

## Análise de Sobrevida

Camila Borelli Zeller  
Lupércio França Bessegato  
Departamento de Estatística/UFJF

### Roteiro Geral



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

Análise de Sobrevida -- 2017

2

## Modelos de Regressão Paramétricos

### Roteiro do Módulo



4. Modelos paramétricos de sobrevivência:
  - a) Introdução
  - b) Modelos paramétricos de sobrevivência
  - c) Modelo linear para dados de sobrevivência
  - d) Seleção de modelos
  - e) Adequação do modelo ajustado
  - f) Interpretação dos coeficientes estimados
  - g) Exemplos

Análise de Sobrevida -- 2017

4

## Introdução

## 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 Sobrevida -- 2017

6

## 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 Sobrevida -- 2017

7

## 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 Sobrevida -- 2017

8

## Modelos Paramétricos de Sobrevida

## Modelos com Covariáveis



- Abordagens para modelos dados de sobrevida com covariáveis:
  - √ Famílias paramétricas
  - √ Vida acelerada
  - √ Riscos proporcionais
  - √ Chances proporcionais

Análise de Sobrevida -- 2017

10

## Famílias Paramétricas



- Escolher uma das distribuições paramétricas
- Parâmetros da distribuição dependendo das covariáveis
  - √ Exponencial – modelo log-linear:
    - Parâmetro  $\alpha$ :  $\log \alpha = \mathbf{x}'\beta$
  - √ Weibull – modelo log-linear:
    - Parâmetro  $\alpha$ :  $\log \alpha = \mathbf{x}'\beta$
    - Parâmetro  $\gamma$ : fixo ou  $\log \gamma = \mathbf{x}'\beta^*$

Análise de Sobrevida -- 2017

11

## Comentários:



- √ Se houver  $k$  grupos, cada grupo teria sua própria distribuição em uma família
- √ Abordagem trabalhável, mas que não é parcimoniosa
  - Não leva a interpretações fáceis

Análise de Sobrevida -- 2017

12

### Modelo de Tempo de Vida Acelerado

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

- √  $\nu$ : termo de erro com distribuição apropriada
- Distribuição para  $\nu$ :
  - √ Valor extremo (T é Weibull)
  - √ Normal (T é lognormal)
  - √ Log-gama (T é gama)
  - √ Logística (T é log-logística)

Análise de Sobrevivência -- 2017

13

- Modelo de tempo de vida acelerado 

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


- Modelo na escala original

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

- √ Covariáveis tem efeito de acelerar (ou desacelerar) o tempo de vida

Análise de Sobrevivência -- 2017

14

- Modelo bastante utilizado na prática 

- √ 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 -- 2017

15

- Vida Acelerada – Interpretação: 

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

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

Análise de Sobrevivência -- 2017

16

√ Considerando o efeito das covariáveis

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

- Covariáveis agem multiplicativamente no tempo de sobrevivência

√ Probabilidade de indivíduo com valores de covariáveis  $x$  estar vivo no tempo  $t$ :

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

Análise de Sobrevivência -- 2017 17

- Probabilidade de indivíduo com valores de covariáveis  $x$  estar vivo no tempo  $t$ :

$$S(t|x) = S_0(t e^{-x'\beta})$$

- √ É a mesma probabilidade de indivíduo de referência estar vivo no tempo  $t e^{-x'\beta}$
- √ O tempo passa mais rapidamente por um fator  $e^{-x'\beta}$ 
  - (duas vezes mais rápido, metade mais rápido)
- √ Caso o interesse seja probabilidade de estar morto troca-se o sinal dos  $\beta$ 's.

Análise de Sobrevivência -- 2017 18

### Função *Baseline*


- Função de interesse de qualquer indivíduo pode ser expressa em termos de função baseline (ou de referência) correspondente:
  - √ Função de densidade:
 
$$f(t|x) = f_0(t e^{x'\beta}) e^{x'\beta}$$
  - √ Função de risco:
 
$$\lambda(t|x) = \lambda_0(t e^{x'\beta}) e^{x'\beta}$$
    - Relação simples entre funções de sobrevivência para diferentes  $x$ 's.  
(dilatação do eixo do tempo)

Análise de Sobrevivência -- 2017 19

- Exemplo:
  - √ Multiplicador de 2 para indivíduos com covariáveis  $x$ .
    - Sobrevivência:  $P\left\{\begin{array}{l} \text{indivíduo estar vivo} \\ \text{a qualquer tempo} \end{array}\right\} = P\left\{\begin{array}{l} \text{indivíduo referência estar vivo} \\ \text{com dobro desse tempo} \end{array}\right\}$
    - Risco:
      - Indivíduo está exposto em qualquer tempo ao dobro de risco de indivíduo de referência duas vezes mais velho

Análise de Sobrevivência -- 2017 20

- Pode-se começar com uma dada família para dilatar o tempo e terminar com uma família completamente diferente
  - √ Nem todas as famílias são fechadas à aceleração de tempo
  - √ Exceção:
    - Dilatando uma Weibull produz-se uma outra Weibull




Análise de Sobrevivência -- 2017 21

## Riscos Proporcionais

- Abordagem alternativa:
  - √ Assumir que o efeito das covariáveis é aumentar (ou diminuir) o risco por uma quantidade proporcional em todas as durações
 
$$\lambda(t|\mathbf{x}) = \lambda_0(t) \exp\{\mathbf{x}'\boldsymbol{\beta}\}$$


$$= \lambda_0(t) e^{\beta_0} e^{\beta_1 x_1} \dots e^{\beta_p x_p}$$
    - $\lambda_0(t)$ : risco para indivíduo com covariáveis zero (risco baseline)
    - $\exp\{\mathbf{x}'\boldsymbol{\beta}\}$ : risco relativo associado aos valores  $\mathbf{x}$  das covariáveis



Análise de Sobrevivência -- 2017 22


- Risco acumulado:
  - √ Segue a mesma relação
 
$$\Lambda(t|\mathbf{x}) = \Lambda_0(t) e^{\mathbf{x}'\boldsymbol{\beta}}$$
- Sobrevivência:
 
$$\exp\{-\Lambda(t|\mathbf{x})\} = \exp\{-\Lambda_0(t) \exp\{\mathbf{x}'\boldsymbol{\beta}\}\} = \exp\{-\Lambda_0(t)\}^{\exp\{\mathbf{x}'\boldsymbol{\beta}\}}$$

$$S(t|\mathbf{x}) = [S_0(t)]^{\exp\{\mathbf{x}'\boldsymbol{\beta}\}}$$
  - √ Sobrevivência para as covariáveis  $\mathbf{x}$ :
    - Sobrevivência *baseline* elevada a uma potência




Análise de Sobrevivência -- 2017 23

- Exemplo:
  - √ Indivíduo exposto ao dobro do risco de indivíduo de referência
    - Probabilidade de indivíduo estar vivo em qualquer tempo é o quadrado da probabilidade de o indivíduo de referência estar vivo na mesma idade
    - Dobro do risco está associado a um determinado valor de covariáveis



Análise de Sobrevivência -- 2017 24


- Razão de risco de dois indivíduos:
 
$$\frac{\lambda_i(t|\mathbf{x}_i)}{\lambda_j(t|\mathbf{x}_j)} = \frac{\lambda_0(t) \exp\{\mathbf{x}'_i\boldsymbol{\beta}\}}{\lambda_0(t) \exp\{\mathbf{x}'_j\boldsymbol{\beta}\}} = \frac{\exp\{\mathbf{x}'_i\boldsymbol{\beta}\}}{\exp\{\mathbf{x}'_j\boldsymbol{\beta}\}}$$
  - √ Função apenas das covariáveis
    - (não depende do tempo)
  - √ Diferentes indivíduos com covariáveis  $\mathbf{x}_i$  e  $\mathbf{x}_j^*$  possuem riscos proporcionais



Análise de Sobrevivência -- 2017 25


- Relação simples em termos de risco traduz-se em relação mais complexa em termos das funções de sobrevivência
  - √ Exemplo:
    - Função risco da distribuição de Weibull (baseline)
 
$$\lambda(t) = \alpha_0 \gamma (\alpha t)^{\gamma-1}$$
    - Risco relativo multiplicativo  $e^{\mathbf{x}'\boldsymbol{\beta}}$ :
 
$$\lambda(t|\mathbf{x}) = \alpha_0 \gamma (\alpha_0 t)^{\gamma-1} e^{\mathbf{x}'\boldsymbol{\beta}} = \alpha_0^\gamma e^{\mathbf{x}'\boldsymbol{\beta}} \gamma t^{\gamma-1}$$

$$= \left( \alpha_0 e^{\frac{\mathbf{x}'\boldsymbol{\beta}}{\gamma}} \right)^\gamma \gamma t^{\gamma-1}$$
    - A família Weibull é fechada para a proporcionalidade de risco




Análise de Sobrevivência -- 2017 26

- Isso não é verdade para outras distribuições
  - √ Se T é log-logística com efeito multiplicativo das covariáveis na função de risco
    - Função de risco baseline multiplicada por  $e^{\mathbf{x}'\boldsymbol{\beta}}$
    - Função de risco resultante não é da distribuição log-logística



Análise de Sobrevivência -- 2017 27

### Riscos Proporcionais e Vida Acelerada



- Os modelos de riscos proporcionais e de vida acelerada coincidem?
  - √ Se iniciarmos com um risco e multiplicarmos por um risco relativo e começarmos com outro risco e dilatarmos o tempo, terminaremos com a mesma distribuição?
  - √ Formulação da questão:
 
$$\lambda_0(t) e^{\mathbf{x}'\boldsymbol{\beta}} = \lambda_0 \left( t e^{\mathbf{x}'\boldsymbol{\beta}} \right) e^{\mathbf{x}'\boldsymbol{\beta}}, \forall \mathbf{x}, t ?$$

Análise de Sobrevivência -- 2017 28

- Formulação da questão:

$$\lambda_0(t) e^{x'\beta} = \lambda_0(t e^{x'\beta}) e^{x'\beta}, \forall x, t ?$$

- √ Condição será verdadeira  $\forall x$ , então será verdadeira para  $x = \mathbf{0}$ , logo o risco *baseline* deverá ser o mesmo.
- √ Qual é este risco?

- A Weibull é a única distribuição que é fechada para as famílias de vida acelerada e de risco proporcional

- √ Os parâmetros de vida acelerada e de riscos proporcionais  $\beta^*$  e  $\beta$  são proporcionais entre si, com proporcionalidade constante igual a  $\gamma$ 
  - Iguais para  $\gamma = 1$  (exponencial)
  - Neste contexto, o modelo de vida acelerado deve estar definido em termos da probabilidade de morrer, para preservar a interpretação dos coeficientes  $\beta$ 's como aumento do risco, consistente com os modelos de risco
    - Troca de sinal dos  $\beta$ 's no Modelo de Vida Acelerada)

- Exemplo:

- √ Modelo exponencial ( $\gamma = 1$ )
  - O dobro do risco faz o tempo ir duas vezes mais rápido
- √ Modelo Weibull com  $\gamma = 2$ :
  - O dobro do risco faz o tempo ir somente 40% mais rápido

## Chances Proporcionais

- Abordagem alternativa:

- √ Assumir que o efeito das covariáveis aumenta (ou diminui) as chances do desfecho, para uma dada duração, por uma quantidade proporcional



### Chances Proporcionais

- Abordagem alternativa:
  - √ Assumir que o efeito das covariáveis é aumentar (ou diminuir) as chances do desfecho por uma quantidade proporcional em todas as durações

$$\frac{1 - S(t|\mathbf{x})}{S(t|\mathbf{x})} = \frac{1 - S_0(t|\mathbf{x})}{S_0(t|\mathbf{x})} \exp\{\mathbf{x}'\boldsymbol{\beta}\}$$

- $S_0(t)$ : função de sobrevivência para indivíduo com covariáveis zero (risco baseline)
- $\exp\{\mathbf{x}'\boldsymbol{\beta}\}$ : multiplicador da chance associado aos valores  $\mathbf{x}$  das covariáveis

34

### Função Logit

$$\text{logit}(p) = \log\left(\frac{p}{1-p}\right) = \log(p) - \log(1-p)$$

- Logit é a inversa do sigmóide (ou função logística)

$$\log(\text{OR}) = \log\left(\frac{\frac{p}{1-p}}{\frac{q}{1-q}}\right) = \text{logit}(p) - \text{logit}(q)$$

35

$$\frac{1 - S(t|\mathbf{x})}{S(t|\mathbf{x})} = \frac{1 - S_0(t)}{S_0(t)} \exp\{\mathbf{x}'\boldsymbol{\beta}\}$$

- Tomando o log da chance:
  - $\text{logit}(1 - S(t|\mathbf{x})) = \text{logit}(1 - S_0(t)) + \mathbf{x}'\boldsymbol{\beta}$
- √ Efeito da covariável é linear na escala logit
  - Log chance do desfecho (em geral, morrer)
- √ Modelo pode ser definido em termos de chance de sobreviver à duração  $t$ 
  - Trocar sinal dos  $\boldsymbol{\beta}$ 's.

36

### Modelo de Chances Proporcionais Log-Logístico


- Chance baseline
 
$$S_0(t) = \frac{1}{1 + (\alpha t)^\gamma} \quad \frac{1 - S_0(t)}{S_0(t)} = (\alpha t)^\gamma$$

$$1 - S_0(t) = \frac{(\alpha t)^\gamma}{1 + (\alpha t)^\gamma}$$
- Multiplicando a chance *baseline* tem-se outro modelo log-logístico, com
 
$$\alpha^* = \alpha \exp\left\{\frac{\mathbf{x}'\boldsymbol{\beta}}{\gamma}\right\}$$

$$\gamma^* = \gamma$$


37

- Comentários:
  - √ A família log-logística é fechada para a proporcionalidade de chances
  - √ Isto não é verdade para outras distribuições
- Chances proporcionais e vida acelerada
  - √ Os modelos de chances proporcionais e de vida acelerada coincidem se e somente se a distribuição *baseline* for log-logística



Análise de Sobrevida -- 2017 38


### Estimação dos Parâmetros do Modelo



- Estimação dos efeitos das covariáveis ( $\beta$ 's da regressão)
  - √ Métodos dos mínimos quadrados
    - 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 -- 2017 39

### Estimação de Máxima Verossimilhança




- Todos os modelos podem ser ajustados maximizando a função de verossimilhança apropriada
  - √ Dados: pares  $(t_i, \delta_i)$ :
    - $t_i$ : tempo até desfecho ou censura
    - $\delta_i$ : indicador de desfecho

Análise de Sobrevida -- 2017 40

- Forma geral da função de verossimilhança sob censura geral não-informativa:
 

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

  - √ Em geral, a função de verossimilhança é maximizada numericamente
    - Newton-Raphson ou outro



Análise de Sobrevida -- 2017 41

## Modelo Linear para Dados de Sobrevivência

## Modelos de Regressão para Dados de Sobrevivência

- √ Forma de incorporar 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 -- 2017

43

## Modelo de Regressão Linear

- √ Modelo mais conhecido em Estatística
- √ Modelo linear associa resposta com as variáveis explicativas (ou covariáveis)

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

- Y: variável resposta
- x: covariável (ou variável explicativa, ou variável independente)
- $\beta_0, \beta_1$ : parâmetros a serem estimados
- $\epsilon$ : erro aleatório (com distribuição normal)

Análise de Sobrevivência -- 2017

44

- 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 Sobrevivência -- 2017

45

## 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

Análise de Sobrevida -- 2017

46

- √ 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 -- 2017

47

- 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

Análise de Sobrevida -- 2017

48

- Equivalência:



- Usar como componente determinístico  $\exp\{\beta'x\}$  (transformação logarítmica da resposta)
- Distribuição lognormal para os erros (há outras distribuições assimétricas disponíveis)

Análise de Sobrevida -- 2017


49

## Modelo de Regressão do Risco

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

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

- √  $\boldsymbol{\beta}$ : vetor de coeficientes a estimar
- √  $\lambda_0(t)$ : risco basal de um indivíduo que possui  $\exp(\mathbf{x}'\boldsymbol{\beta})=1$

- 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:
  - Aumentar ou diminuir o risco por quantidade proporcional em todas as durações

- Razão de risco de dois indivíduos: 

$$\frac{\lambda_i(t|\mathbf{x}_i)}{\lambda_j(t|\mathbf{x}_j)} = \frac{\lambda_0(t) \exp\{\mathbf{x}'_i\boldsymbol{\beta}\}}{\lambda_0(t) \exp\{\mathbf{x}'_j\boldsymbol{\beta}\}} = \frac{\exp\{\mathbf{x}'_i\boldsymbol{\beta}\}}{\exp\{\mathbf{x}'_j\boldsymbol{\beta}\}}$$

- √ Função apenas das covariáveis
  - (não depende do tempo)
- √ Diferentes indivíduos com covariáveis  $\mathbf{x}_i$  e  $\mathbf{x}_j^*$  possuem riscos proporcionais

### Modelo de Tempo de Vida Acelerada

- Modelo na log-escala

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

√  $\sigma\nu$  : distribuição de referência quando  $\mathbf{x} = 0$

- Modelo na escala original

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


- Considerando o efeito das covariáveis

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

- Covariáveis agem multiplicativamente no tempo de sobrevivência

Análise de Sobrevivência -- 2017

54

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

$$S(t|\mathbf{x}) = S_0 \left( t e^{-\mathbf{x}'\boldsymbol{\beta}} \right)$$

√ 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)

√ Caso o interesse seja probabilidade de estar morto troca-se o sinal dos  $\boldsymbol{\beta}$ 's.

Análise de Sobrevivência -- 2017

55

### Modelo de Regressão Exponencial

√ Modelo mais simples em Análise de Sobrevivência

- Componente determinístico:  $\exp\{\boldsymbol{\beta}'\mathbf{x}\}$
- Componente aleatório:  $\epsilon \sim$  exponencial padrão

√ Modelo de regressão exponencial

$$T = \exp\{\boldsymbol{\beta}'\mathbf{x}\}\epsilon$$

- Relação não linear entre T e x
- Componente de erro com distribuição assimétrica
- Função de ligação: logarítmica
- Resposta com distribuição exponencial

Análise de Sobrevivência -- 2017

56

- Modelo é linearizável 

$$Y = \ln(T) = \beta_0 + \beta_1 x_1 + \dots + \beta_p x_p + \nu$$

$$= \boldsymbol{\beta}'\mathbf{x} + \nu$$

√  $\nu \sim$  distribuição de valor extremo padrão

$$\nu = \ln(\epsilon), \text{ com } f(\nu) = \exp\{\nu - \exp\{\nu\}\}$$

$$\mathbf{x}' = (1, x_1, x_2, \dots, x_p)$$

$$\boldsymbol{\beta}' = (\beta_0, \beta_1, \dots, \beta_p)$$

√ Covariável x atua linearmente em Y e multiplicativamente em T

Análise de Sobrevivência -- 2017

57

- Parâmetro  $\alpha$  depende das covariáveis
  - $\alpha(\mathbf{x}) = \exp\{\beta'\mathbf{x}\}$
  - $\beta$ : estimativa dos efeitos das covariáveis
  - $\alpha$ : parâmetro que define o risco exponencial (assumido constante)
- Função de sobrevivência
  - ✓ Para Y, condicionada a x
    - $S(y|\mathbf{x}) = \exp\{-\exp\{y + \beta'\mathbf{x}\}\}$
  - ✓ Para T, condicionada a x:
    - $S(t|\mathbf{x}) = \exp\{-\beta'\mathbf{x}t\}$

Análise de Sobrevida -- 2017 58

- Modela o risco como uma função das covariáveis
  - ✓ Parâmetro  $\alpha$  depende das covariáveis
    - $\alpha(\mathbf{x}) = \exp\{\mathbf{x}'\beta\}$
  - ✓ Risco considerado constante para qualquer tempo t, dado os valores  $\mathbf{x}$  para as covariáveis
  - ✓ Exemplos:
    - 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 -- 2017 59

- Funções para o modelo de regressão exponencial
  - ✓ Função de risco
    - $\lambda(t|\mathbf{x}) = \alpha(\mathbf{x}) = \exp\{\beta'\mathbf{x}\}$
  - ✓ Função de sobrevivência:
    - $S(t|\mathbf{x}) = \exp\{-\alpha(\mathbf{x})t\} = \exp\{-\exp\{\beta'\mathbf{x}\}t\}$

Análise de Sobrevida -- 2017 60

### Estimação dos Parâmetros do Modelo

- Estimação dos efeitos das covariáveis ( $\beta$ 's da regressão)
  - ✓ Método da máxima verossimilhança
    - Adequado na presença de censura e ausência de normalidade

Análise de Sobrevida -- 2017 61

### 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

64

- 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
 

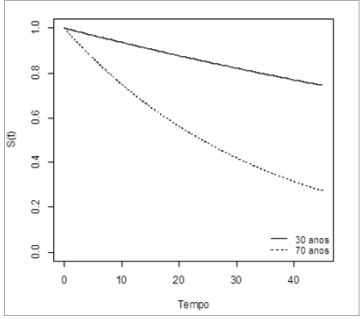
```
library(survival)
dialise <- read.csv("dados/dialise.csv", header = T)
reg.exp <- survreg(Surv(tempo, status)~idade, data = dialise,
+ dist='exponential')
reg.exp$coefficients
(Intercept)      idade       $\hat{\beta}_0 = -6,136$ 
6.13552416 -0.03700427       $\hat{\beta}_1 = 0,037$ 
```

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

65

- 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  $\exp\{0,037\} = 1,037$  vezes
  - √ Comparação 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
    - Indivíduos com diferença de 40 anos entre si geram um risco relativo estimado em 4,4 (modelo de riscos proporcionais)

66

- Curva de sobrevivência (30 e 70 anos)
 
  - √ Indivíduo com 70 anos progride 4,4 vezes mais rápido ao longo do tempo
    - acelera a uma taxa constante

67



### Modelo de Regressão de Weibull

√ Forma de generalizar o modelo exponencial

- Inclusão de parâmetro extra de escala, na presença de covariáveis

$$Y = \ln(T) = \beta_0 + \beta_1 x_1 + \dots + \beta_p x_p + \sigma v \\ = \beta' \mathbf{x} + \sigma v$$

- com:  $v \sim$  valor extremo padrão, e
- $Y = \ln(T) \sim$  Valor extremo com parâmetro de escala  $\sigma$  e parâmetro de locação  $\mu$ .

Análise de Sobrevivência -- 2017

68

- Modelo na escala original

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

√  $T \sim$  Weibull  $(\alpha, \gamma)$ , com parâmetro  $\alpha$  sendo modelado pelas covariáveis

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

- $\beta'$ : estimativa dos efeitos das covariáveis
- $\mathbf{x}'$ : valores das covariáveis

√ Relação entre os parâmetros da Weibull (escala original) e valor extremo (log-escala)

$$\alpha = \exp\{-\mu\}$$

$$\gamma = \frac{1}{\sigma}$$

Análise de Sobrevivência -- 2017

69

- Risco e sobrevivência modelados em função das covariáveis

√ Função de risco

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

√ Caso  $\alpha = g(\mathbf{x})$  (modelo em questão)

- Os riscos para diferentes indivíduos são proporcionais

√ Caso  $\gamma$  também varie com as covariáveis [ $\gamma = h(\mathbf{x})$ ]

- Modelo de regressão deixa de ser de riscos proporcionais

Análise de Sobrevivência -- 2017

70

- Parâmetro  $\gamma$ :

√  $\gamma > 1$ : o risco aumenta no tempo

√  $\gamma < 1$ : o risco diminui no tempo

√  $\gamma = 1$ : a função de risco é constante (exponencial)

Análise de Sobrevivência -- 2017

71

- Função de sobrevivência
  - √ Para Y, condicionada a x
 
$$S(y|x) = \exp \left\{ - \exp \left\{ \frac{y + \beta'x}{\sigma} \right\} \right\}$$
  - √ Para T, condicionada a x:
 
$$S(t|x) = \exp \{ -[\alpha(x)t]^\gamma \} = \exp \{ - (\exp \{ \beta'x \} t)^\gamma \}$$

$$S(t|x) = \exp \left\{ - (\exp \{ \beta'x t \})^{\frac{1}{\sigma}} \right\}$$

72

### 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

73

- 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

74

- Análise resultados

```

> 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
    
```

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

- √ Teste de significância do parâmetro
  - Efeito da idade ( $\beta_1$ ) é significativo
  - Parâmetro de forma ( $\gamma$ ) é significativamente diferente de 1
- √ Parâmetros da distribuição do tempo:
 
$$\hat{\alpha} = \exp\{-x'\beta\}$$

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

75

√ 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)

76

√ 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)

77

## Estratificação

- Utilização de estratos na modelagem
  - √ Subgrupos populacionais com parâmetros  $\gamma$  diferentes nas distribuições de seus tempos
  - √ Parâmetros regressão comuns em todos grupos
    - Mesmo efeito das covariáveis
  - √ Curva de risco basal variando entre os estratos
    - Melhoria na qualidade da estimativa do efeito das covariáveis
  - √ Nas situações em que for indicado:
    - Estimar o efeito das covariáveis para cada estrato

78

- Causa da insuficiência: doença congênita
  - √ Padrão de sobrevida pode ser muito diferente (mais transplantes em pacientes mais jovens)
- 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')
    
```

79

## Slide 76

---

**LFB1**

Conferir interpretação  $\exp\{0,0436\}$  (livro, pág 156) ou  $(\exp\{0,0436\})^{0,82}$  (risco relativo, página 156)

Lupercio; 13/11/2014

• 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

Coeficientes 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 -- 2017 80

**Modelo Simples – Comentários**

- Compatibilização entre saída do R e texto
  - ✓ Parâmetro  $\alpha$ :  $\hat{\alpha} = \exp\{-x'\beta\}$
  - ✓ Parâmetro  $\gamma$ :  $\hat{\gamma} = \frac{1}{\hat{\sigma}} = \frac{1}{scale}$
- Erro padrão e teste de significância ( $\gamma=1$ )
 
$$\ln(scale) = \ln\left(\frac{1}{\hat{\gamma}}\right)$$
- 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 -- 2017 81

• 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

Coeficientes significativos

Log scale

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

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

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

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

Análise de Sobrevivência -- 2017 82

**Modelo Estratificado – Comentários**

- Efeito de variável de estratificação não é estimado
- Níveis com parâmetros de escala diferentes
  - ✓ Congênita = 0
    - Risco de morrer diminui c/ tempo de hemodiálise
  - ✓ Congênita = 1
    - Risco de morrer aumenta c/ tempo de hemodiálise

Análise de Sobrevivência -- 2017 83

• 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

Scale:  
congenita=0 1.222  
congenita=1 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

$\hat{\beta}_0 = -6,7446$   
 $\hat{\beta}_{idade} = 0,04375$   
 $\hat{\beta}_{(idade) \times (congenita)} = 0,040735 = 0$

$\hat{\gamma}_{cong=0} = \frac{1}{1,222} = 0,818$   
 $\hat{\gamma}_{cong=1} = \frac{1}{0,894} = 1,118$

Interação não significativa

Log scale

Análise de Sobrevivência -- 2017 84

Modelo com Iteração – Comentários

- Efeito da interação entre idade e a doença congênita não é significativo
- Níveis com parâmetros de escala diferentes
  - ✓ Congênita = 0
    - Risco de morrer diminui c/ tempo de hemodiálise
  - ✓ Congênita = 1
    - Risco de morrer aumenta c/ tempo de hemodiálise

Análise de Sobrevivência -- 2017 85

• Resumos dos modelos – Saídas do R

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

Análise de Sobrevivência -- 2017 86

• Estimação dos parâmetros de forma

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

```
> # Parametros 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 -- 2017 87

• **Estimação dos riscos relativos**

$$\lambda(t|\mathbf{x}) = \gamma t^{\gamma-1} [\exp\{\beta' \mathbf{x}\}]^\gamma$$

```

> # 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
    
```

Análise de Sobrevivência -- 2017 88

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

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

Análise de Sobrevivência -- 2017 89

**Comentários**

- **Parâmetro de forma ( $\gamma$ )**
  - ✓ Bastante diferente em estrato de insuficiência renal causada por doença congênita
  - ✓  $\gamma_{\text{global}} \approx \gamma_{\text{congenita}=0}$ 
    - Apenas 2% dos pacientes com doença congênita
- **Aumento do risco de morte por ano de vida**
  - ✓ Maior em estrato de doença congênita
  - ✓ Mantém-se próximos em todos os modelos para estrato sem doença congênita

Análise de Sobrevivência -- 2017 90

• **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 -- 2017 91

√ 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 -- 2017 92

### Exemplo

- Sobrevivência ao diagnóstico de Aids
  - √ Pacientes com tempo de observação menor que 193 dias
    - Óbitos: 90
    - Censuras: 103
  - √ Objetivo:
    - Estimar efeito do tratamento controlado por idade e sexo

Análise de Sobrevivência -- 2017 93

- Modelo de regressão – 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	0.4521	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 -- 2017 94

- Modelo de regressão – 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 -- 2017 95



### 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



96

Análise de Sobrevivência -- 2017

### • 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)



97

Análise de Sobrevivência -- 2017

### • Parametrização dos modelos Weibull no R:

√ Na presença de covariáveis, os parâmetros de regressão  $\beta$  ficam com o sinal inverso ao que aparece na saída do pacote



98

Análise de Sobrevivência -- 2017

## Seleção de Modelos

## Seleção de Modelos Paramétricos



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

Análise de Sobrevivência -- 2017

100

## Teste da Razão de Verossimilhanças



- 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 -- 2017

101

## Exemplo



- Dados de Aids
  - √ Aplicação:
    - Comparar modelos 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         NA
2 idade + sexo + tratam      188 1484.049    = 1  2.893647 0.08892942
```

Análise de Sobrevivência -- 2017

102

## 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
```

### √ Hipóteses:

- $H_0$ : modhiv.wei não é significativo (modelo nulo)
  - $H_1$ : modhiv.wei é significativo
- $$RV = 2[l_{estimado} - l_{nulo}] = 2[(-742) - (-770,3)] = 56,6$$

Análise de Sobrevivência -- 2017

103

## Teste de Wald

- Testa a significância individual de covariáveis

✓  $H_0: \beta_j = 0$  vs.  $\beta_j \neq 0$

✓ Estatística de teste:  $z_j = \frac{\hat{\beta}_j}{\text{ep}(\hat{\beta}_j)}$

✓ Distribuição amostral (sob  $H_0$ ):  $Z_j \sim N(0, 1)$

## • 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      Pr(>|z|)
(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
```

Único efeito significativo:  
• tratamento

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

## Adequação do Modelo Ajustado

## Qualidade do Ajuste


- Avaliação da qualidade do ajuste de um modelo paramétrico

✓ Medida global de qualidade:

- Função desvio (ou *deviance*)
- Ferramenta gráfica

### Deviance

- 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 (não produz resíduos)
  - √ Parâmetros de perturbação são mantidos fixos
    - Parâmetros comuns aos dois ajustes e sem interesse no estimador
    - Ex. Parâmetro de forma no modelo de Weibull




Análise de Sobrevivência -- 2017 109

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

```
> # Deviance
> modhivwei.dev = sum(resid(modhiv.wei, type = "deviance")^2)
> modhivwei.dev
[1] 237.1074
> gl = 193 - 3 - 1
> 1-pchisq(modhivwei.dev, gl)
[1] 0.01004656
```

  - Teste de qualidade global de ajuste também rejeita  $H_0$
  - Teste de qualidade global de ajuste rejeita  $H_0$
  - Ainda assim, serão verificados riscos relativos relacionados os modelos Weibull e exponencial




Análise de Sobrevivência -- 2017 110

- Conclusão – Modelo Weibull:
  - √ O modelo foi rejeitado

	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

- √ Risco relativo:
  - Para cada medicamento acrescentado no tratamento, o risco diminui em 72,5%
 
$$\exp\{-1,486\}^{1/1,15} = 0,275$$



Análise de Sobrevivência -- 2017 111


- Conclusão – Modelo Exponencial
  - √ O modelo foi rejeitado

```
> 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
```

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



Análise de Sobrevivência -- 2017 112

• 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
```

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

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

$$= 1.491,924$$

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

**Análise Gráfica do Ajuste**

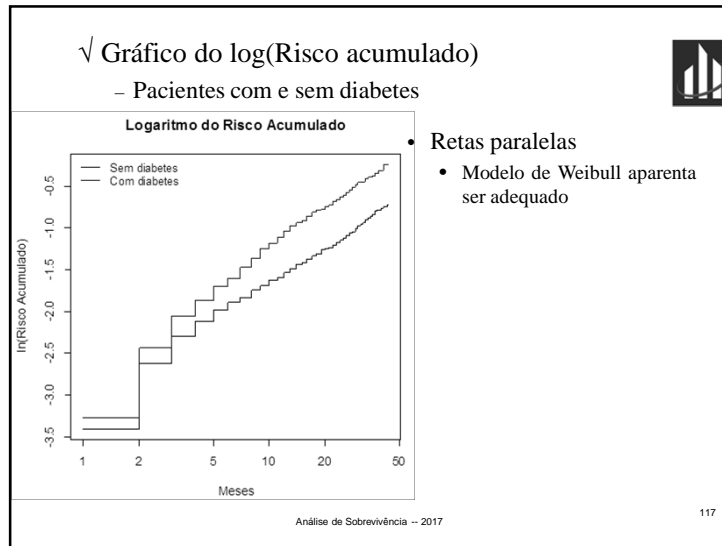
- Ferramenta exploratória
  - √ Auxiliar na escolha de distribuições candidatas
- Gráficos:
  - √  $\log(\Lambda(t))$  vs.  $\log(t)$
  - √ Comparação de curvas de sobrevivência
    - Estimador de Kaplan-Meier vs. Estimação paramétrica

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 de Weibull é candidato?



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 -- 2017 118

**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 -- 2017 119



## Comentários



- √ Análises gráficas para avaliação 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
- √ Métodos gráficos 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 -- 2017

121

- √ É comum diferentes modelos paramétricos terem ajustes razoáveis para um mesmo conjunto de dados
  - Em geral, em intervalos com concentração de observações, os modelos podem apresentar quantidades de interesse com resultados semelhantes



Análise de Sobrevivência -- 2017

122

## Análise de Resíduos



- Definição de uma medida de resíduo não é clara no contexto de sobrevivência
- 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 -- 2017

123

- Resíduos para modelos paramétricos e de Cox:

- √ Resíduo de Cox-Snell
- √ Resíduo martingale
- √ Resíduo *deviance*
- √ Resíduo de escore



Análise de Sobrevivência -- 2017

124

- 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 -- 2017

125

- 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 -- 2017

126

## 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 -- 2017

127

- 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 -- 2017

128



✓ Resíduos de perturbação de verossimilhança

- Coorte de Aids – modelo de regressão de Weibull

Vetor de Parâmetros

Valores Preditos

Parâmetro de Forma

- Casos identificados:

- 9, 10, 49, 82, 182

Análise de Sobrevivência – 2017

• 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 – 2017

• 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 – 2017

• Modelo de regressão de 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 – 2017

• Modelo de regressão de Weibull

√ Sem o caso 82

```
> 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
```

√ Modelo de Weibull – Comparação

	Completo	Sem indivíduo 82
Intercept	6,0684 (0,5674)	5,7996 (0,5760)
Idade	0,0095 (0,0130)	0,0151 (0,0133)
sexoM	-0,2363 (0,3277)	-0,2603 (0,3231)
tratam	1,4861 (0,2273)	1,5490 (0,2266)
Scale	1,1524	1,1367
Shape	0,868	0,880
Loglik(model)	-742,02	-739,21

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

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

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

**Exemplos de Aplicação**

**Exemplo**

• Sobrevida 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:  $\log_{10}(\text{WBC})$

### √ 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 -- 2017 137

### • Modelo de regressão para análise dos dados

#### √ Gráficos de linearização - sem a covariável: lwbc

Candidatas:

- Exponencial
- Weibull

Análise de Sobrevivência -- 2017 138

### √ 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

Exponential distribution  
Loglik(model)= -83.9 Loglik(intercept only)= -83.9  
Chisq= 6.83 on 1 degrees of freedom, p= 0

```
> 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

Weibull distribution  
Loglik(model)= -83.9 Loglik(intercept only)= -87.1  
Chisq= 6.48 on 1 degrees of freedom, p= 0.012

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 -- 2017 139

### • Estimativas dos modelos

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  $\gamma$  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 -- 2017 140

• Avaliação do ajuste

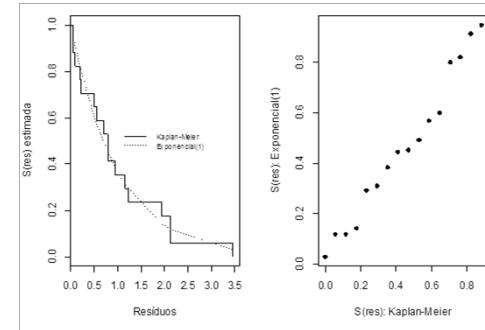
√ Resíduos de Cox-Snell – modelo exponencial

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

√ 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

√ Modelo Exponencial – Análise gráfica dos resíduos Cox-Snell



√ Modelo adequado

- Exponencial padrão parece aceitável

• 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  $H_0$

- Possível que parte da variação observada nos tempos de sobrevivência possa ser explicada pela contagem de glóbulos brancos


• 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,  $\beta_1$  é positivo

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



- 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 condicionada ao valor de  $x_1$ :
 
$$S(t|x_1) = \exp\{-\exp\{-8,4775 + 1.1093x_1\}t\}, t \geq 0$$
- Análise de Sobrevivência -- 2017 146

- ### Exemplo
- Sobrevida pacientes com leucemia aguda
    - √ Sobrevivência a diagnóstico (semanas)
      - 17 pacientes expressando antígeno Calla (Ag+)
      - 16 paciente não expressando 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-).
    - √ Escolhido modelo de regressão exponencial para o grupo Ag+.
      - Investigar se o mesmo se aplica ao grupo Ag-
- Análise de Sobrevivência -- 2017 148

√ Pacientes com leucemia – Conjunto de dados

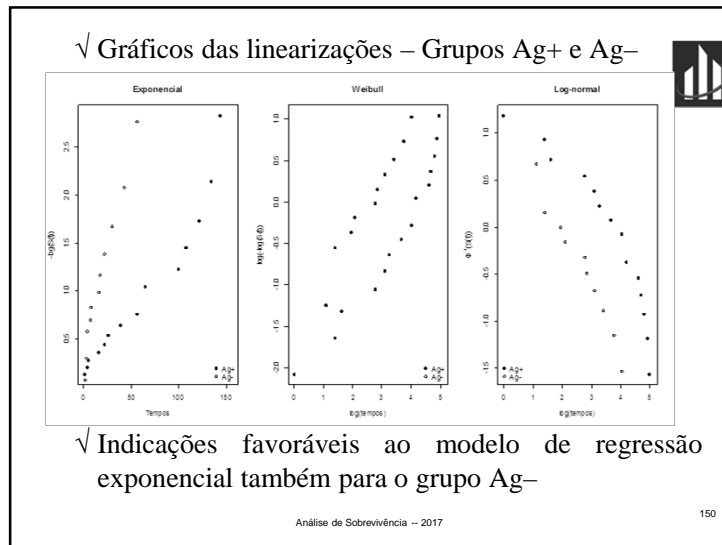
```

> 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 -- 2017 149



- 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 -- 2017 151

```
> 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 -- 2017 152

```
> 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:**  
 $X_1$  e  $X_2$

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

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

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

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

Análise de Sobrevivência -- 2017 153

```

> 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 -- 2017 154

√ 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 $X_1 * X_2$	$\beta_0 = -8,4775$ $\beta_1 = 1,1093$ $\beta_2 = 4,1385$ $\beta_3 = -0,7557$	$l_5 = -145,7$

Análise de Sobrevivência -- 2017 155

√ Testes da razão de verossimilhanças:

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 da significância do efeito de  $X_1$  ( $p = 0,0047$ )
- √ Evidências da significância do efeito de  $X_2$  ( $p = 0,0058$ )

Análise de Sobrevivência -- 2017 156

√ Análise gráfica dos resíduos Cox-Snell:

– Modelo exponencial

– Modelo exponencial apresenta ajuste razoável

Análise de Sobrevivência -- 2017 157

√ 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)
- Possível que parte da variação observada na resposta possa ser explicada pela contagem de glóbulos brancos e pelo grupo de antígeno

Análise de Sobrevivência -- 2017 158

- Modelo 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 -- 2017 159

√ Curvas de sobrevivências – Ag+ e Ag-

√ Pacientes Ag- com menor sobrevivência

- Menor sobrevivência para pacientes com  $x_1$  maior

Análise de Sobrevivência -- 2017 160

√ Riscos estimados pelo modelo – Ag+ e Ag-


√ Riscos constantes ao longo do tempo

- Quanto maior a contagem, maior o risco

Análise de Sobrevivência -- 2017 161




- 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 — 2017 162

### 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 desmame
  - √ Covariáveis: 11
  - √ Objetivo:
    - Identificar fatores de risco ou de proteção para desmame precoce




Análise de Sobrevida — 2017 163

- 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

- √ Possível comparar categorias por K-M
  - Todas as variáveis são dicotômicas


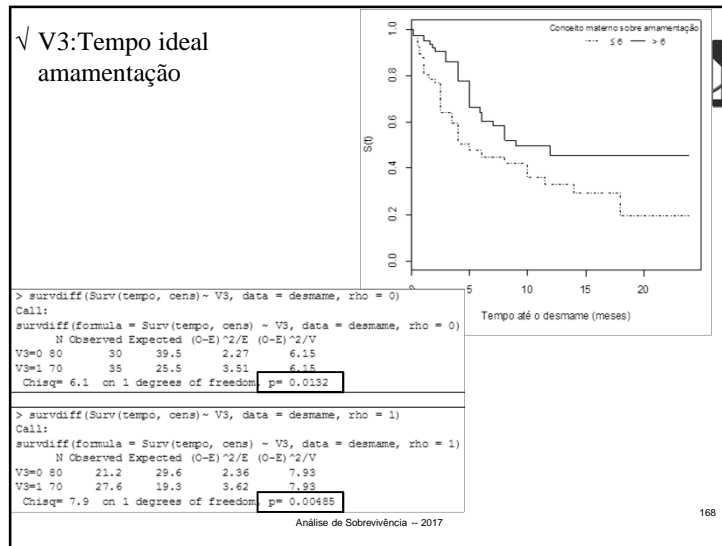
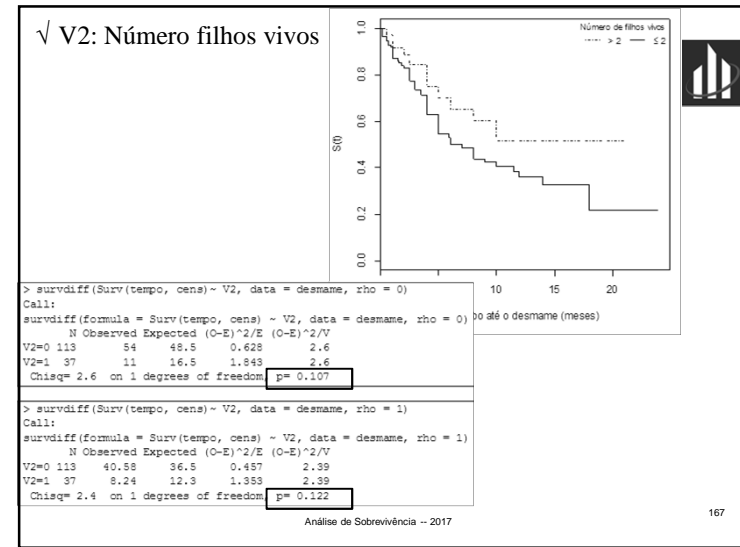



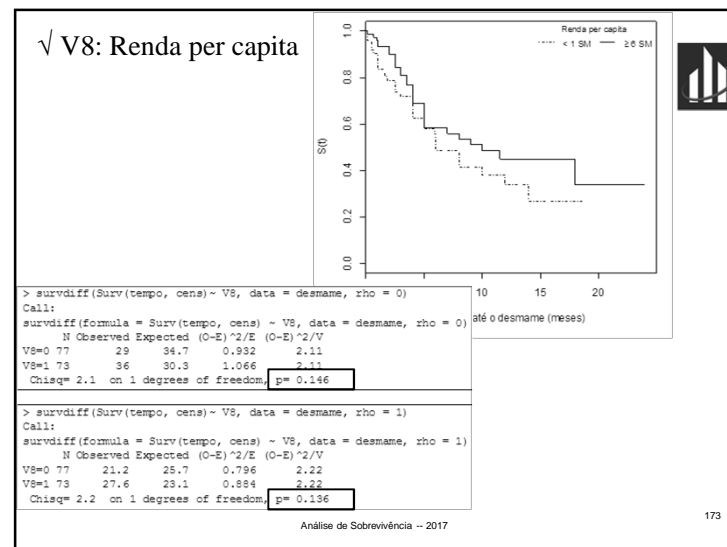
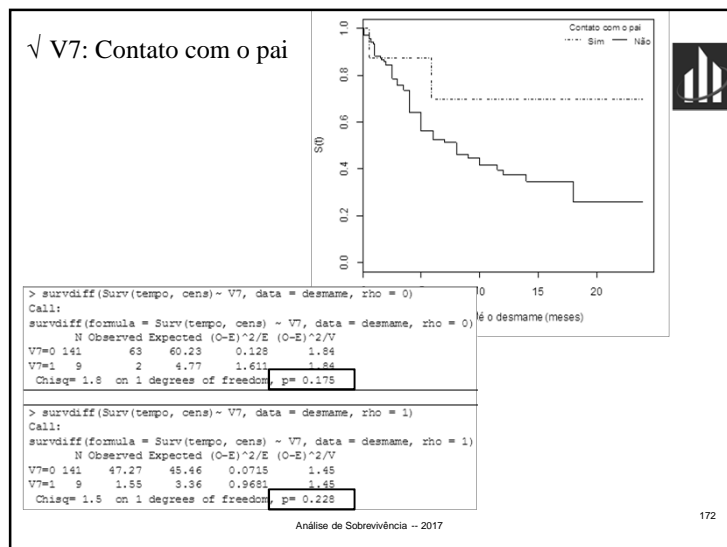
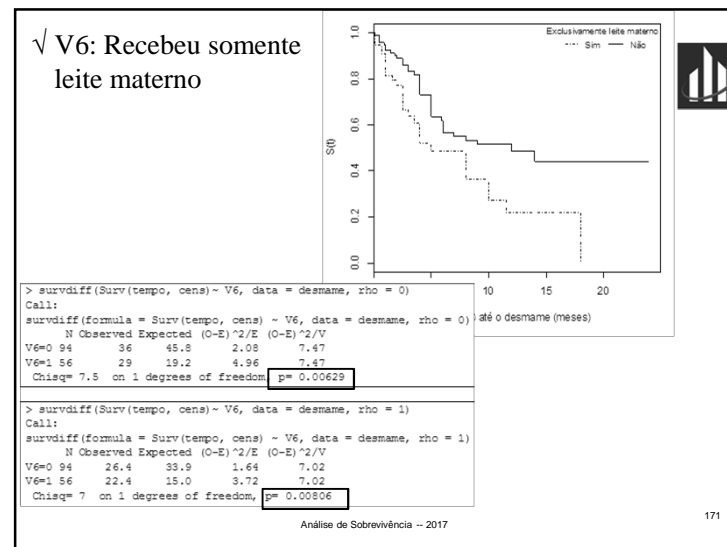

Análise de Sobrevida — 2017 164

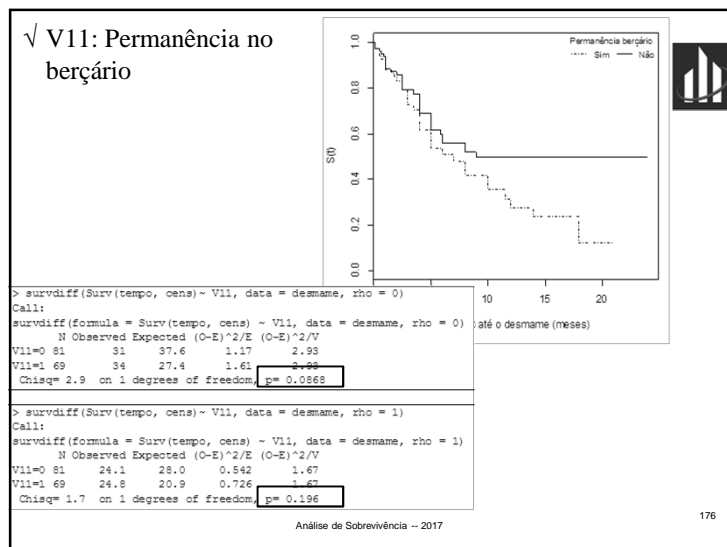

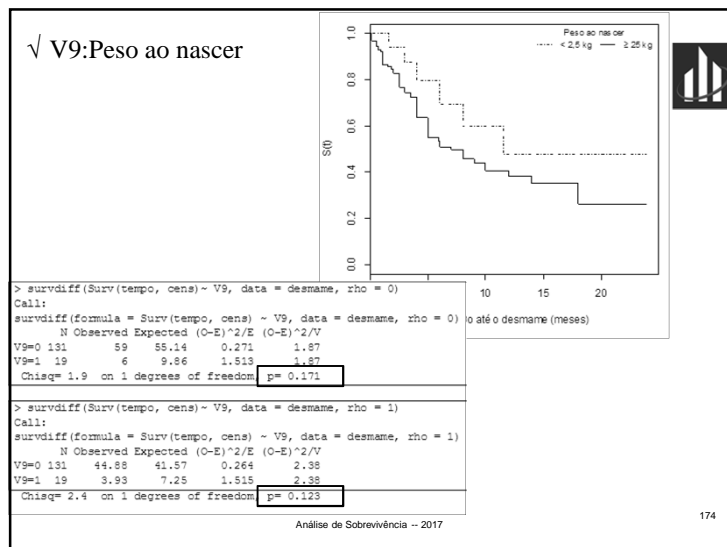
- Análise Exploratória
  - √ Construir estimativas Kaplan-Meier para comparar as duas categorias
  - √ Conduzir testes logrank e Peto para testar
    - $H_0: S_1(t) = S_2(t)$
  - √ Todas as covariáveis com p-valor < 0,25 devem ser incluídas na etapa de modelagem estatística
    - Nível de significância modesto 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 — 2017 165







### √ Tabela de valores dos testes logrank e Peto

Código	Variável	Descrição	Valor	Qte.	logrank		Peto	
					$\chi^2$	p-valor	$\chi^2$	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					

- Todos os p-valores menores que 0,25

Análise de Sobrevivência -- 2017 177

- **Comentários:**

- √ 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 — 2017

178

- **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 — 2017

179

- **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 — 2017

180

- **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 — 2017

181

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

Análise de Sobrevivência -- 2017 182

- Em geral, ajusta-se a gama generalizada para o Teste de Razão de Verossimilhanças
  - √ Aninha os modelos exponencial, de Weibull, lognormal e gama
- Ajuste do modelo gama generalizado:
 

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

Análise de Sobrevivência -- 2017 183

- Ajuste de modelos com uma única covariável

Passo 1		$l(\theta)$	$-2l(\hat{\theta})$	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

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

Covariáveis excluídas: V5, V7, V10, V11

Análise de Sobrevivência -- 2017 185

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 -- 2017 186

- 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

### 3. Ajustar modelo com covariáveis retidas no passo 2



- As covariáveis excluídas no passo 2 retornam ao modelo para confirmar sua significância estatística

- 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	424,950		
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

### 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

- 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

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

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

- Inclusão covariáveis significativas em 4

√ Testa-se possibilidade da retirada de alguma 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

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



• 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

• Modelo Final:

√ Efeitos principais identificados no passo 5

- V3, V4, V6, V8

√ Termos de interação identificados no passo 6

- Nenhum é significativo

• 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 permanência de variável baseada em evidências clínicas

• 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

• 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
```

• Busca de modelo mais parcimonioso

	$l(\theta)$	$-2l(\theta)$	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

• 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
```

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

• 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	

## 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 -- 2017

203

## Resíduos padronizados

- √ Baseado na representação dos modelos log-lineares

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

- √ Modelo lognormal bem ajustado para os dados:
  - Resíduos com distribuição aproximadamente normal padrão
  - Exponencial dos resíduos com distribuição lognormal

Análise de Sobrevivência -- 2017

204

## Procedimento:

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

Análise de Sobrevivência -- 2017

205

## 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 = "Residuos (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 -- 2017

206

√ 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 -- 2017 207

√ 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 -- 2017 208

- 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 -- 2017 209

- 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$time
> a.t <- snell.km$surv
> a.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, a.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, a.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 -- 2017 210

√ 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 -- 2017 211

### 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 -- 2017 212

- 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 -- 2017 213

- √ 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 -- 2017 214

## Referências

## Bibliografia



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

Análise de Sobrevivência – 2017

Prof. Lupércio<sup>217</sup>

## Material de Apoio



- R:  
√ [www.r-project.org](http://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 – 2017

Prof. Lupércio<sup>218</sup>