 - Estimativa do modelo de regressão de Weibull

Análise de Sobrevivência Aplicada à Saúde -- 2014

✓ Comparação de curvas de sobrevivência



- Modelo que mais se aproxima da estimação não paramétrica
- Modelo de regressão de Weibull

Análise de Sobrevivência Aplicada à Saúde -- 2014

Comentários

- ✓ Análises gráficas de avaliação de qualidade do ajuste do modelo são mais indicadas do que testes estatísticos formais
 - Tendem a ter baixo poder para amostras pequenas e rejeitar o modelo para amostras grandes
- ✓ Os métodos apresentados devem ser usados para descartar modelos claramente inapropriados
 - E não para demonstrar que um modelo paramétrico é melhor
 - (nesse caso o melhor é análise de resíduos)

Análise de Sobrevivência Aplicada à Saúde -- 2014

- ✓ É comum diferentes modelos paramétricos terem ajustes razoáveis para um mesmo conjunto de dados
 - Especialmente nos intervalos que concentram um maior número de observações, apresentando resultados semelhantes das quantidades de interesse

Análise de Sobrevivência Aplicada à Saúde -- 2014

Análise de Resíduos

- No contexto de sobrevivência, a definição de uma medida de resíduo não clara
- Resíduos para modelos paramétricos:
 - ✓ Resíduos de perturbação para modelos tempos de vida acelerados
- Resíduos para modelos de Cox
 - ✓ Resíduo de Schoenfeld
 - Avaliação do pressuposto de proporcionalidade

Análise de Sobrevivência Aplicada à Saúde -- 2014

- Resíduos para modelos paramétricos e de Cox:
 - √ Resíduo de Cox-Snell
 - √ Resíduo martingale
 - √ Resíduo *deviance*
 - √ Resíduo de escore

Análise de Sobrevivência Aplicada à Saúde -- 2014

- Resíduos de perturbação para modelos tempos de vida acelerados
 - √ Avaliam o impacto da retirada de uma observação no ajuste global do modelo
 - √ Tipos:
 - Mede mudança no vetor estimado de parâmetros
 - Mede mudança na resposta predita (em desvios padrão)
 - Avalia efeito sobre parâmetro de forma

Análise de Sobrevivência Aplicada à Saúde -- 2014

- Objetivo
 - √ Identificar pontos influentes do modelo
 - √ Verificar seu impacto sobre
 - Conjunto de parâmetros de regressão: **ldcase**
 - Valores preditos: **ldresp**
 - Parâmetro de forma: **ldshape**
- Comandos em R:
 - √ Para identificar indivíduos muito afastados
 - Usar função **identify**

Análise de Sobrevivência Aplicada à Saúde -- 2014

Exemplo – Continuação

- Sobrevivência ao diagnóstico de Aids
 - √ Pacientes com tempo de observação menor que 193 dias
 - Óbitos: 90
 - Censuras: 103
 - √ Objetivo:
 - Determinar os resíduos do modelo paramétrico de Weibull
 - Identificar e analisar possíveis pontos influentes

Análise de Sobrevivência Aplicada à Saúde -- 2014

• Modelo de regressão paramétrico – Weibull:

```
> modhiv.wei <- survreg(Surv(tempo, status)~idade + sexo + tratam
+ data = hiv, dist='weibull')
> summary(modhiv.wei)

Call:
survreg(formula = Surv(tempo, status) ~ idade + sexo + tratam,
data = hiv, dist = "weibull")

            Value Std. Error      z      p
(Intercept)  6.06842    0.5674 10.695 1.07e-26
idade        0.00951    0.0130  0.731 4.65e-01
sexoM       -0.23627    0.3277 -0.721 4.71e-01
tratam      1.48608    0.2273  6.538 6.25e-11
Log(scale)  0.14185    0.0862  1.647 9.97e-02

Scale= 1.15

Weibull distribution
Loglik(model)= -742  Loglik(intercept only)= -770.3
      Chisq= 56.64 on 3 degrees of freedom, p= 3.1e-12
Number of Newton-Raphson Iterations: 5
n= 193
```

Análise de Sobrevivência Aplicada à Saúde -- 2014

• Identificação dos resíduos


```
> # Análise de Resíduos de Perturbação - Modelo de Weibull
>
> res.ldcase <- residuals(modhiv.wei, type = "ldcase")
> res.x = 1:length(res.ldcase)
> plot(res.ldcase, xlab = "Índice")
> title("Vetor de Parâmetros")
> idx.ldcase<-identify(x = res.x, y = res.ldcase, n = 5 )
>
> res.ldresp <- residuals(modhiv.wei, type = "ldresp")
> plot(res.ldresp, xlab = "Índice")
> title("Valores Preditos")
> idx.ldresp<-identify(x = res.x, y = res.ldresp, n = 5)
>
> res.ldshape <- residuals(modhiv.wei, type = "ldshape")
> plot(res.ldshape, xlab = "Índice")
> title("Parâmetro de Forma")
> idx.ldshape<-identify(x = res.x, y = res.ldshape, n = 5)
>
> idx<-as.numeric(levels(as.factor(c(idx.ldcase, idx.ldresp, idx.ldshape))))
> idx
[1]  9 10 49 82 182
```

Análise de Sobrevivência Aplicada à Saúde -- 2014

✓ Resíduos de perturbação de verossimilhança

- Coorte de Aids – modelo de regressão de Weibull


Vetor de Parâmetros




- Casos identificados:

- 9, 10, 49, 82, 182

Valores Preditos



Parâmetro de Forma



Análise de Sobrevivência Aplicada à Saúde -- 2014

• Casos identificados nos gráficos:

```
> idx
[1]  9 10 49 82 182
> hiv[idx,c("tempo", "status", "sexo", "idade", "tratam")]
      tempo status sexo idade tratam
9      1563     1   M    44      0
10     1247     1   M    23      0
49     1344     0   M    30      0
82     1272     0   M    22      0
182      16     1   M    42      3
```

✓ Casos 9 e 10:

- Sobreviveram um longo tempo

✓ Casos 49 e 82:

- Censurados sem receber antirretroviral

✓ Caso 182:

- Morreu rapidamente e recebeu 3 medicamentos

Análise de Sobrevivência Aplicada à Saúde -- 2014

• Modelo de regressão de Weibull, sem o caso 82

√ Aparece nos três gráficos

```
> summary(survreg( formula = Surv(tempo, status) ~ idade + sexo + tratam,
+ data = hiv, dist = "weibull", subset = -82))
Call:
survreg(formula = Surv(tempo, status) ~ idade + sexo + tratam,
data = hiv, subset = -82, dist = "weibull")
      Value Std. Error      z      p
(Intercept)  5.7996    0.5760 10.069 7.60e-24
idade        0.0151    0.0133  1.137 2.55e-01
sexoM       -0.2603    0.3231 -0.806 4.20e-01
tratam       1.5490    0.2266  6.836 8.16e-12
Log(scale)   0.1281    0.0857  1.496 1.35e-01
Scale= 1.14
Weibull distribution
Loglik(model)= -739.2  Loglik(intercept only)= -769.7
      Chisq= 61.03 on 3 degrees of freedom, p= 3.5e-13
Number of Newton-Raphson Iterations: 5
n= 192
```

Análise de Sobrevivência Aplicada à Saúde -- 2014

• Modelo de regressão paramétrico – Weibull:

```
> modhiv.wei <- survreg(Surv(tempo, status)~idade + sexo + tratam
+ data = hiv, dist='weibull')
> summary(modhiv.wei)
Call:
survreg(formula = Surv(tempo, status) ~ idade + sexo + tratam,
data = hiv, dist = "weibull")
      Value Std. Error      z      p
(Intercept)  6.06842    0.5674 10.695 1.07e-26
idade        0.00951    0.0130  0.731 4.65e-01
sexoM       -0.23627    0.3277 -0.721 4.71e-01
tratam       1.48608    0.2273  6.538 6.25e-11
Log(scale)   0.14185    0.0862  1.647 9.97e-02
Scale= 1.15
Weibull distribution
Loglik(model)= -742  Loglik(intercept only)= -770.3
      Chisq= 56.64 on 3 degrees of freedom, p= 3.1e-12
Number of Newton-Raphson Iterations: 5
n= 193
```

Análise de Sobrevivência Aplicada à Saúde -- 2014

√ Modelo de Weibull – Comparação das estimativas dos parâmetros e da log-verossimilhança

	Completo	Sem indivíduo 82
Intercept	6,0684	5,7996
Idade	0,0095	0,0151
sexoM	-0,2363	-0,2603
tratam	1,4861	1,5490
Scale	1,1524	1,1367
Shape	0,868	0,880
Loglik(model)	-742,02	-739,21

√ Alteração das estimativas dos parâmetros (**ldcase**)

√ Aumento da log-verossimilhança (**ldresp**)

√ Mudança na estimativa do parâmetro de forma (**ldshape**)

Análise de Sobrevivência Aplicada à Saúde -- 2014

Exemplo

• Sobrevida de pacientes com leucemia aguda

√ Tempo de sobrevivência a diagnóstico (semanas)

√ 17 pacientes com leucemia aguda

√ Dados sem censura

√ Covariável

– wbc: contagem de glóbulos brancos na data do diagnóstico

– lwbc: $\log_{10}(\text{WBC})$

Análise de Sobrevivência Aplicada à Saúde -- 2014

√ Pacientes com leucemia – Conjunto de dados

```
temp<-c(65,156,100,134,16,108,121,4,39,143,56,26,22,1,1,5,65)
cens<-rep(1,17)
lwbc<-c(3.36,2.88,3.63,3.41,3.78,4.02,4.00,4.23,3.73,3.85,3.97,
4.51,4.54,5.00,5.00,4.72,5.00)
dados<-cbind(temp,cens,lwbc)
dados<-as.data.frame(dados)
dados
  temp cens lwbc
1    65   1 3.36
2   156   1 2.88
3   100   1 3.63
4   134   1 3.41
5    16   1 3.78
6   108   1 4.02
7   121   1 4.00
8     4   1 4.23
9    39   1 3.73
10  143   1 3.85
11   56   1 3.97
12   26   1 4.51
13   22   1 4.54
14    1   1 5.00
15    1   1 5.00
16    5   1 4.72
17   65   1 5.00
```

Dados sem censura

– Inviável estratificação pela covariável lwbc

Análise de Sobrevivência Aplicada à Saúde -- 2014

• Modelo de regressão para análise dos dados

√ Gráficos de linearização - sem a covariável: lwbc

• Candidatas:

- Exponencial
- Weibull

Análise de Sobrevivência Aplicada à Saúde -- 2014

√ Modelo de regressão linear

– Covariável: $X_1 = \log(\text{WBC})$

– Exponencial e Weibull

```
> leuk.exp<-survreg(Surv(temp, cens)~ lwbc,
+ data = dados, dist='exponential')
> summary(leuk.exp)
Call:
survreg(formula = Surv(temp, cens) ~ lwbc,
data = dados, dist = "exponential")

              Value Std. Error z      p
Intercept)  8.48    1.711  4.95 7.27e-07
lwbc       -1.11    0.414 -2.68 7.31e-03
Scale fixed at 1

Exponential distribution
loglik(model)= -83.9  Loglik(intercept only)= -87.1
ChiSq= 6.83 on 1 degrees of freedom, p= 0.008
Number of Newton-Raphson Iterations: 5
#= 17
> leuk.exp$loglik
[1] -87.28983 -83.87705

> leuk.wei<-survreg(Surv(temp, cens)~ lwbc,
+ data = dados, dist='weibull')
> summary(leuk.wei)
Call:
survreg(formula = Surv(temp, cens) ~ lwbc,
data = dados, dist = "weibull")

              Value Std. Error z      p
Intercept)  8.4408    1.709  4.940 7.81e-07
lwbc       -1.0982    0.418 -2.630 8.53e-03
Log(scale) -0.0216    0.202 -0.107 9.15e-01
Scale= 0.979

Weibull distribution
loglik(model)= -83.9  Loglik(intercept only)= -87.1
ChiSq= 6.48 on 1 degrees of freedom, p= 0.012
Number of Newton-Raphson Iterations: 6
#= 17
> leuk.wei$loglik
[1] -87.10948 -83.87136
```

Log scale não significativo

$\hat{\beta}_0 = -8,4775$

$\hat{\beta}_{lwbc} = 1,1093$

$\hat{\beta}_0 = -8,4408$

$\hat{\beta}_{lwbc} = 1,0982$

$\hat{\gamma} = \frac{1}{\text{scale}} = \frac{1}{0,979} = 1,0218$

Análise de Sobrevivência Aplicada à Saúde -- 2014

• Estimativas para os dados de leucemia aguda

Regressão	
Exponencial	Weibull
$\beta_0 = -8,4775$	$\beta_0 = -8,4408$
$\beta_1 = 1,1093$	$\beta_1 = 1,0982$
$\gamma = 1$ (fixo)	$\gamma = 1,0218$

√ Estimativa de γ muito próxima de 1

- (log scale é não significativo)
- Indicativo de que o modelo é exponencial ($\gamma=1$)

√ Teste da razão da verossimilhança

- Weibull e exponencial são aninhados

$RV = 2(83,8771 - 83,8714) = 0,0113$ $p = P\{\chi_1^2 > 0,0113\} = 0,915$

– Resultado fornece indicações favoráveis ao modelo de regressão exponencial

Análise de Sobrevivência Aplicada à Saúde -- 2014

• Avaliação do ajuste

√ Resíduos de Cox-Snell – modelo exponencial

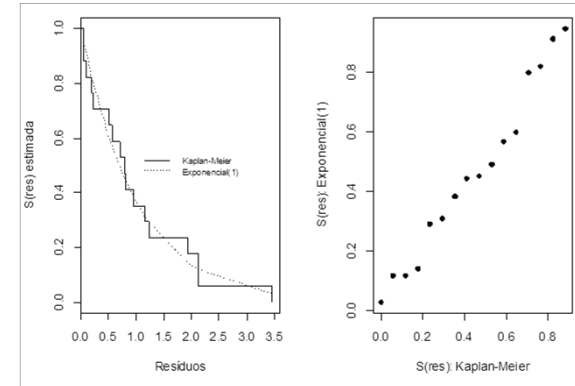
$$\hat{\epsilon}_i = \hat{\Lambda}(t_i|x_1) - \ln[S(t_i|x_1)] = \left[t_i \exp\{\hat{\beta}_0 + \hat{\beta}_1 x_1\} \right]$$

√ Se o modelo for adequado

- Resíduos seguem distribuição exponencial padrão
- Curvas de sobrevivência dos resíduos, por Kaplan-Meier e exponencial padrão devem estar próximas
- Gráfico dos pontos ($S_{KM}(res)$, $S_{exp}(res)$) devem se aproximar de uma reta

Análise de Sobrevivência Aplicada à Saúde -- 2014

√ Análise gráfica dos resíduos Cox-Snell – Exponencial



- Exponencial padrão parece aceitável (modelo adequado)

Análise de Sobrevivência Aplicada à Saúde -- 2014

• Teste da razão de verossimilhanças

√ $H_0: \beta_1 = 0$

√ Estatística de teste

$$RV = 2(87.2898 - 83.8771) = 6,825$$

√ Probabilidade de significância

$$p = P\{\chi_1^2 > 6,825\} = 0.0090$$

√ Rejeita-se H_0

- É possível que parte da variação observada nos tempos de sobrevivência dos pacientes pode ser explicada pela contagem de glóbulos brancos

Análise de Sobrevivência Aplicada à Saúde -- 2014

• Modelo de regressão exponencial

√ Função de sobrevivência estimada


$$S(t|x_1) = \exp\{-\exp\{-8,4775 + 1.1093x_1\}t\}, t \geq 0$$

√ Na expressão, β_1 é positivo

- Quanto maior o valor de x_1 , menor a probabilidade de sobrevivência estimada

Análise de Sobrevivência Aplicada à Saúde -- 2014

√ Curvas de sobrevivência para valores de lwbc



- $S(100 | x_1 = 4) = 17\%$ (estarão vivos em 100 semanas)
- $S(100 | x_2 = 3) = 56\%$

Análise de Sobrevivência Aplicada à Saúde -- 2014

• Comentários

√ Modelo de regressão exponencial ajustou-se satisfatoriamente aos dados

√ Conclusão:

- Tempo estimado diminui à medida que são observadas contagens crescentes de glóbulos brancos, no diagnóstico

√ Probabilidade de sobrevivência dado valor de x_1 :

$$S(t|x_1) = \exp\{-\exp\{-8,4775 + 1.1093x_1\}t\}, t \geq 0$$

Análise de Sobrevivência Aplicada à Saúde -- 2014

Exemplo

• Sobrevivência de pacientes com leucemia aguda

√ Tempo de sobrevivência a diagnóstico (semanas)

- 17 pacientes que expressam antígeno Calla (Ag+)
- 16 paciente que não expressam antígeno Calla (Ag-)

√ Dados sem censura

√ Covariáveis

- X_1 : lwbc: $\log_{10}(\text{WBC})$
- X_2 : grupo (0, se grupo Ag+; 1, se grupo Ag-).

√ Foi escolhido modelo de regressão exponencial para o grupo Ag+.

- Investigar se o mesmo se aplica ao grupo Ag-

Análise de Sobrevivência Aplicada à Saúde -- 2014

√ Pacientes com leucemia – Conjunto de dados

```

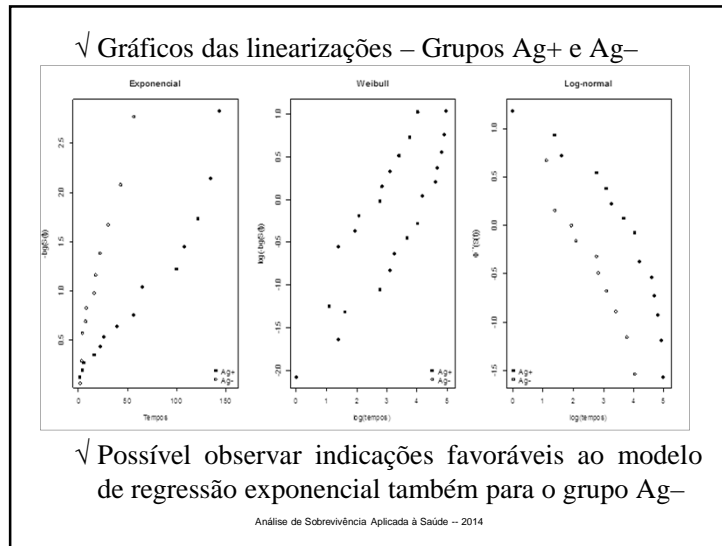
> tempo <- c(65,156,100,134,16,108,121,4,39,143,56,26,22,1,1,5,65,
+           56,65,17,7,16,22,3,4,2,3,8,4,3,30,4,43)
> status <- c(rep(1,17),rep(1,16))
> lwbc <-
+ c(3.36,2.88,3.63,3.41,3.78,4.02,4,4.23,3.73,3.85,3.97,4.51,4.54,5,5,4.72,
+ 3.64,3.48,3.6,3.18,3.95,3.72,4,4.28,4.43,4.45,4.49,4.41,4.32,4.90,5,5)
> grupo <- c(rep(0,17),rep(1,16))
> dados<-cbind(tempo, status, lwbc, grupo)
> dados<-as.data.frame(dados)

```

Dados sem censura

tempo	status	lwbc	grupo	tempo	status	lwbc	grupo
1	65	1 3.36	0	18	56	1 3.64	1
2	156	1 2.88	0	19	65	1 3.48	1
3	100	1 3.63	0	20	17	1 3.60	1
4	134	1 3.41	0	21	7	1 3.18	1
5	16	1 3.78	0	22	16	1 3.95	1
6	108	1 4.02	0	23	22	1 3.72	1
7	121	1 4.00	0	24	3	1 4.00	1
8	4	1 4.23	0	25	4	1 4.28	1
9	39	1 3.73	0	26	2	1 4.43	1
10	143	1 3.85	0	27	3	1 4.45	1
11	56	1 3.97	0	28	8	1 4.49	1
12	26	1 4.51	0	29	4	1 4.41	1
13	22	1 4.54	0	30	3	1 4.32	1
14	1	1 5.00	0	31	30	1 4.90	1
15	1	1 5.00	0	32	4	1 5.00	1
16	5	1 4.72	0	33	43	1 5.00	1
17	65	1 5.00	0				

Análise de Sobrevivência Aplicada à Saúde -- 2014



• Ajuste de modelos de regressão exponencial

√ Modelo 1:

– Nenhuma covariável incluída

√ Modelo 2:

– Incluída apenas a covariável X_1 : lwbc

√ Modelo 3:

– Incluída apenas a covariável X_2 : grupos

√ Modelo 4:

– Incluída as covariáveis X_1 e X_2

√ Modelo 5:

– Incluídas variáveis X_1 , X_2 e $X_1 * X_2$

Análise de Sobrevivência Aplicada à Saúde -- 2014

```
> leuk.mod1 <- survreg(Surv(temp, status) ~ 1,
  data = dados, dist = 'exponential')
> leuk.mod1
Call:
survreg(formula = Surv(temp, status) ~ 1,
  data = dados, dist = "exponential")
Coefficients:
(Intercept)
 3.710611
Scale fixed at 1
Loglik(model) = -155.5 Loglik(intercept only) = -155.5
n = 33
```

Modelo 1:
nenhuma covariável

$$\hat{\beta}_0 = -3,7106$$

$$l(\hat{\beta}) = -155,5$$

```
> leuk.mod2 <- survreg(Surv(temp, status) ~ lwbc,
  data = dados, dist = 'exponential')
> leuk.mod2
Call:
survreg(formula = Surv(temp, status) ~ lwbc,
  data = dados, dist = "exponential")
Coefficients:
(Intercept) lwbc
 7.3712449 -0.9229052
Scale fixed at 1
Loglik(model) = -150.3 Loglik(intercept only) = -155.5
Chisq = 10.31 on 1 degrees of freedom, p = 0.0013
n = 33
```

Modelo 2:
 X_1

$$\hat{\beta}_0 = -7,3712$$

$$\hat{\beta}_1 = 0,9229$$

$$l(\hat{\beta}) = -150,3$$

Análise de Sobrevivência Aplicada à Saúde -- 2014

```
> leuk.mod3 <- survreg(Surv(temp, status) ~ grupo,
  data = dados, dist = 'exponential')
> leuk.mod3
Call:
survreg(formula = Surv(temp, status) ~ grupo,
  data = dados, dist = "exponential")
Coefficients:
(Intercept) grupo
 4.134696 -1.247802
Scale fixed at 1
Loglik(model) = -149.5 Loglik(intercept only) = -155.5
Chisq = 11.94 on 1 degrees of freedom, p = 0.00055
n = 33
```

Modelo 3:
 X_2

$$\hat{\beta}_0 = -4,1347$$

$$\hat{\beta}_2 = 1,2478$$

$$l(\hat{\beta}) = -149,5$$

```
> leuk.mod4 <- survreg(Surv(temp, status) ~ lwbc + grupo,
  data = dados, dist = 'exponential')
> leuk.mod4
Call:
survreg(formula = Surv(temp, status) ~ lwbc + grupo,
  data = dados, dist = "exponential")
Coefficients:
(Intercept) lwbc grupo
 6.8295300 -0.700326 -1.0180633
Scale fixed at 1
Loglik(model) = -146.5 Loglik(intercept only) = -155.5
Chisq = 17.81 on 2 degrees of freedom, p = 0.00014
n = 33
```

Modelo 4:
 X_1

$$\hat{\beta}_0 = -6,8295$$

$$\hat{\beta}_1 = 0,7000$$

$$\hat{\beta}_2 = 1,0181$$

$$l(\hat{\beta}) = -146,5$$

Análise de Sobrevivência Aplicada à Saúde -- 2014

```

> leuk.mod5 <- survreg(Surv(temp, status)~ lwbc + grupo + lwbc*grupo,
  data = dados, dist = 'exponential')
> leuk.mod5
Call:
survreg(formula = Surv(temp, status)~lwbc + grupo + lwbc*grupo,
  data = dados, dist = "exponential")
Coefficients:
(Intercept)      lwbc      grupo  lwbc:grupo
  8.477498   -1.109298  -4.138509    0.755652
Scale fixed at 1
Loglik(model)=-145.7  Loglik(intercept only)= -155.5
Chisq= 19.58 on 3 degrees of freedom, p= 0.00021
n= 33
  
```

Modelo 5:
 X_1, X_2 e $X_1 * X_2$

$\hat{\beta}_0 = -8,4775$
 $\hat{\beta}_1 = 1,1093$
 $\hat{\beta}_2 = 4,1385$
 $\hat{\beta}_3 = -0,7557$
 $l(\hat{\beta}) = -145,7$

Análise de Sobrevivência Aplicada à Saúde -- 2014

√ Estimativas dos parâmetros e da log-verossimilhança

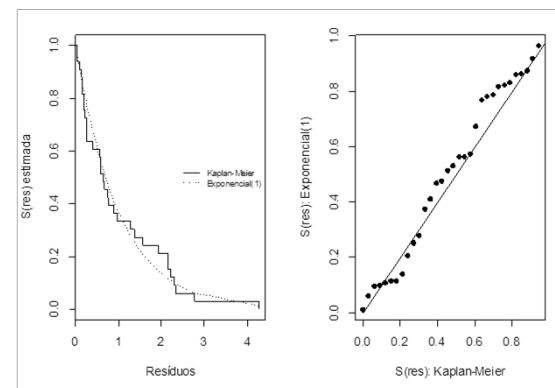
Modelo	Covariáveis	Estimativas	Log-verossimilhança
1	Nenhuma	$\beta_0 = -3,7106$	$l_1 = -155,5$
2	X_1	$\beta_0 = -7,3712$ $\beta_1 = 0,9229$	$l_2 = -150,3$
3	X_2	$\beta_0 = -4,1347$ $\beta_1 = 1,2478$	$l_3 = -149,5$
4	X_1 e X_2	$\beta_0 = -6,8295$ $\beta_1 = 0,7000$ $\beta_2 = 1,0181$	$l_4 = -146,5$
5	X_1, X_2 e $X_1 * X_2$	$\beta_0 = -8,4775$ $\beta_1 = 1,1093$ $\beta_2 = 4,1385$ $\beta_3 = -0,7557$	$l_5 = -145,7$

√ Testes da razão de verossimilhanças – Resultados:

Efeito	H_0	RV	GL	p-valor
Interação: $X_1 * X_2$	$\beta_3 = 0$	$2(146,5 - 145,7) = 1,6$	1	0,2059
de $X_2 X_1$	$\beta_2 = 0$	$2(150,3 - 146,5) = 7,6$	1	0,0058
de $X_1 X_2$	$\beta_1 = 0$	$2(149,5 - 146,5) = 8,0$	1	0,0047

- √ Não há evidências estatísticas de que a interação entre X_1 e X_2 seja significativa
- √ Evidências estatísticas do efeito da covariável X_1 (p = 0,0047)
- √ Evidências estatísticas do efeito da covariável X_2 (p = 0,0058)

√ Análise gráfica dos resíduos Cox-Snell – Exponencial



– Modelo exponencial apresenta ajuste razoável

√ Resultados do modelo de regressão exponencial final

- Modelo 4

```
> summary(leuk.mod4)
Call:
survreg(formula = Surv(temp, status) ~ lwbc + grupo, data = dados,
        dist = "exponential")

      Value Std. Error      z      p
(Intercept)  6.83      1.158  5.90 3.73e-09
lwbc        -0.70      0.286 -2.45 1.44e-02
grupo       -1.02      0.364 -2.80 5.12e-03
```

Scale fixed at 1
Exponential distribution
Loglik(model)= -146.5 Loglik(intercept only)= -155.5
Chisq= 17.81 on 2 degrees of freedom, p= 0.00014
Number of Newton-Raphson Iterations: 5
n= 33

- Rejeita-se $H_0: \beta_1 = \beta_2 = 0$ (p-valor = 0,00014)
- É possível que parte da variação observada na resposta possa ser explicada pela contagem de glóbulos brancos e pelo grupo de antígeno

Análise de Sobrevivência Aplicada à Saúde -- 2014

• Modelo de regressão exponencial – Modelo 4

√ Função de sobrevivência estimada

$$S(t|x_1, x_2) = \exp\{-\exp\{-6,8295 + 0,7000x_1 + 1,0181x_2\}t\}, t \geq 0$$

√ $\beta_1 > 0$


- Quanto maior o valor de x_1 (contagem de glóbulos brancos) menor a probabilidade de sobrevivência estimada

√ $\beta_2 > 0$

- Pacientes do grupo Ag- ($x_2 = 1$) apresentam probabilidades de sobrevivência menores do que os pacientes do grupo Ag+ ($x_2 = 0$)

Análise de Sobrevivência Aplicada à Saúde -- 2014

√ Curvas de sobrevivências estimadas – Ag+ e Ag-




√ Pacientes do grupo Ag- com menor sobrevivência

- Menor sobrevivência para pacientes com x_1 maior

Análise de Sobrevivência Aplicada à Saúde -- 2014

√ Riscos estimados pelo modelo – Ag+ e Ag-



√ Riscos constantes ao longo do tempo

- Quanto maior a contagem, maior o risco

Análise de Sobrevivência Aplicada à Saúde -- 2014

• Conclusões:

- √ Quanto maior a contagem de glóbulos brancos no diagnóstico, maior o risco
 - Nos 2 grupos
- √ Pacientes que apresentam o antígeno Calla ($x_2=0$) têm melhor prognóstico do que os que ainda não experimentaram

Análise de Sobrevida Aplicada à Saúde -- 2014

Exemplo

- Análise de dados de aleitamento materno
 - √ Estudo ambulatorial sobre amamentação
 - √ Amostra:
 - 150 mães de crianças com menos de 2 anos
 - √ Resposta:
 - Tempo máximo de aleitamento materno
 - Censura: crianças não acompanhadas até o desmame
 - √ Covariáveis: 11
 - √ Objetivo:
 - Identificar fatores de risco ou de proteção para desmame precoce

Análise de Sobrevida Aplicada à Saúde -- 2014

• Descrição das covariáveis

Código	Descrição	Categorias
V1	Experiência anterior amamentação	0: sim 1: não
V2	Número de filhos vivos	0: ≥ 2 1: < 2
V3	Conceito materno sobre o tempo ideal de amamentação	0: > 6 meses 1: ≤ 6 meses
V4	Dificuldade para amamentar nos primeiros dias pós-parto	0: não 1: sim
V5	Tipo de serviço em que realizou o pré-natal	0: público 1: privado/convênios
V6	Recebeu exclusivamente leite materno na maternidade	0: sim 1: não
V7	A criança teve contato com o pai	0: sim 1: não
V8	Renda per capita (em SM/mês)	0: ≥ 1 SM 1: < 1 SM
V9	Peso ao nascimento	0: ≥ 2,5 kg 1: < 2,5 kg
V10	Tempo de separação mãe-filho pós-parto	0: ≤ 6 horas 1: > 6 horas
V11	Permanência no berçário	0: não 1: sim





- √ Todas as variáveis são dicotômicas (possível comparar categorias pelo Kaplan-Meier)





Análise de Sobrevida Aplicada à Saúde -- 2014

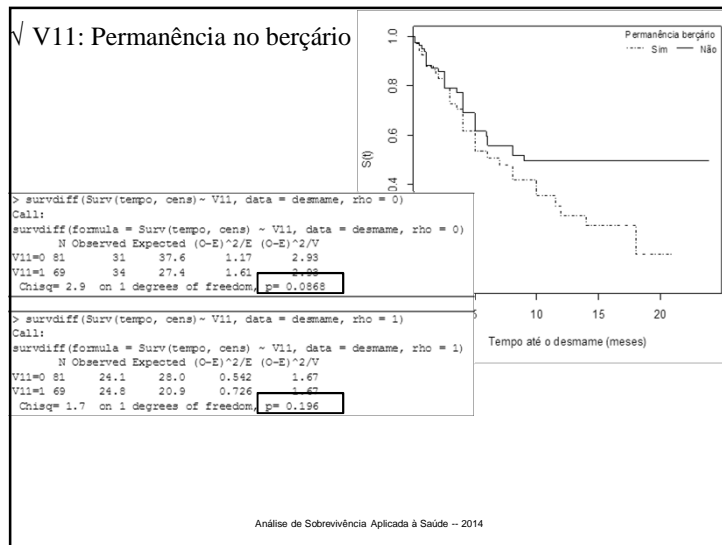

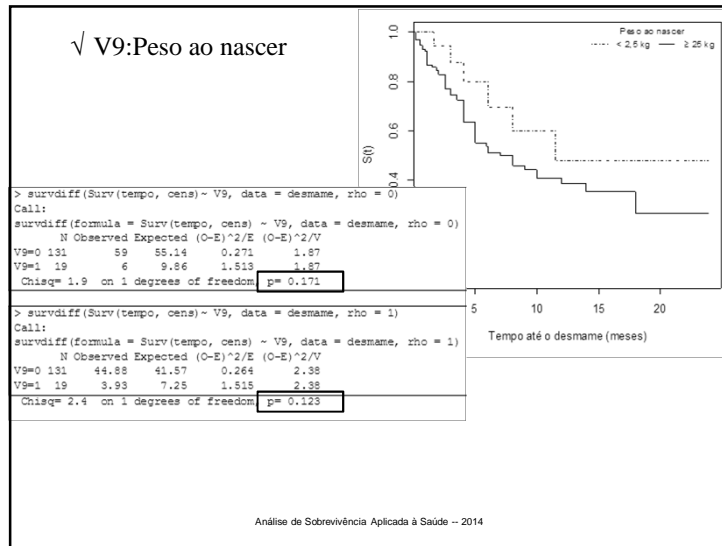
• Análise Descritiva e Exploratória

- √ Construir estimativas Kaplan-Meier para comparar as duas categorias
- √ Conduzir testes logrank e Peto para testar
 - $H_0: S_1(t) = S_2(t)$
- √ Todas as covariáveis com p-valor < 0,25 devem ser incluídas na etapa de modelagem estatística
 - Escolha de nível de significância modesto é recomendado por:
 - Bendel e Afifi (1977) – para regressão linear
 - Constanza e Afifi (1979) – para análise discriminante
 - Mickey e Greenland (1989) – para mudança nos coeficientes de modelo de regressão logística

Análise de Sobrevida Aplicada à Saúde -- 2014







√ Tabela de valores dos testes logrank e Peto

Código	Variável	Descrição	Valor	Qte.	logrank		Peto	
					χ^2	p-valor	χ^2	p-valor
V1	Experiência anterior amamentação	0	87	3,9	0,047	5,7	0,017	
		1	63					
V2	Número de filhos vivos	0	113	2,6	0,107	2,4	0,122	
		1	37					
V3	Conceito materno sobre o tempo ideal de amamentação	0	80	6,1	0,013	7,9	0,005	
		1	70					
V4	Dificuldade para amamentar nos primeiros dias pós-parto	0	84	12,3	0,000	14,9	0,000	
		1	66					
V5	Tipo de serviço em que realizou o pré-natal	0	122	1,4	0,241	1,3	0,257	
		1	28					
V6	Recebeu exclusivamente leite materno na maternidade	0	94	7,5	0,006	7,0	0,008	
		1	56					
V7	A criança teve contato com o pai	0	141	1,8	0,175	1,5	0,228	
		1	9					
V8	Renda per capita (em SM/mês)	0	77	2,1	0,146	2,2	0,136	
		1	73					
V9	Peso ao nascimento	0	131	1,9	0,171	2,4	0,123	
		1	19					
V10	Tempo de separação mãe-filho pós-parto	0	69	2,6	0,107	1,6	0,208	
		1	81					
V11	Permanência no berçário	0	81	2,9	0,087	1,7	0,196	
		1	69					

- p-valores menores que 0,25

Análise de Sobrevivência Aplicada à Saúde -- 2014

- **Comentários:**

- √ Há 11 covariáveis potencialmente importantes
 - $2^{11} = 2048$ modelos possíveis
- √ É impraticável ajustar todos esses possíveis modelos para selecionar aquele que explica melhor a resposta
- √ Há procedimentos automáticos disponíveis em pacotes estatísticos:

Análise de Sobrevida Aplicada à Saúde -- 2014

- **Procedimentos automáticos:**

- √ **Tipos:**
 - Forward
 - Backward
 - Stepwise
- √ **Vantagem**
 - Métodos implementados e disponíveis em pacotes
- √ **Desvantagens:**
 - Tendem a identificar um particular conjunto de covariáveis em vez de possíveis conjuntos igualmente bons
 - Impede que dois ou mais conjuntos igualmente bons sejam apresentados ao pesquisador para a escolha do mais relevante em sua área de aplicação

Análise de Sobrevida Aplicada à Saúde -- 2014

- **Seleção de covariáveis:**

- √ Covariáveis com significância clínica devem ser incluídas independente de significância estatística
- √ Importância clínica deve ser considerada em cada passo de inclusão ou exclusão no processo de seleção de covariáveis
- √ Evitar ser muito rigoroso ao testar cada nível individual de significância
 - Recomenda-se um valor próximo de 0,10

Análise de Sobrevida Aplicada à Saúde -- 2014

- **Modelagem separada de cada covariável com a resposta**

- √ **Objetivo:**
 - selecionar quais covariáveis prosseguirão na análise
- √ **Critério utilizado:**
 - Permanecer com covariáveis que apresentarem p-valor inferior a 0,25
- √ Todas as covariáveis passam por esse critério

Análise de Sobrevida Aplicada à Saúde -- 2014

- Passos da estratégia para seleção de covariáveis: (Colosimo e Giolo, 2006)
 1. Ajustar todos os modelos contendo uma única covariável
 - Incluir todas as covariáveis que forem significativas ao nível de 0,10
 - Aconselhável usar o Teste da Razão de Verossimilhanças

Análise de Sobrevivência Aplicada à Saúde -- 2014

- Teste de Razão de Verossimilhanças é usualmente realizado utilizando-se a distribuição gama generalizada.
 - √ Tem aninhados os modelos exponencial, de Weibull, lognormal e gama
- Para ajuste do modelo gama generalizado no R:


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

Análise de Sobrevivência Aplicada à Saúde -- 2014

- Ajuste de modelos com uma única covariável

Passo 1					
	Modelo	$l(\theta)$	$-2l(\hat{\theta})$	TRV	p-valor
	Nulo	-228,226	456,452		
V1	Experiência anterior amamentação	-225,579	451,158	5,294	0,0214
V2	Número de filhos vivos	-226,819	453,638	2,814	0,0935
V3	Conceito materno sobre o tempo ideal de amamentação	-225,330	450,659	5,793	0,0161
V4	Dificuldade para amamentar nos primeiros dias pós-parto	-221,811	443,621	12,831	0,0003
V5	Tipo de serviço em que realizou o pré-natal	-227,335	454,670	1,782	0,1819
V6	Recebeu exclusivamente leite materno na maternidade	-224,718	449,436	7,016	0,0081
V7	A criança teve contato com o pai	-227,101	454,202	2,250	0,1336
V8	Renda per capita (em SM/mês)	-226,736	453,473	2,979	0,0843
V9	Peso ao nascimento	-226,753	453,506	2,946	0,0861
V10	Tempo de separação mãe-filho pós-parto	-227,255	454,511	1,942	0,1635
V11	Permanência no berçário	-227,181	454,362	2,090	0,1483

Análise de Sobrevivência Aplicada à Saúde -- 2014

Covariáveis retidas:
V1, V2, V3, V4, V6, V8, V9

Covariáveis excluídas:
V5, V7, V10, V11

2. Ajustar conjuntamente as covariáveis significativas no passo 1
 - Na presença de certas covariáveis, outras podem deixar de ser significativas
 - Ajustam-se modelos reduzidos, excluindo uma única covariável de cada vez
 - Permanecem no modelo somente aquelas que atingirem a significância

Análise de Sobrevivência Aplicada à Saúde -- 2014

- Ajuste conjunto das covariáveis significativas
 - √ Exclusão de uma variável por vez
 - √ Permanecem apenas aquelas que atingirem significância

Passo 2					
Modelo		$l(\theta)$	$-2l(\theta)$	TRV	p-valor
V1 + V2 + V3 + V4 + V6 + V8 + V9		-212,475	424,950		
V1+V2+V3+V4+V6+V8		-213,129	426,258	1,307	0,2529
V1+V2+V3+V4+V6+V9	V8	-214,213	428,426	3,475	0,0623
V1+V2+V3+V4+V8+V9	V6	-215,196	430,391	5,441	0,0197
V1+V2+V3+V6+V8+V9	V4	-216,698	433,397	8,447	0,0037
V1+V2+V4+V6+V8+V9	V3	-214,155	428,310	3,360	0,0668
V1+V3+V4+V6+V8+V9		-212,539	425,077	0,127	0,7219
V2+V3+V4+V6+V8+V9		-213,100	426,199	1,249	0,2638

Covariáveis retidas:
V3, V4, V6, V8

Covariáveis excluídas:
V1, V2, V9

Análise de Sobrevivência Aplicada à Saúde -- 2014

3. Ajustar modelo com covariáveis retidas no passo 2
 - As covariáveis excluídas no passo 2 retornam ao modelo para confirmar sua significância estatística

Análise de Sobrevivência Aplicada à Saúde -- 2014

- Ajuste de modelo com covariáveis retidas
 - √ Retorno de covariável excluída uma a uma

Passo 3					
Modelo		$l(\theta)$	$-2l(\theta)$	TRV	p-valor
V3+V4+V6+V8		-212,475	428,397		
V3+V4+V6+V8+V1		-213,221	426,442	1,955	0,1620
V3+V4+V6+V8+V2		-213,635	427,269	1,127	0,2884
V3+V4+V6+V8+V9		-213,647	427,294	1,103	0,2936

Covariáveis retidas:
V3, V4, V6, V8

- √ As covariáveis excluídas no passo anterior não são significativas

Análise de Sobrevivência Aplicada à Saúde -- 2014

4. Inclusão no modelo de eventuais covariáveis significativas no passo 3
 - As covariáveis excluídas no passo 1 retornam ao modelo para confirmar sua significância estatística

Análise de Sobrevivência Aplicada à Saúde -- 2014

- Ajuste de modelo com covariáveis retidas nos passos 2 e 3

√ Retorno de covariáveis excluídas no passo 1

Passo 4				
Modelo	$l(\theta)$	$-2l(\theta)$	TRV	p-valor
V3+V4+V6+V8	-212,475	428,397		
V3+V4+V6+V8+V5	-214,198	428,397	0,000	0,9989
V3+V4+V6+V8+V7	-213,319	426,637	1,759	0,1847
V3+V4+V6+V8+V10	-214,072	428,143	0,253	0,6146
V3+V4+V6+V8+V11	-214,117	428,234	0,163	0,6863

Covariáveis retidas:
V3, V4, V6, V8

√ As covariáveis excluídas no passo 1 não são significativas

Análise de Sobrevivência Aplicada à Saúde -- 2014

5. Inclusão no modelo de eventuais covariáveis significativas no passo 4

– Testa-se se alguma dela pode ser retirada do modelo

Análise de Sobrevivência Aplicada à Saúde -- 2014

- Inclusão de covariáveis significativas no passo 4

√ Testa-se se alguma delas pode ser retirada do modelo

Passo 5				
Modelo	$l(\theta)$	$-2l(\theta)$	TRV	p-valor
V3+V4+V6+V8	-212,475	428,397		
V3+V4+V6	-216,955	433,911	5,514	0,0189
V3+V4+V8	-216,747	433,493	5,097	0,0240
V3+V6+V8	-220,753	441,506	13,109	0,0003
V4+V6+V8	-216,109	432,218	3,822	0,0506

Covariáveis retidas:
V3, V4, V6, V8

√ Todas as covariáveis incluídas nos passos anteriores são significativas

Análise de Sobrevivência Aplicada à Saúde -- 2014

6. Ajusta-se modelo final para os efeitos principais utilizando as covariáveis que não foram excluídas no passo 5

– Verifica-se a possibilidade de inclusão de termos de interação dupla entre as covariáveis incluídas no modelo

Análise de Sobrevivência Aplicada à Saúde -- 2014

• Modelo final para os efeitos principais

√ Verificação inclusão de interações duplas

Passo 6					
Modelo	$l(\theta)$	$-2l(\theta)$	TRV	gl	p-valor
V3+V4+V6+V8	-212,475	428,397			
V3+V4+V6+V8+V3*V4	-213,844	427,689	0,708	0,4002	
V3+V4+V6+V8+V3*V6	-213,295	426,590	1,807	0,1789	
V3+V4+V6+V8+V3*V8	-214,059	428,118	0,279	0,5973	
V3+V4+V6+V8+V4*V6	-213,823	427,647	0,750	0,3865	
V3+V4+V6+V8+V4*V8	-213,826	427,652	0,744	0,3883	
V3+V4+V6+V8+V6*V8	-214,056	428,112	0,284	0,5939	

Covariáveis retidas:
V3, V4, V6, V8

√ Nenhum termo de interação dupla foi significativo

Análise de Sobrevivência Aplicada à Saúde -- 2014

• Modelo Final:

√ Efeitos principais identificados no passo 5

- V3, V4, V6, V8

√ Termos de interação identificados no passo 6

- Nenhum é significativo

Análise de Sobrevivência Aplicada à Saúde -- 2014

• Modelo Final:

	$l(\theta)$	$-2l(\theta)$	TRV	gl	p-valor
Nulo	-228,226	456,452			
V3+V4+V6+V8	-214,198	428,397	28,056	4	0,000
V3+V4+V6+V1	-215,228	430,456	25,996	4	0,000

√ Possível efeito de multicolenaridade entre:

- V1: experiência anterior de amamentação

- V8: renda per capita

(estatísticas de teste não são muito diferentes)

√ Decisão sobre qual variável deveria permanecer foi baseada em evidências clínicas

Análise de Sobrevivência Aplicada à Saúde -- 2014

• Variáveis prognósticas:

√ V1:

- Experiência anterior de amamentação

√ V3:

- Conceito materno sobre o tempo ideal de amamentação

√ V4:

- Dificuldades de amamentar nos primeiros dias pós-parto

√ V6:

- Recebimento exclusivo de leite materno na maternidade

Análise de Sobrevivência Aplicada à Saúde -- 2014

• Saídas dos modelos Weibull e Lognormal

```
> desm.wei <- survreg(Surv(desmameStempo, desmameScens)~ V3 + V4 + V6 + V1,
+ dist = 'weibull')
> desm.wei
Call:
survreg(formula = Surv(desmameStempo, desmameScens) ~ V3 + V4 +
V6 + V1, dist = "weibull")
Coefficients:
(Intercept)      V3          V4          V6          V1
 3.5871202  -0.4926920  -0.6820891  -0.6521603  -0.5336577
Scale= 1.048537
Loglik(model)= -217.9  Loglik(intercept only)= -228.2
Chisq= 22.57 on 4 degrees of freedom, p= 0.00015
n= 150

> desm.ln <- survreg(Surv(desmameStempo, desmameScens)~ V3 + V4 + V6 + V1,
+ dist = 'lognorm')
> desm.ln
Call:
survreg(formula = Surv(desmameStempo, desmameScens) ~ V3 + V4 +
V6 + V1, dist = "lognorm")
Coefficients:
(Intercept)      V3          V4          V6          V1
 3.2925917  -0.6314176  -0.8242242  -0.6804915  -0.5721767
Scale= 1.438643
Loglik(model)= -215.3  Loglik(intercept only)= -228.9
Chisq= 27.21 on 4 degrees of freedom, p= 1.8e-05
n= 150
```

Análise de Sobrevivência Aplicada à Saúde -- 2014

• Busca-se modelo mais simples que o gama generalizada

	$l(\theta)$	$-2l(\theta)$	TRV	gl	p-valor
Gama generalizada	-215,228	430,456			
Weibull	-217,902	435,803	5,347	1	0,0208
Lognormal	-215,337	430,673	0,218	1	0,6409

✓ H_0 : o modelo de interesse é adequado

✓ Conclusão:

- Modelo de regressão lognormal é adequado para ajustar os tempos até o desmame
- Variáveis prognósticas: V1, V3, V4, V6

Análise de Sobrevivência Aplicada à Saúde -- 2014

• Estimativas dos parâmetros do modelo de regressão lognormal

✓ Coeficientes estimados expressos na escala logarítmica dos tempos

$$Y = \ln(T) = \alpha'\beta + \sigma v$$

```
> desm.ln <- survreg(Surv(desmameStempo, desmameScens)~ V3 + V4 + V6 + V1,
+ dist = 'lognorm')
> summary(desm.ln)
Call:
survreg(formula = Surv(desmameStempo, desmameScens) ~ V3 + V4 +
V6 + V1, dist = "lognorm")

              Value Std. Error      z      p
(Intercept)  3.293      0.304 10.84 2.29e-27
V3           -0.631      0.290  -2.18 2.93e-02
V4           -0.824      0.302  -2.73 6.33e-03
V6           -0.680      0.293  -2.33 2.00e-02
V1           -0.572      0.301  -1.90 5.72e-02
Log(scale)   0.364      0.090  4.04 5.36e-05
Scale= 1.44

Log Normal distribution
Loglik(model)= -215.3  Loglik(intercept only)= -228.9
Chisq= 27.21 on 4 degrees of freedom, p= 1.8e-05
Number of Newton-Raphson Iterations: 4
```

$$ep(\hat{\sigma}) = ep[\ln(\hat{\sigma})]\hat{\sigma} = (0,090)(1,44) = 0,1295$$

Análise de Sobrevivência Aplicada à Saúde -- 2014

• Estimativa dos parâmetros:

	Covariável	Estimativa	Erro Padrão	p-valor
	Intercepto	3,293	0,304	0,000
V1	Experiência anterior de amamentação	-0,572	0,301	0,0572
V3	Conceito sobre o tempo de amamentação	-0,631	0,290	0,0293
V4	Dificuldades de amamentação pós-parto	-0,824	0,302	0,0063
V6	Recebimento exclusivo de leite materno	-0,680	0,293	0,0020
	Parâmetro de forma	1,439	0,129	

Análise de Sobrevivência Aplicada à Saúde -- 2014

Adequação do Modelo Ajustado

- Métodos gráficos:
 - √ Utilização dos resíduos para confirmar a adequação do modelo lognormal
- Tipos de resíduos:
 - √ Resíduos padronizados
 - √ Resíduos de Cox-Snell

Análise de Sobrevivência Aplicada à Saúde -- 2014

Resíduos padronizados

√ Baseado na representação dos modelos log-lineares

$$\hat{v}_i = \frac{y_i - \mathbf{x}'_i \beta}{\hat{\sigma}}, \text{ com } y_i = \ln(t_i)$$

√ Modelo lognormal bem ajustado para os dados:

- Resíduos têm distribuição próxima à normal padrão
- Exponencial dos resíduos tem distribuição lognormal

√ Procedimento:

- Estimar sobrevivência dos resíduos com Kaplan-Meier
- Comparar estimação de Kaplan-Meier com sobrevivência da lognormal padrão

Análise de Sobrevivência Aplicada à Saúde -- 2014

Cálculo e transformação dos resíduos:

```
> # Determinacao Residuos e*i (log-normal padrão)
>
> residuos <- predict(desm.ln, type = "response") # Escala original
> padr.log <- (log(tempo)-log(residuos))/desm.ln$scale # Padroniza na escala log
> padr.orig<-exp(padr.log) # Escala original
> padr.km <- survfit(Surv(padr.orig, cens)~ 1)
> res <- padr.km$time
> sln <- pnorm(-log(res))
```


Gráficos dos resíduos padronizados:

```
> # Gráficos Residuos e*i
>
> win.graph(width=12, height=6) # Default width = 7, height = 7
> par(mfrow = c(1,2))
> plot(padr.km$surv, sln, pch = 16, ylab = "S(e*i): Log-normal padrão",
+ xlab = "S(e*i): Kaplan-Meier")
> plot(padr.km, conf.int = F, mark.time = F, pch = 16,
+ xlab = "Resíduos (e*i)", ylab = "Sobrevivência estimada")
> lines(res, sln, lty = 2)
> legenda = c("Kaplan-Meier", "Log-normal padrão")
> legend(x = "topright", legend = legenda, lty = 1:2, cex = 0.8, bty = "n")
> par(mfrow = c(1,1))
```

Análise de Sobrevivência Aplicada à Saúde -- 2014

Sobrevivência dos resíduos e*_i:

- Estimativa Kaplan-Meier e Log-normal padrão



- Pode-se acreditar que o modelo de regressão lognormal se encontra bem ajustado aos dados sob análise

Análise de Sobrevivência Aplicada à Saúde -- 2014

√ Resíduos de Cox-Snell

$$\hat{e}_i = \hat{\Lambda}(t_i|x_1) = -\ln[\hat{S}(t_i|x_1)]$$

√ Modelos:

- Exponencial: $\hat{e}_i = [t_i \exp\{x_i' \hat{\beta}\}]$

- Weibull: $\hat{e}_i = [t_i \exp\{x_i' \hat{\beta}\}]^{\hat{\gamma}}$

- Lognormal: $\hat{e}_i = -\ln \left[1 - \Phi \left(\frac{\ln(t_i) - x_i' \hat{\beta}}{\hat{\sigma}} \right) \right]$

Análise de Sobrevivência Aplicada à Saúde -- 2014

• Se o modelo for adequado:

√ Resíduos seguem distribuição exponencial padrão

- Curvas de sobrevivência dos resíduos, por Kaplan-Meier e exponencial padrão devem estar próximas
- Gráfico dos pontos ($S_{KM}(res)$, $S_{exp}(res)$) devem se aproximar de uma reta
- Gráfico e_i vs. $\Lambda(e_i)$ deve ser aproximadamente uma reta

Análise de Sobrevivência Aplicada à Saúde -- 2014

• Cálculo dos resíduos de Cox-Snell:

```
# Determinação Resíduos Cox-Snell
>
> snell <- - log(1 - pnorm(padr.log))
> snell.km <- survfit(Surv(snell, cens)~ 1)
> t <- snell.km$time
> s.t <- snell.km$surv
> s.exp <- exp(-t)
```


• Gráficos dos resíduos padronizados:

```
# Gráficos Resíduos Cox-Snell
>
> win.graph(width=12, height=6) # Default width = 7, height = 7
> par(mfrow = c(1,2))
> plot(s.t, s.exp, pch = 16, ylab = "S(ei): Exponencial padrão",
+ xlab = "Resíduos de Cox-Snell")
> plot(snell.km, conf.int = F, mark.time = F, pch = 16,
+ xlab = "Resíduos de Cox-Snell", ylab = "Sobrevivência estimada")
> lines(t, s.exp, lty = 4)
> legenda = c("Kaplan-Meier", "Exponencial padrão")
> legend(x = "topright", legend = legenda, lty = c(1, 4), cex = 0.8, bty = "n")
> par(mfrow = c(1,1))
```

Análise de Sobrevivência Aplicada à Saúde -- 2014

√ Sobrevivência dos resíduos de Cox-Snell (e_i):

- Estimativa Kaplan-Meier e Exponencial padrão



- Evidências de que o modelo de regressão lognormal se encontra bem ajustado aos dados sob análise

Análise de Sobrevivência Aplicada à Saúde -- 2014

Interpretação dos Coeficientes

- Para variável binária

√ $\exp\{\beta_i\}$ é a razão dos tempos medianos:

$$e^{\hat{\beta}_i} = \frac{t_{0,5}(x = 1, \hat{\beta}_i)}{t_{0,5}(x = 0, \hat{\beta}_i)}$$

√ Válido para os modelos Weibull e lognormal

Análise de Sobrevivência Aplicada à Saúde -- 2014

- No exemplo

√ Efeito da experiência anterior de amamentação

$$e^{\hat{\beta}_1} = e^{-0,572} = 0,564$$

0: sim
1: não

- Tempo mediano até o desmame de mães que não tiveram experiência anterior de amamentação é aproximadamente a metade daquele das mães que já tiveram esta experiência

√ Efeito do conceito sobre o tempo de amamentação:

$$e^{\hat{\beta}_2} = e^{-0,631} = 0,532$$

0: > 6 meses
1: ≤ 6 meses

- Mães que acreditam que o tempo ideal de desmame é superior a 6 meses apresentam tempo mediano até o desmame de aproximadamente 2 vezes maior do que as mães que pensam ser este tempo igual ou inferior a 6 meses

Análise de Sobrevivência Aplicada à Saúde -- 2014

√ Efeito da dificuldade de amamentação pós-parto

$$e^{\hat{\beta}_3} = e^{-0,824} = 0,439$$

0: sim
1: não

- Tempo mediano até o desmame de mães que não apresentaram dificuldades de amamentar nos primeiros dias até o parto é 2,3 vezes maior que o tempo das que sofreram este tipo de dificuldade.

√ Efeito do recebimento exclusivo de leite materno:

$$e^{\hat{\beta}_4} = e^{-0,680} = 0,507$$

0: sim
1: não

- Crianças que receberam exclusivamente leite materno na maternidade têm um tempo mediano de amamentação duas vezes maior do que o tempo daqueles que receberam outro tipo de alimentação juntamente com o leite materno

Análise de Sobrevivência Aplicada à Saúde -- 2014

Referências

Bibliografia

- Carvalho, M. S. et al. *Análise de Sobrevivência: Teoria e Aplicações em Saúde*. (Fiocruz)
- Colosimo, E. A. e Giolo, S. R. *Análise de Sobrevivência Aplicada*. (Edgard Blucher)
- Klein, J. P. e Moeschberger, M. L. *Survival Analysis: Techniques for Censored and Truncated Data*. (Springer)
- Kleinbaum, D. G. *Survival Analysis: a Self-Learning Text*

Análise de Sobrevivência Aplicada à Saúde -- 2014

Material de Apoio

- R:
√ www.r-project.org
- Tutorial online do R:
√ <http://www.leg.ufpr.br/Rtutorial>
√ <http://www.leg.ufpr.br/~paulojus/embrapa/Rembrapa>
- Conjuntos de dados e material Análise de Sobrevivência – Carvalho et al.
√ <http://sobrevida.fiocruz.br>

Análise de Sobrevivência Aplicada à Saúde -- 2014