

## **Análise de Sobrevida Aplicada à Saúde**

Lupércio França Bessegato  
Dep. Estatística/UFJF

### **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

## **Modelo de Regressão de Cox**

### **Introdução**

- Interesse:
  - √ Modelar o efeito de covariáveis sobre o tempo de sobrevivência (risco)
- Modelo de riscos proporcionais de Cox
  - √ Modelo de regressão mais utilizado em Sobrevida
  - √ Efeito multiplicativo das covariáveis
- Modelo de Cox estendido
  - √ Modelagem de situações complexas com base em processo de contagem

Análise de Sobrevida Aplicada à Saúde -- 2014

• Exemplo – Estudo clínico aleatorizado:

√ Comparação dos tempos de sobrevida

√ Grupos:

- Tratamento padrão (grupo 0)
- Novo tratamento (grupo 1)

√ A única covariável é indicadora de grupo

$$x = \begin{cases} 0, & \text{se grupo 0} \\ 1, & \text{se grupo 1} \end{cases}$$

√ Forma mais simples do modelo de Cox

Análise de Sobrevivência Aplicada à Saúde -- 2014

√ Funções de risco:

- $\lambda_0(t)$ : função de risco do grupo padrão
- $\lambda_1(t)$ : função de risco do grupo tratamento

√ Assume-se proporcionalidade entre as funções

$$\frac{\lambda_1(t)}{\lambda_0(t)} = \exp\{\beta x\} = K, \forall t.$$

√ Modelo de Cox para uma única covariável

$$\lambda(t) = \lambda_0(t) \exp\{\beta x\}$$

$$\lambda(t) = \begin{cases} \lambda_1(t) = \lambda_0(t) \exp\{\beta\} & , \text{ se } x = 1 \\ \lambda_0(t), & , \text{ se } x = 0. \end{cases}$$

Análise de Sobrevivência Aplicada à Saúde -- 2014

### Modelo de Riscos Proporcionais

• Ajusta a função de risco  $\lambda(t)$

√ Considera um risco basal  $\lambda_0(t)$

√ Inclui o vetor de covariáveis  $\mathbf{x}$

$$\lambda(t|\mathbf{x}) = \lambda_0(t) \exp(x_1\beta_1 + x_2\beta_2 + \dots + x_p\beta_p) = \lambda_0(t) \exp(\mathbf{x}'\boldsymbol{\beta})$$

• Razão entre o risco de ocorrência do evento para dois indivíduos  $k$  e  $l$ , com covariáveis  $\mathbf{x}_k$  e  $\mathbf{x}_l$

$$\frac{\lambda_k(t|\mathbf{x}_k)}{\lambda_l(t|\mathbf{x}_l)} = \frac{\exp(\mathbf{x}'_k\boldsymbol{\beta})}{\exp(\mathbf{x}'_l\boldsymbol{\beta})} = \exp\{(\mathbf{x}'_k - \mathbf{x}'_l)\boldsymbol{\beta}\}$$

√ Razão de riscos NÃO varia ao longo do tempo

Análise de Sobrevivência Aplicada à Saúde -- 2014

• Riscos proporcionais:

√ O risco de desenvolvimento do câncer ao longo do tempo para quem fuma é sempre o mesmo ao longo do tempo

√ Algumas pessoas vão desenvolver rapidamente e outras mais tarde, mas sempre na mesma proporção estimada

(Exponencial do coeficiente [ $\exp\{\beta_{\text{Fumo}}\}$ ])

Análise de Sobrevivência Aplicada à Saúde -- 2014

√ Outras formas do modelo de riscos proporcionais:

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

√ Risco acumulado basal  $\Lambda_0(t) = \int_0^t \lambda_0(s) ds$

√ Sobrevivência basal  $\hat{S}_0(t) = \exp[-\hat{\Lambda}_0(t)]$

√ Estimativa do risco basal:  $\hat{\Lambda}_0(t) = \sum_{i:t_i \leq t} \frac{\Delta N_i(t)}{\sum_{j \in R(t_i)} \exp(\mathbf{x}'\hat{\boldsymbol{\beta}})}$

Análise de Sobrevivência Aplicada à Saúde -- 2014

• Modelo de Cox é dito semi-paramétrico:

√ Componente paramétrico do modelo

– Supõe que as covariáveis agem multiplicativamente

√ Componente não paramétrico do modelo

– Não assume distribuição para o tempo de sobrevivência na estimação dos efeitos das covariáveis nem na função de risco basal  $\lambda_0(t)$

√ Observação:

–  $\beta_0$  não aparece no componente paramétrico

– É absorvido pelo componente não paramétrico  $\lambda_0(t)$

Análise de Sobrevivência Aplicada à Saúde -- 2014

### Modelo de Cox – Suposições

- Covariáveis agem multiplicativamente sobre o risco
  - √ Parte paramétrica do modelo
- Razão de risco é constante ao longo do tempo
  - √ Riscos proporcionais
- Os tempos de ocorrência do evento são independentes
- Não há empates na ocorrência do evento
  - √ Tempo é contínuo

Análise de Sobrevivência Aplicada à Saúde -- 2014

### Modelo de Cox – Comentários

- É o modelo mais utilizado em estudos clínicos
  - √ A presença do componente não paramétrico torna o modelo bastante flexível
- Caso particular do modelo de Cox
  - √ Modelo de regressão de Weibull

Análise de Sobrevivência Aplicada à Saúde -- 2014

### Ajustando o Modelo de Cox

- Modelo caracterizado pelos coeficientes  $\beta$ 's:
  - √ Medem os efeitos das covariáveis na função de risco
  - √ Quantidades são estimadas a partir das observações
- O componente não paramétrico  $\lambda_0$  na função de verossimilhança torna o método de máxima verossimilhança inapropriado

Análise de Sobrevivência Aplicada à Saúde -- 2014

- Função de verossimilhança dos  $\beta$ 's:

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

- √ No modelo de Cox

$$S(t_i|\mathbf{x}_i) = \exp \left\{ - \int_0^{t_i} \lambda_0(u) \exp\{\mathbf{x}'_i \beta\} du \right\}$$

$$= [S_0(t_i)]^{\exp\{\mathbf{x}'_i \beta\}}$$

então 
$$L(\beta) = \prod_{i=1}^n [\lambda_0(t_i) \exp\{\mathbf{x}'_i \beta\}]^{\delta_i} [S_0(t_i)]^{\exp\{\mathbf{x}'_i \beta\}}$$

que é função do componente não paramétrico  $\lambda_0$ .

Análise de Sobrevivência Aplicada à Saúde -- 2014

- Solução:
  - √ Condicionar a construção da função de verossimilhança ao conhecimento histórico passado de desfechos e censuras
  - √ Objetivo:
    - eliminar esta função de perturbação da verossimilhança

Análise de Sobrevivência Aplicada à Saúde -- 2014

### Estimação dos Coeficientes

- Modelo de regressão de Cox:
  - √ Determinação da função de verossimilhança parcial:
    - Elimina-se a função de risco basal
    - Considera a informação dos indivíduos sob risco em cada tempo  $t$
    - Formulação semelhante aos modelos não paramétricos (Kaplan-Meier), mas que permite a estimação dos efeitos das covariáveis (fatores de risco no tempo de sobrevivência)

Análise de Sobrevivência Aplicada à Saúde -- 2014

### Verossimilhança Parcial

√ Sejam  $t_1 < t_2 < \dots < t_m$ ,  $m$  tempos diferentes ordenados (sem empate)

√  $L_i$ : verossimilhança individual

(contribuição individual para o tempo de sobrevivência  $t_i$ )

$$L_i = \frac{\lambda_i(t_i)}{\sum_{j \in R(t_i)} \lambda_j(t_j)} = \frac{\exp(\mathbf{x}'_i \boldsymbol{\beta})}{\sum_{j \in R(t_i)} \exp(\mathbf{x}'_j \boldsymbol{\beta})}$$

– Razão entre o risco do indivíduo  $i$  apresentar o evento em  $t_i$  e a soma dos riscos até a ocorrência do evento em todos os indivíduos sob risco

Análise de Sobrevida Aplicada à Saúde -- 2014

- Função de verossimilhança parcial

$$L(\boldsymbol{\beta}) = \prod_{i=1}^m \frac{\exp(\mathbf{x}'_i \boldsymbol{\beta})}{\sum_{j \in R(t_i)} \exp(\mathbf{x}'_j \boldsymbol{\beta})}$$

$$= \prod_{i=1}^n \left[ \frac{\exp(\mathbf{x}'_i \boldsymbol{\beta})}{\sum_{j \in R(t_i)} \exp(\mathbf{x}'_j \boldsymbol{\beta})} \right]^{\delta_i}$$

- Estimadores de máxima verossimilhança:

√ Valores de  $\boldsymbol{\beta}$  que maximizam a função de verossimilhança parcial

- A função de verossimilhança parcial assume que os tempos de sobrevivência são contínuos

√ Não pressupõe a possibilidade de empates

Análise de Sobrevida Aplicada à Saúde -- 2014

- Definição da verossimilhança parcial em notação de processo de contagem:

$$L_i = \frac{\exp(\mathbf{x}'_i \boldsymbol{\beta})}{\sum_{t \geq 0} Y_j(t) \exp(\mathbf{x}'_j \boldsymbol{\beta})}$$

√  $Y_j(t)$ : indicadora de risco do indivíduo  $j$  em  $t$   
(1 se o indivíduo  $j$  estiver em risco no tempo  $t$ )

√ Verossimilhança parcial não depende do risco basal

Análise de Sobrevida Aplicada à Saúde -- 2014

- Verossimilhança parcial  $L(\boldsymbol{\beta}) =$  produto das  $L_i$

$$L(\boldsymbol{\beta}) = \prod_{i=1}^n \prod_{t \geq 0} \left\{ \frac{Y_i(t) \exp(\mathbf{x}'_i \boldsymbol{\beta})}{\sum_j Y_j(t) \exp(\mathbf{x}'_j \boldsymbol{\beta})} \right\}^{\Delta N_i(t)}$$

√  $\Delta N_i(t)$ : diferença entre a contagem de eventos até o instante  $t$  e a contagem no momento imediatamente anterior a  $t$

√ Numerador: indivíduos que experimentaram o evento

√ Denominador: todos os indivíduos que não experimentaram o evento (inclusive as censuras)

Análise de Sobrevida Aplicada à Saúde -- 2014

### Empates

- Podem ocorrer na prática:
  - √ Empates devido à escala de medidas
    - Tempos em dias, meses e até mesmo em anos
  - √ Empates entre desfechos e censuras
    - Convencionou-se que a censura ocorreu após o desfecho
- Quando ocorrem empates no tempo de sobrevivência
  - √ Necessária modificar a função de verossimilhança parcial para incorporar as observações empatadas
  - √ Função de verossimilhança exata envolve permutações
    - Pode consumir muito tempo computacional

Análise de Sobrevivência Aplicada à Saúde -- 2014

- Aproximação da verossimilhança parcial:

- √ Simples e muito usada nos pacotes
  - Proposta por Breslow (1972) e Peto (1972)

$$L(\beta) = \prod_{i=1}^m \frac{\exp(\mathbf{s}_i' \beta)}{\left[ \sum_{j \in R(t_i)} \exp(\mathbf{x}_j' \beta) \right]^{\Delta N_i(t_i)}}$$

- √  $\mathbf{s}_i$ : vetor formado pela soma das correspondentes  $p$  variáveis para os indivíduos com desfecho no tempo  $t_i$ .
- √  $\Delta N_i(t)$ : número de falhas no tempo  $t_i$ .

Análise de Sobrevivência Aplicada à Saúde -- 2014

### Estimadores de Máxima Verossimilhança Parcial

- Propriedades assintóticas:
  - √ Estimadores são consistentes e assintoticamente normais
    - (Andersen e Gill, 1982)
- Propriedades necessárias para a construção de intervalos de confiança e para testar hipóteses sobre os coeficientes do modelo
  - √ É possível utilizar:
    - Estatística de Wald
    - Estatística da Razão de Verossimilhanças
    - Estatística Escore

Análise de Sobrevivência Aplicada à Saúde -- 2014

### Interpretação dos Coeficientes

- Modelo de Cox:
  - √ Efeito das covariáveis é acelerar ou desacelerar a função de risco
- Razão de risco de dois indivíduos:
  - √ Mesmos valores para as covariáveis exceto para  $x_l$ 

$$\frac{\lambda_i(t)}{\lambda_j(t)} = \exp\{\beta_l(x_{il} - x_{jl})\}$$
    - Razão de riscos: constante no tempo
  - √ Ex.:  $x_l$ : indicadora de paciente hipertenso
    - O risco de morte de hipertensos é  $\exp\{\beta_l\}$  vezes o risco de pacientes com pressão normal (demais covariáveis fixas)

Análise de Sobrevivência Aplicada à Saúde -- 2014

- Estimativa pontual para  $\exp\{\beta_l\}$ :
  - √ Utiliza-se a propriedade de invariância do estimador de máxima verossimilhança parcial
- Erro padrão de  $\exp\{\beta_l\}$ :
  - √ Utiliza-se o método delta
- Intervalo de confiança para  $\exp\{\beta_l\}$ :
  - √ 1 pertence ao intervalo
    - Indica não haver evidências de que haja diferenças significativas de risco entre os dois grupos (se dicotômica)

Análise de Sobrevivência Aplicada à Saúde -- 2014

- Para variáveis categóricas:
  - √ Razão de riscos:  $e^{\hat{\beta}_l}$
- Exemplo:
  - √ Covariável grupo com 3 níveis
    - (0: controle; 1: grupo 1; 2: grupo 2)
  - √ Termo referente a esta covariável no modelo
$$\beta_1 x_1 + \beta_2 x_2$$
    - $x_1$ : indicadora do grupo 1
    - $x_2$ : indicadora do grupo 2

Análise de Sobrevivência Aplicada à Saúde -- 2014

- Estimativas pontuais e intervalares:
$$e^{\hat{\beta}_1} = 2,0(1,5; 4,1)$$
$$e^{\hat{\beta}_2} = 1,2(0,7; 1,8)$$
  - √ Comparação entre grupos de controle e 1
    - Existe diferença significativa
    - Risco de morte para os pacientes do grupo 1 é 2 vezes o risco dos pacientes do grupo controle
  - √ Comparação entre grupos de controle e 2
    - Não existe diferença significativa

Análise de Sobrevivência Aplicada à Saúde -- 2014

- Interpretação para variáveis contínuas:
  - √ Ex.: efeito de idade é significativo
$$e^{\hat{\beta}_{idade}} = 1,05$$
    - Se aumentarmos 1 ano a idade, o risco de morte fica aumentado em 5%

Análise de Sobrevivência Aplicada à Saúde -- 2014

### Estimando Funções Relacionadas a $\lambda_0(t)$

- Quantidades de interesse na modelagem estatística
  - √ Coeficientes da regressão
- Funções relacionadas com  $\lambda_0(t)$ 
  - √ Função de risco acumulado basal

$$\Lambda_0(t) = \int_0^t \lambda_0(u) du$$

- É de grande importância na avaliação gráfica do modelo ajustado

Análise de Sobrevivência Aplicada à Saúde -- 2014

- √ Função de sobrevivência basal

$$S_0(t) = \exp[-\Lambda_0(t)]$$

- √ Função de sobrevivência

$$S(t) = [S_0(t)]^{\exp(\mathbf{x}'\boldsymbol{\beta})}$$

- Útil quando se deseja analisar percentis associados a grupos de indivíduos

Análise de Sobrevivência Aplicada à Saúde -- 2014

- $\lambda_0(t)$  não é especificada parametricamente
  - √ Função eliminada pelo argumento condicional
  - √ Seus estimadores são de natureza não paramétrica

- Estimador para  $\Lambda_0(t)$

- √ Estimador de Nelson-Aalen-Breslow (Breslow, 1972)

$$\hat{\Lambda}_0 = \sum_{j:t_j \leq t} \frac{\Delta N(t_j)}{\sum_{l \in R_j} \exp\{\mathbf{x}'_l \boldsymbol{\beta}\}}$$

- √  $\Delta N(t_j)$ : número de desfechos em  $t_j$ .
- √ Na ausência de covariáveis a expressão é o estimador de Nelson-Aalen

Análise de Sobrevivência Aplicada à Saúde -- 2014

- Estimativas da sobrevivência:

$$\hat{S}_0(t) = \exp[-\hat{\Lambda}_0(t)]$$

$$\hat{S}(t|\mathbf{x}) = [\hat{S}_0(t)]^{\exp(\mathbf{x}'\hat{\boldsymbol{\beta}})}$$

Análise de Sobrevivência Aplicada à Saúde -- 2014

### Exemplo

- Transplante de medula óssea
  - √ Objetivo: avaliação dos fatores prognósticos associados a transplante de medula óssea
  - √ Pacientes: 96
    - Óbitos: 49
    - Censuras: 47
  - √ Banco de dados: *tmoclas.dat*

```
> library(survival)
> tmo <- read.table("dados/tmoclas.dat", header = T, sep = " ")
> tmo.tot = survfit(formula = Surv(os, status)~1, data = tmo)
> tmo.tot
Call: survfit(formula = Surv(os, status) ~ 1, data = tmo)
records  n.max n.start  events  median 0.95LCL 0.95UCL
      96    96     96     49    453    370     NA
```

Análise de Sobrevida Aplicada à Saúde -- 2014

- Resposta:
  - √ os: tempo de sobrevivência desde o transplante até o óbito
  - √ status: 0: censura; 1: óbito
- Covariáveis:
  - √ sexo: 1: masculino; 2: feminino
  - √ idade: idade na data do transplante (anos)
  - √ fase: fase da doença no momento do transplante (1: crônica; 2: aguda; 3: crise blástica)
  - √ deag: doença enxerto contra hospedeiro aguda (0: não; 1: sim)
  - √ decr: doença enxerto contra hospedeiro crônica (0: não; 1: sim)

Análise de Sobrevida Aplicada à Saúde -- 2014

### Análise Exploratória

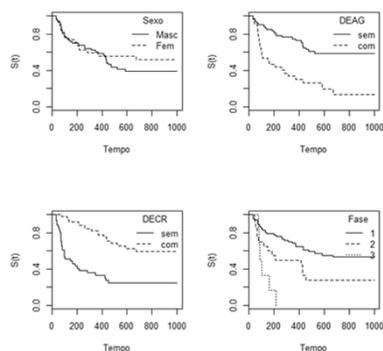
- Curvas de sobrevivência estimadas pelo método de Kaplan-Meier:
  - √ Objetivo:
    - Verificar o pressuposto de proporcionalidade dos riscos das variáveis a serem incluídas no modelo

Análise de Sobrevida Aplicada à Saúde -- 2014

- Covariáveis com pequeno número de categorias:
  - √ Gráfico da sobrevivência estratificado poderá dar indicação de proporcionalidade
    - Curvas razoavelmente paralelas ao longo de todo o tempo (podem indicar proporcionalidade)
    - Curvas com entrelaçamento ou variação na distância entre as curvas das categorias (podem indicar ausência de proporcionalidade)

Análise de Sobrevida Aplicada à Saúde -- 2014

• Avaliação do pressuposto de proporcionalidade



√ Parece razoável admitir proporcionalidade

- Variável sexo apresenta superposição, afastando-se no final (número de observações é pequeno)

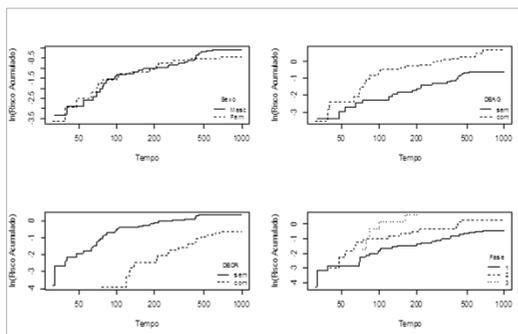
Análise de Sobrevivência Aplicada à Saúde -- 2014

√ Outra forma de visualização

- Gráfico do logaritmo da função de risco acumulado em cada categoria (duas retas paralelas podem indicar proporcionalidade)

Análise de Sobrevivência Aplicada à Saúde -- 2014

• Avaliação do pressuposto de proporcionalidade



√ Parece razoável admitir proporcionalidade

- Variável sexo apresenta superposição

Análise de Sobrevivência Aplicada à Saúde -- 2014

• Estimação do Modelo de Cox:

```
> # Modelo de Cox - covariáveis Idade e Sexo
>
> m1 <- coxph(Surv(os, status)~(idade + sexo), data = tmo, x =
TRUE)
> summary(m1)
Call:
coxph(formula = Surv(os, status) ~ (idade + sexo), data = tmo,
x = TRUE)

n= 96, number of events= 49

             coef exp(coef) se(coef)      z Pr(>|z|)
idade -0.02167  0.97857  0.01399 -1.548  0.122
sexo2  -0.37649  0.68626  0.32120 -1.172  0.241

             exp(coef) exp(-coef) lower .95 upper .95
idade   0.9786      1.022  0.9521  1.006
sexo2   0.6863      1.457  0.3657  1.288

Concordance= 0.568 (se = 0.044 )
Rsquare= 0.03 (max possible= 0.986 )
Likelihood ratio test= 2.92 on 2 df,  p=0.232
Wald test            = 2.85 on 2 df,  p=0.2408
Score (logrank) test = 2.85 on 2 df,  p=0.2406
```

Sexo feminino:

- Risco 0,68 vezes menor de ir a óbito do que sexo masculino
- IC da razão inclui 1

Sexo masculino

- Risco 1,45 vezes maior do que sexo feminino

Análise de Sobrevivência Aplicada à Saúde -- 2014

### Interpretação dos Coeficientes

- Coeficiente:
  - √ Valores positivos:
    - Variáveis que contribuem para o aumento do risco
  - √ Valores negativos:
    - Variáveis que contribuem para a redução do risco
- Exponencial do coeficiente
  - √ Risco relativo ou razão de riscos (*hazard ratio*)
    - Maiores que 1: sobrerisco
    - Entre 0 e 1: proteção

Análise de Sobrevivência Aplicada à Saúde -- 2014

	exp(coef)	exp(-coef)	lower .95	upper .95
idade	0.9786	1.022	0.9521	1.006
sexo2	0.6863	1.457	0.3657	1.288

- No exemplo:
  - √ Paciente do sexo feminino tem risco 0,68 vezes (ou 32%) menor de ir a óbito do que do sexo masculino
    - IC da razão de riscos: [0,365; 1,288]
  - √ Paciente do sexo masculino tem risco 1,45 vezes (ou 45%) maior de ir a óbito a cada unidade de tempo
    - IC da razão de riscos: [1/1,29; 1/0,37] = [0,78; 2,74]
  - √ Estimativa de risco atribuído ao sexo e idade não é significativo
    - Intervalo de confiança engloba a unidade

Análise de Sobrevivência Aplicada à Saúde -- 2014

### Modelo de Cox Estratificado

- $\lambda_0(t)$  não é o mesmo para todos os indivíduos
  - √  $\lambda_{0A}(t) \neq \lambda_{0B}(t) \neq \lambda_{0C}(t)$ , definindo diferentes estratos
- Usado quando alguma covariável não atende à proporcionalidade
- Não será estimado o efeito da variável para a qual se estratifica

Análise de Sobrevivência Aplicada à Saúde -- 2014

### Formalização do Procedimento

- Modelo estratificado para o estrato  $j$  ( $s$  estratos)
 
$$\lambda_j(t) = \lambda_0(t) \exp\{\mathbf{x}'\boldsymbol{\beta}\}$$
  - √ Suposição:
    - Todos os estratos com os mesmos coeficientes de regressão
    - Risco basal varia para cada estrato
  - √ Verossimilhança individual calculada da nas mesma forma da verossimilhança parcial do modelo de Cox
    - Participam do conjunto sob risco apenas os indivíduos que pertençam ao mesmo estrato

Análise de Sobrevivência Aplicada à Saúde -- 2014

- ✓ Verossimilhança individual calculada da nas mesma forma da verossimilhança parcial do modelo de Cox
  - Participam do conjunto sob risco apenas os indivíduos que pertençam ao mesmo estrato

- ✓ Verossimilhança parcial total
  - Produto das verossimilhanças parciais para cada estrato

$$L(\beta) = \prod_{j=1}^s L_j(\beta)$$

- $L_j(\beta)$ : verossimilhança parcial do estrato j
  - Apenas observações dos indivíduos desse estrato

Análise de Sobrevivência Aplicada à Saúde -- 2014

### Exemplo

- Modelagem da sobrevivência dos pacientes
  - ✓ Consideração:
    - aparecimento de doença de enxerto crônica divide em estratos com linhas de base diferentes
  - ✓ Raciocínio:
    - Considerar que para que ocorra doença crônica, o paciente necessariamente sobreviveu algum tempo
    - (efeito da variável varia com o tempo)
  - ✓ Não é possível estimar o efeito para a variável que estratifica o risco

Análise de Sobrevivência Aplicada à Saúde -- 2014

### • Modelo incorpora o efeito da variável decr

```
> m4 <- coxph(Surv(os, status) ~ (idade + sexo + fase + deag +
+ decr), data = tmo, x = TRUE)
> summary(m4)

Call:
coxph(formula = Surv(os, status) ~ (idade + sexo + fase + deag +
+ decr), data = tmo, x = TRUE)

n = 96, number of events = 49

             coef exp(coef) se(coef)      z Pr(>|z|)
idade -0.005019  0.994993  0.014912 -0.337  0.736415
sexo2  -0.271984  0.761866  0.332115 -0.819  0.412816
fase2   0.593973  1.811171  0.371427  1.599  0.109784
fase3   0.938411  2.555918  0.522357  1.796  0.072416 .
deag1   1.190381  3.288332  0.327485  3.635  0.000278 ***
decr1  -1.061750  0.345890  0.338452 -3.137  0.001706 ***
---
Signif. codes:  0 '***' 0.001 '**' 0.01 '*' 0.05 '.' 0.1 ' ' 1

             exp(coef) exp(-coef) lower .95 upper .95
idade    0.9950    1.0050    0.9663    1.0245
sexo2    0.7619    1.3126    0.3974    1.4607
fase2    1.8112    0.5521    0.8746    3.7508
fase3    2.5559    0.3912    0.9152    7.1151
deag1    3.2883    0.3064    1.9028    5.4489
decr1    0.3459    2.8914    0.1782    0.6714

Concordance = 0.768 (se = 0.044 )
Rsquare = 0.345 (max possible = 0.986 )
Likelihood ratio test = 40.67 on 6 df, p=3.365e-07
Wald test = 38.46 on 6 df, p=9.113e-07
Score (logrank) test = 47.62 on 6 df, p=1.405e-08
```

Doença de efeito crônico exerce efeito protetor importante  
 • IC: [0,1782; 0,6714]  
 (não inclui o 1)

Análise de Sobrevivência Aplicada à Saúde -- 2014

### • Modelo estratificando a varável decr

```
> mstrata <- coxph(Surv(os, status) ~ (idade + sexo + fase + deag
+ strata(decr)),
+ data = tmo, x = TRUE)
> summary(mstrata)

Call:
coxph(formula = Surv(os, status) ~ (idade + sexo + fase + deag +
+ strata(decr)), data = tmo, x = TRUE)

n = 96, number of events = 49

             coef exp(coef) se(coef)      z Pr(>|z|)
idade -0.007951  0.992051  0.014666 -0.544  0.586309
sexo2  -0.270798  0.762771  0.328394 -0.825  0.409592
fase2   0.684868  1.985511  0.373774  1.832  0.068906 .
fase3   0.777338  2.175672  0.519240  1.497  0.134390 .
deag1   1.134616  3.109979  0.328494  3.454  0.000552 ***
---
Signif. codes:  0 '***' 0.001 '**' 0.01 '*' 0.05 '.' 0.1 ' ' 1

             exp(coef) exp(-coef) lower .95 upper .95
idade    0.9921    1.0080    0.9639    1.021
sexo2    0.7628    1.3110    0.4007    1.452
fase2    1.9835    0.5042    0.9534    4.127
fase3    2.1757    0.4596    0.7563    6.020
deag1    3.1100    0.3215    1.6936    5.921

Concordance = 0.676 (se = 0.064 )
Rsquare = 0.17 (max possible = 0.968 )
Likelihood ratio test = 17.88 on 5 df, p=0.003105
Wald test = 17.99 on 5 df, p=0.002955
Score (logrank) test = 19.36 on 5 df, p=0.001647
```

Efeitos estão controlados pela variação no risco de base atribuível aos estratos  
 • Controle efetuado por decr  
 Não foi estimado o coeficiente da variável decr  
 • Ajustados os efeitos das demais variáveis

Análise de Sobrevivência Aplicada à Saúde -- 2014

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

Variáveis	Modelos					
	m4			mstrata		
	exp(coef)	lower .95	upper .95	exp(coef)	lower .95	upper .95
Idade	0.9950	0.9663	1.0245	0.9921	0.9639	1.021
sexo2	0.7619	0.3974	1.4607	0.7628	0.4007	1.452
fase2	1.8112	0.8746	3.7508	1.9835	0.9534	4.127
fase3	2.5559	0.9182	7.1151	2.1757	0.7863	6.020
deag1	3.2883	1.7307	6.2479	3.1100	1.6336	5.921
decr1	0.3459	0.1782	0.6714			

√ Intervalos de confiança do modelo estratificado são ligeiramente maiores

Análise de Sobrevivência Aplicada à Saúde -- 2014

- Comentários
- √ Coeficientes estimados são semelhantes para os modelos m4 e mstrata
    - Em geral, os ICs em mstrata são ligeiramente maiores
  - √ Efeito é esperado pois o número de quantidades a serem estimados no modelo mstrata é maior
    - s riscos de base  $\lambda_{0s}(t)$  a serem estimados
    - É maior a incerteza dos coeficientes dos modelos
- Análise de Sobrevivência Aplicada à Saúde -- 2014

### Seleção de Modelos

- Teste de Wald
  - √  $H_0: \beta_j = 0$ 
    - Efeito da covariável é não significativo
  - √ Estatística de teste:
 
$$Z_j = \frac{\hat{\beta}_j}{\text{ep}(\hat{\beta}_j)}$$
  - √ Distribuição amostral
 
$$Z_j \stackrel{H_0}{\sim} N(0, 1)$$

Análise de Sobrevivência Aplicada à Saúde -- 2014

### Teste da Razão de Verossimilhança

- $H_0$ : não há diferença entre os modelos
  - √ (modelo maior = modelo menor)
- Estatística de teste:  $RV = 2(l_{\text{maior}} - l_{\text{menor}})$ 
  - √  $l_{\text{mod}} = \ln(L_{\text{mod}})$
- Distribuição amostral:  $RV \stackrel{H_0}{\sim} \chi_d^2$ 
  - √ d: diferença no número de covariáveis nos modelos em questão

Análise de Sobrevivência Aplicada à Saúde -- 2014

• Teste da razão de verossimilhança:

- √ Compara modelos aninhados
  - Modelo com maior número de parâmetros tem de conter todos os parâmetros do modelo menor
- √ Avalia se a inclusão de covariáveis no modelo aumenta significativamente a verossimilhança
- √ Assintoticamente semelhante ao teste de Wald
  - Mais robusto quando o número de observações é pequeno
- √ Modelos aninhados perdem comparabilidade caso existam valores ausentes

Análise de Sobrevivência Aplicada à Saúde -- 2014

√ Modelos estratificados e não estratificados não são aninhados

- Não podem ser comparados

√ Opção por modelos estratificados baseia-se em:

- Delineamento do estudo
- Conhecimento a priori do problema
- Avaliação do pressuposto de proporcionalidade

Análise de Sobrevivência Aplicada à Saúde -- 2014

• Demais modelos

√  $m2 = m1 + fase$

```
> # Demais modelos
>
> # m1 + fase
> m2 <- coxph(Surv(os, status)~(idade + sexo + fase),
+ data = tmo, x = TRUE)
> summary(m2)
Call:
coxph(formula = Surv(os, status) ~ (idade + sexo + fase), data = tmo,
      x = TRUE)

n = 96, number of events = 49

      coef exp(coef) se(coef)      z Pr(>|z|)
idade -0.02786  0.97252  0.01441 -1.933 0.053230 .
sexo2  -0.20776  0.81240  0.32428 -0.641 0.521742 .
fase2   0.86502  2.37505  0.34873  2.481 0.013119 *
fase3  1.89091  6.62539  0.48690  3.884 0.000103 ***
---
Signif. codes:  0 '***' 0.001 '**' 0.01 '*' 0.05 '.' 0.1 ' ' 1

      exp(coef) exp(-coef) lower .95 upper .95
idade  0.9725  1.0283  0.9454  1.000
sexo2  0.8124  1.2309  0.4303  1.554
fase2  2.3751  0.4210  1.1991  4.704
fase3  6.6254  0.1509  2.5513 17.205

Concordance= 0.649 (se = 0.044 )
Rsquare= 0.166 (max possible= 0.986 )
Likelihood ratio test= 17.41 on 4 df,  p=0.00161
Wald test            = 19.65 on 4 df,  p=0.0005853
Score (logrank) test = 23.12 on 4 df,  p=0.0001196
```

Análise de Sobrevivência Aplicada à Saúde -- 2014

√  $m3 = m2 + deag$

```
> # m2 + deag
> m3 <- coxph(Surv(os, status)~(idade + sexo + fase + deag),
+ data = tmo, x = TRUE)
> summary(m3)
Call:
coxph(formula = Surv(os, status) ~ (idade + sexo + fase + deag),
      data = tmo, x = TRUE)

n = 96, number of events = 49

      coef exp(coef) se(coef)      z Pr(>|z|)
idade -0.01877  0.98140  0.01429 -1.314 0.188888
sexo2  -0.24258  0.78460  0.31841 -0.762 0.446149
fase2   0.94870  2.58234  0.34103  2.782 0.005405 **
fase3  1.52206  4.58164  0.49600  3.069 0.002150 **
deag1  1.19600  3.11429  0.30972  3.668 0.000245 ***
---
Signif. codes:  0 '***' 0.001 '**' 0.01 '*' 0.05 '.' 0.1 ' ' 1

      exp(coef) exp(-coef) lower .95 upper .95
idade  0.9814  1.0190  0.9543  1.009
sexo2  0.7846  1.2745  0.4204  1.464
fase2  2.5823  0.3872  1.3235  5.038
fase3  4.5816  0.2183  1.7331 12.112
deag1  3.1143  0.3211  1.6972  5.715

Concordance= 0.72 (se = 0.044 )
Rsquare= 0.272 (max possible= 0.986 )
Likelihood ratio test= 30.52 on 5 df,  p=1.167e-05
Wald test            = 31.81 on 5 df,  p=6.491e-06
Score (logrank) test = 37.67 on 5 df,  p=4.405e-07
```

Análise de Sobrevivência Aplicada à Saúde -- 2014

• Comparação de modelos

√ Saída R:

```
> anova(m1, m2, m3, m4)
Analysis of Deviance Table
Cox model: response is Surv(os, status)
Model 1: ~ (idade + sexo)
Model 2: ~ (idade + sexo + fase)
Model 3: ~ (idade + sexo + fase + deag)
Model 4: ~ (idade + sexo + fase + deag + decr)
loglik   Chisq Df P(>|Chi|)
1 -201.94
2 -194.70 14.486 2 0.0007152
3 -188.15 13.109 1 0.0002939
4 -183.07 10.152 1 0.0014413
```

- 2ª. Linha:
- Comparação modelos 1 e 2
- 3ª. Linha
- Comparação modelos 2 e 3
- 4ª. Linha
- Comparação modelos 3 e 4

√  $H_0$ : igualdade entre modelos

- É rejeitada para cada nova covariável incluída
- Cada covariável incluída melhorou o ajuste

√ Saída R:

```
> anova(m1, m2, m3, m4)
Analysis of Deviance Table
Cox model: response is Surv(os, status)
Model 1: ~ (idade + sexo)
Model 2: ~ (idade + sexo + fase)
Model 3: ~ (idade + sexo + fase + deag)
Model 4: ~ (idade + sexo + fase + deag + decr)
loglik   Chisq Df P(>|Chi|)
1 -201.94
2 -194.70 14.486 2 0.0007152
3 -188.15 13.109 1 0.0002939
4 -183.07 10.152 1 0.0014413
```

$RV = 2[-194,70 - (-201,90)] = 14,40$

Variáveis incorporadas no modelo

**Qualidade de Ajuste**

- O modelo selecionado
  - √ se ajusta bem aos dados?
  - √ Qual o poder explicativo do modelo?

**Medida de Qualidade de Ajuste**

- Medida de qualidade de ajuste nos modelos lineares com resposta normal
  - √  $R^2$
- Avaliação global da qualidade de ajuste de um modelo de sobrevivência
  - √ Função desvio (ou *deviance*)
  - √ Método gráfico de sobrevivência por índice de prognóstico

### Variabilidade Total Explicada

- Proporção explicada pelas covariáveis
  - √ Modelo nulo: menor poder de explicação
    - Modelo sem covariáveis
    - Verossimilhança é apenas a linha de base
  - √ Modelo saturado: maior poder de explicação
    - Cada indivíduo está totalmente explicado (um coeficiente para cada indivíduo)
    - Modelo sem resíduos (saturado)
    - Não explica nem prediz coisa alguma

Análise de Sobrevida Aplicada à Saúde -- 2014

- Modelo nulo:

```
mod.nulo <- coxph(Surv(os, status)~1, data = tmo)
mod.nulo
Call: coxph(formula = Surv(os, status) ~ 1, data = tmo)

Null model
log likelihood= -203.404
n= 96
```

- Modelo saturado:

```
> mod.saturado <- coxph(Surv(os, status)~as.factor(id), data=tmo)
> summary(mod.saturado)
Call:
coxph(formula = Surv(os, status) ~ as.factor(id), data = tmo)

n= 96, number of events= 49
[...]
```

```
Concordance= 1 (se = 0.044 )
Rsquare= 0.985 (max possible= 0.986 )
Likelihood ratio test= 404 on 95 df, p=0
Wald test = 1826 on 95 df, p=0
Score (logrank) test = 394.1 on 95 df, p=0
```

Análise de Sobrevida Aplicada à Saúde -- 2014

- Verossimilhança dos modelos:

Modelo	$l_{\text{modelo}}$
Nulo	-203,40
Saturado	-1,39
m1: idade + sexo	-201,94
m2: m1 + fase	-194,70
m3: m2 + deag	-188,15
m4: m3 + decr	-183,07

```
> #Logverossimilhanças
> m1$loglik[1]
[1] -203.404
> mod.saturado$loglik[2]
[1] -1.386498
> m1$loglik[2]
[1] -201.9431
> m2$loglik[2]
[1] -194.7002
> m3$loglik[2]
[1] -188.1458
> m4$loglik[2]
[1] -183.0697
```

Análise de Sobrevida Aplicada à Saúde -- 2014

### Medida Global de Ajuste – $R^2$

- $R^2$ : poder explicativo das covariáveis no tempo de ocorrência do evento em estudo

$$R_{LR}^2 = 1 - \left\{ \frac{L(0)}{L(\hat{\beta})} \right\}^{\frac{2}{n}} = 1 - \exp \left( \frac{2\{l(0) - l(\hat{\beta})\}}{n} \right)$$

- $L(0)$ : verossimilhança do modelo nulo
- $L(\hat{\beta})$ : verossimilhança do modelo ajustado
- √ Valor mínimo possível  $L(0) = L(\hat{\beta})$
- √ Valor máximo não é 1 (100%)
  - É a razão entre as verossimilhanças dos modelos saturados e nulo

Análise de Sobrevida Aplicada à Saúde -- 2014

• Exemplo:

√ Modelo m1:

$$R_{LR}^2 = 1 - \exp\left(\frac{2\{l(0) - l(\hat{\beta})\}}{n}\right)$$

$$= 1 - \exp\left(\frac{2\{-201,94 - (-203,40)\}}{96}\right)$$

$$= 1 - \exp(-0,003042) = 0,0300$$

√ Porcentagem de explicação:

$$\% \text{ explicação} = \frac{R_{\text{modelo}}^2}{R_{\text{saturado}}^2} \times 100$$

$$= \frac{0,0300}{0,986} \times 100 = 2,958\%$$

Análise de Sobrevivência Aplicada à Saúde -- 2014

• Modelo m1 – saída R

```
> summary(m1)
Call:
coxph(formula = Surv(os, status) ~ (idade + sexo), data = tmo,
      x = TRUE)

n= 96, number of events= 49

      coef exp(coef) se(coef)      z Pr(>|z|)
idade -0.02167  0.97857  0.01399 -1.548  0.122
sexo2 -0.37649  0.68626  0.32120 -1.172  0.241

      exp(coef) exp(-coef) lower .95 upper .95
idade  0.9786   1.022   0.9521   1.006
sexo2  0.6863   1.457   0.3657   1.288

Concordance= 0.568 (se = 0.044 )
Rsquare= 0.03 (max possible= 0.986 )
Likelihood ratio test= 2.92 on 2 df, p=0.232
Wald test            = 2.85 on 2 df, p=0.2408
Score (logrank) test = 2.85 on 2 df, p=0.2406

> m1.res<-summary(m1)
> m1.res$rsq
      rsq   maxrsq
0.02997644 0.98555755
> m1.res$conf.int
      exp(coef) exp(-coef) lower .95 upper .95
idade 0.9785651  1.021904  0.9520904  1.005776
sexo2 0.6862628  1.457168  0.3656678  1.287936
> m1.res$loglik
[1] -203.4040 -201.9431
> m1.res$logtest
      test      df      pvalue
2.9217524  2.0000000  0.2320329
```

Análise de Sobrevivência Aplicada à Saúde -- 2014

• Verossimilhança dos modelos:

Modelo	$l_{\text{modelo}}$	$R^2$	Variabilidade Explicada (%)
Nulo	-203,40	0,000	0,0
Saturado	-1,39	0,986	100,0
m1: idade + sexo	-201,94	0,030	3,0
m2: m1 + fase	-194,70	0,166	16,8
m3: m2 + deag	-188,15	0,272	27,6
m4: m3 + decr	-183,07	0,345	35,0

$$\% \text{ explicação} = \frac{R_{\text{modelo}}^2}{R_{\text{saturado}}^2} \times 100$$

√ m4 é o melhor e explica 35% da variabilidade

Análise de Sobrevivência Aplicada à Saúde -- 2014

**Comentários**

- Em modelos de sobrevivência é raro encontrar poder explicativo muito maior
  - √ Tempos de sobrevivência têm grande variabilidade individual
  - √ Diferenças causadas por fatores incorporados ao modelo trazem informação importante em
    - Avaliação terapêutica
    - Fatores prognósticos
    - Fatores de risco ou proteção

Análise de Sobrevivência Aplicada à Saúde -- 2014

### Probabilidade de Concordância

- Medida global de ajuste útil quando o objetivo do estudo é obter modelo preditivo
  - √ Usada para avaliar o poder discriminatório e a acurácia preditiva do modelo de Cox
- Concordância:
  - √ Ao selecionar aleatoriamente duas observações, a que possui menor tempo de sobrevivência é também aquela que possui o maior risco estimado (predito) pelo modelo de Cox

Análise de Sobrevivência Aplicada à Saúde -- 2014

- Probabilidade de concordância estimada pelo modelo de Cox:
  - √ Entre 0,3 e 0,4:
    - Modelo possui baixo poder preditivo (ou discriminatório)
  - √ 0,5:
    - A concordância pode ter ocorrido por acaso
  - √ Entre 0,6 e 0,7:
    - Resultado comum em Análise de Sobrevivência
  - √ Entre 0,7 e 0,8:
    - Resultado discriminatório muito bom
  - √ Entre 0,8 e 0,9
    - Resultado discriminatório excelente

Análise de Sobrevivência Aplicada à Saúde -- 2014

### • Modelo m4

```
> m4 <- coxph(Surv(os, status)~(idade + sexo + fase + deag +
+ decr), data = tmo, x = TRUE)
> summary(m4)
Call:
coxph(formula = Surv(os, status) ~ (idade + sexo + fase + deag +
+ decr), data = tmo, x = TRUE)

n = 96, number of events = 49

      coef exp(coef)    se(coef)      z Pr(>|z|)
idade -0.005019  0.994993  0.014912 -0.337  0.736415
sexo2  -0.271984  0.761866  0.392115 -0.619  0.412816
fase2   0.593973  1.811171  0.371427  1.599  0.109784
fase3   0.938411  2.555918  0.522357  1.796  0.072416
deag1   1.190381  3.288332  0.327485  3.635  0.000278 ***
decr1  -1.061750  0.345850  0.338452 -3.137  0.001805 ***
---
Siggnif. codes:  0 '***' 0.001 '**' 0.01 '*' 0.05 '.' 0.1 ' ' 1

      concordant discordant tied.risk tied.time std(c-d)
2463.0000  742.0000  4.0000  2.0000  279.5721
(2463+4/2)/(2463+742+4)
[1] 0.7681521

      exp(coef) exp(-coef) lower .95 upper .95
idade  0.9950  1.0050  0.9663  1.0245
sexo2  0.7619  1.3126  0.3974  1.4607
fase2  1.8112  0.5521  0.8746  3.7508
fase3  2.5559  0.3912  0.9182  7.1151
deag1  3.2883  0.3041  1.7307  6.2479
decr1  0.3459  2.8914  0.1782  0.6714

summary(m4)$concordance
concordance.concordant      se.std(c-d)
0.76815207                  0.04356062

Concordance= 0.768 (se = 0.044 )
Nagkerke= 0.345 (max possible= 0.356 )
Likelihood ratio test= 40.67 on 6 df, p=3.365e-07
Wald test = 38.46 on 6 df, p=9.113e-07
Score (logrank) test = 47.62 on 6 df, p=1.405e-08
```

• Comando no R:  
*survConcordance ( )*

Análise de Sobrevivência Aplicada à Saúde -- 2014

### • Exemplo:

Modelo	$l_{\text{modelo}}$	$R^2$	Variabilidade Explicada (%)	Probabilidade de Concordância
Nulo	-203,40	0,000	0,0	
Saturado	-1,39	0,986	100,0	1
m1: idade + sexo	-201,94	0,030	3,0	0,568
m2: m1 + fase	-194,70	0,166	16,8	0,650
m3: m2 + deag	-188,15	0,272	27,6	0,722
m4: m3 + deag	-183,07	0,345	35,0	0,768

√ Poder preditivo (ou discriminatório) do modelo m4 é muito bom

Análise de Sobrevivência Aplicada à Saúde -- 2014

### Índice Prognóstico – IP

- Gráfico de sobrevivência estratificado por IP
  - √ Procedimento exploratório útil para avaliar qualidade de ajuste do modelo
  - √ IP: preditor linear do modelo de Cox ( $x' \hat{\beta}$ )
  - √ Cálculo do IP para cada indivíduo

Análise de Sobrevivência Aplicada à Saúde -- 2014

- Cálculo de índice prognóstico
  - √ Modelo m4

Covariável	$\beta$	Indivíduo A		Indivíduo B	
		$x_A$	$\beta x_A$	$x_B$	$\beta x_B$
idade	-0,005019	56	-0,281064	20	-0,100380
sexo2	-0,271984	0	0	1	-0,271984
fase2	0,593973	1	0,593973	0	0
fase3	0,938411	0	0	1	0,938411
deag	1,190381	1	1,190381	1	1,190381
decr	-1,061750	0	0	0	0
Índice de Prognóstico			1,50329		1,756428

- Indivíduo A: sexo masculino, fase intermediária
- Indivíduo B: sexo feminino, fase avançada
- Manifestação doença de enxerto: deag = 1, decr = 0

Análise de Sobrevivência Aplicada à Saúde -- 2014

- Construção do gráfico:
  - √ Indivíduos são estratificados em grupos de tamanhos aproximadamente iguais
    - Grupos de alto, médio e baixo IP
  - √ Determinação dos valores médios de cada uma das covariáveis dentro de cada grupo
  - √ Obtenção das curvas de sobrevivência sob o modelo ajustado utilizando os valores médios
  - √ Curvas são comparadas às curvas de sobrevivência estimadas por K-M para cada grupo
  - √ Se o modelo for razoável:
    - Curvas ajustadas sejam próximas das curvas K-M, por estrato

Análise de Sobrevivência Aplicada à Saúde -- 2014

- √ Espera-se que os melhores modelos sejam mais capazes de diferenciar os grupos criados pelo valor do índice prognóstico

Análise de Sobrevivência Aplicada à Saúde -- 2014

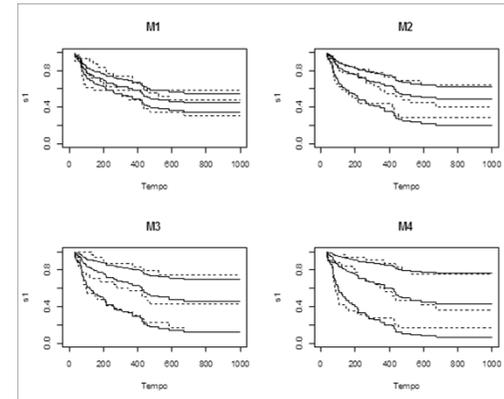
√ Estratificação por índice de prognóstico – Comandos

```
> source("funcoes/Rfun.r")
-----
Funcoes do livro
Análise de Sobrevida: Teoria e Aplicacoes em Saude
Ultima atualizacao: Julho de 2011
-----

Funcoes disponiveis: plot.pi(), plot.frail()
Funcao para estimar quantis do tempo de sobrevida,
desenvolvida pelo Prof. John Fox
> par(mfrow = c(2,2))
> plot.pi(m1, main = "M1", xlab = "Tempo")
The solid line is the fitted model, the dashed one is the K-M
> plot.pi(m2, main = "M2", xlab = "Tempo")
The solid line is the fitted model, the dashed one is the K-M
> plot.pi(m3, main = "M3", xlab = "Tempo")
The solid line is the fitted model, the dashed one is the K-M
> plot.pi(m4, main = "M4", xlab = "Tempo")
The solid line is the fitted model, the dashed one is the K-M
> par(mfrow = c(1,1))

Análise de Sobrevida Aplicada à Saúde -- 2014
```

√ Gráficos estratificados por índice de prognóstico



√ Apenas m1 apresenta-se mal ajustado

Análise de Sobrevida Aplicada à Saúde -- 2014

- Modelos m2, m3 e m4 são mais capazes de discriminar os grupos
  - √ Ajustam-se razoavelmente bem
  - √ Melhoram a cada nova variável incluída
  - √ % variabilidade explicada
    - 16,8% → 27,6% → 35,0%

Análise de Sobrevida Aplicada à Saúde -- 2014

**Função Desvio**

- √  $H_0$ : modelo se ajusta aos dados
- √ Estatística de teste:  $D = 2(l_{\text{saturado}} - l_{\text{modelo}})$ 
  - $l_{\text{saturado}}$ : logverossimilhança do modelo saturado
  - $l_{\text{modelo}}$ : logverossimilhança do modelo
- √ Modelo saturado:
  - Ajustados  $n$  parâmetros para  $n$  observações
- √ Distribuição amostral  $D \stackrel{H_0}{\sim} \chi_{n-p-1}^2$ 
  - Quanto melhor a qualidade, menor a estatística e maior o p-valor

Análise de Sobrevida Aplicada à Saúde -- 2014

• Cálculo da deviance:

- √ Os parâmetros de perturbação são mantidos fixos em ambos os modelos
  - Parâmetros comuns aos dois ajustes e nos quais não há interesse no estimador

Análise de Sobrevida Aplicada à Saúde -- 2014

• Função desvio dos modelos:

Modelo	$l_{\text{modelo}}$	D	GL	P-valor
Nulo	-203,40	404,02		
Saturado	-1,39	0		
m1: idade + sexo	-201,94	401,10	93	0
m2: m1 + fase	-194,70	386,62	91	0
m3: m2 + deag	-188,15	373,52	90	0
m4: m3 + decr	-183,07	363,36	89	0

- √ Rejeita-se a hipótese de que o modelo se ajusta aos dados
  - Teste assintótico

Análise de Sobrevida Aplicada à Saúde -- 2014

**Análise de Resíduos**

**Análise de Resíduos**

- Premissas e ajuste de modelo quanto à
  - √ Proporcionalidade do risco
  - √ Observações mal ajustadas pelo modelo
    - Pontos aberrantes e influentes
- Tipos de resíduos
  - √ Schoenfeld
  - √ Martingale
  - √ Deviance
  - √ Escore

Análise de Sobrevida Aplicada à Saúde -- 2014

### Introdução

- Proporcionalidade:
  - √ A relação entre a variável resposta e tempo é sempre a mesma, independente do momento de ocorrência do evento
- Linearidade (log-linearidade)  $\lambda(t) = \lambda_0(t)e^{\mathbf{x}'\beta}$ 
  - √ A razão de riscos entre um indivíduo de 45 anos e um de 50 anos é idêntica àquela entre um indivíduo de 80 anos e um de 85 anos
- O modelo estima efeito médio de covariáveis:
  - √ Pontos influentes podem afetar estimativa fortemente

Análise de Sobrevivência Aplicada à Saúde -- 2014

- O resíduo obtido como resposta observada menos a esperada não pode ser usado para os dados de sobrevivência:

√ Há censura.

Análise de Sobrevivência Aplicada à Saúde -- 2014

### Riscos Proporcionais - Schoenfeld

- O efeito de uma variável é sempre o mesmo durante todo o tempo observado?
- Resíduo de Schoenfeld:
  - √ Um vetor de resíduos para cada covariável do modelo
  - √ Resíduos são definidos somente nos tempos de ocorrência do evento.

Análise de Sobrevivência Aplicada à Saúde -- 2014

- Para cada covariável  $x_i$  no tempo do evento  $t_i$ :

$$r_{ik} = \delta_i(x_{ik} - a_{ik})$$

$$a_{ik} = \frac{\sum_{j \in R(t_i)} x_{jk} \exp(\mathbf{x}'_j \hat{\beta})}{\sum_{j \in R(t_i)} \exp(\mathbf{x}'_j \hat{\beta})}$$

Resíduo é nulo quando ocorre censura

- √  $\delta_i$ : indicador de censura
- √  $R(t_i)$ : conjunto dos indivíduos em risco no tempo  $t_i$
- √  $x_{jk}$ : valor da covariável  $k$  do indivíduo  $j$  pertencente ao grupo de risco
- √  $a_{ik}$ : média ponderada dos valores das covariáveis dos indivíduos em risco no tempo  $t_i$ .

Análise de Sobrevivência Aplicada à Saúde -- 2014

• Resíduos de Schoenfeld:

√ Diferença entre os valores observados de covariáveis de um indivíduo com tempo de desfecho  $t_i$  e os valores esperados em  $t_i$  dado o grupo em risco  $R(t_i)$ .

√ Peso do indivíduo  $j$  que pertence a  $R(t_i)$ :

$$\frac{\exp\{\mathbf{x}'_j \hat{\beta}\}}{\sum_{j \in R(t_i)} \exp\{\mathbf{x}'_j \hat{\beta}\}}$$

Análise de Sobrevida Aplicada à Saúde -- 2014

• Supor que coeficiente  $\beta_k$  varia com o tempo.  $\beta_k$  pode ser dividido em duas partes:

√ Média constante no tempo –  $E[r_i(\beta_k) | R(t_i)]$ , com variância  $V(\beta_k)$

√ Função  $U(t)$

√ O resíduo padronizado de Schoenfeld em  $t_i$  pode ser obtido por:

$$r_i^*(\beta_k) = \frac{r_i(\beta_k)}{V(\beta_k)}$$

√ Se a premissa de proporcionalidade não é violada esperamos que o gráfico de  $r_i^*(t_j)$  vs.  $(t_j)$  apresente uma reta com inclinação zero

Análise de Sobrevida Aplicada à Saúde -- 2014

• Resíduos padronizados de Schoenfeld vs. Tempo

√ Verificação se distribuídos igualmente no tempo

√ Não deverá existir tendência sistemática se suposição de riscos proporcionais estiver satisfeita

√ Forma da dispersão dos resíduos pode sugerir transformações para obtenção de proporcionalidade

– Pode-se investigar distribuição gráfica dos resíduos contra alguma função do tempo

Análise de Sobrevida Aplicada à Saúde -- 2014

**Schoenfeld no R**

• `> residuo <- cox.zph(modelo)`

• `> plot(residuo[1])`

• Observar a escala do tempo:

√ Kaplan-Meier – nos tempos de falha

√ Calendário

– bom quando ajuste utiliza processo de contagem

– pode ficar pouco visível se concentra grande quantidade de eventos em um mesmo momento

√ Rank (ordem dos eventos):

– útil quando os tempos são muito dispersos

• Suavização por *spline*

• Resíduo não padronizado no R:

√ `residuals(modelo, "schoenfeld")`

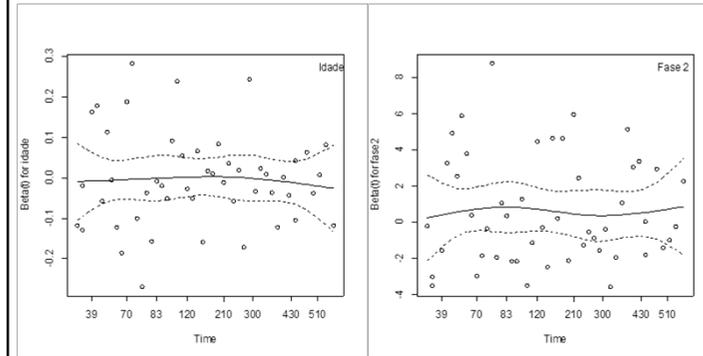
Análise de Sobrevida Aplicada à Saúde -- 2014

### Exemplo

- Sobrevivência de pacientes a transplante:
  - √ Modelo m4
  - √ Análise dos resíduos de Schoenfeld
    - Se a premissa de riscos proporcionais não é violada então espera-se que reta esteja dentro dos intervalos de confiança
    - Suavização:

Análise de Sobrevivência Aplicada à Saúde -- 2014

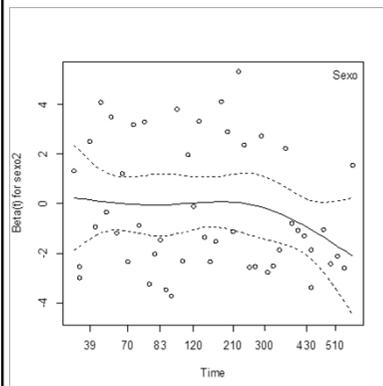
- Idade e fase intermediária da doença:



√ Proporcionais ao longo do tempo

Análise de Sobrevivência Aplicada à Saúde -- 2014

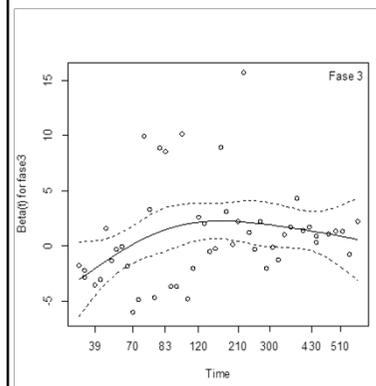
- Sexo



- √ Efeito no final do período de observação parece ser diferente do início
- √ Pode ser considerado proporcional, pois são poucas observações

Análise de Sobrevivência Aplicada à Saúde -- 2014

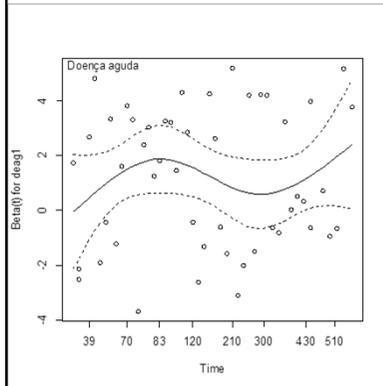
- Fase adiantada da doença



- √ Varia no tempo, embora não muito
- √ Pode ser atribuída à flutuação aleatória (nove pessoas)

Análise de Sobrevivência Aplicada à Saúde -- 2014

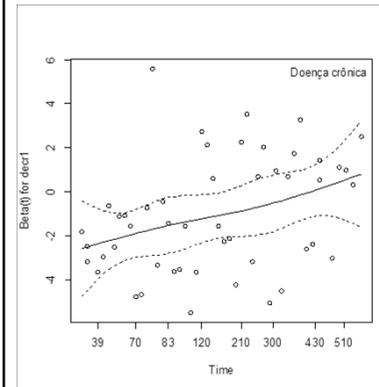
• Doença do enxerto aguda:



- √ Comportamento aleatório
- √ Banda de confiança sempre incluem o valor do parâmetro estimado

Análise de Sobrevivência Aplicada à Saúde -- 2014

• Doença do enxerto crônica:



- √ Tendência visível
- √ Resíduos aumentam de forma consistente com o tempo
- √ Deve-se valorizar mais este tipo de tendência na análise de resíduos do que flutuações em torno de zero
- √ Variável decr não deve entrar diretamente no modelo

Análise de Sobrevivência Aplicada à Saúde -- 2014

### Correlação Linear com o Tempo

- Teste da presença de correlação linear entre tempo de sobrevivência e resíduo

$$\beta_k(t) = \beta_k + \theta_k U_k(t)$$

- $\theta_k$ : parâmetro de variação no tempo
- √  $H_0$ : inclinação igual a zero ( $\theta_k = 0$ )
- O mesmo que  $\ln(\text{risco relativo})$  é constante no tempo

Análise de Sobrevivência Aplicada à Saúde -- 2014

• Saída no R:

```
> residuo <- cox.zph(m4)
> residuo
      rho  chisq  p
idade -0.02226 2.92e-02 0.86439
sexo2 -0.18004 1.86e+00 0.17207
fase2 -0.00212 2.81e-04 0.98663
fase3  0.20766 2.91e+00 0.08810
deag1  0.05110 1.52e-01 0.69706
decr1  0.35133 7.22e+00 0.00719
GLOBAL NA 1.35e+01 0.03622
```

- √ Rejeição de  $H_0$  (riscos são proporcionais):
  - Doença de enxerto crônica
  - (Efeito da covariável parece ter tendência crescente no tempo)
  - Proporcionalidade global do modelo
  - (rejeita hipótese de proporcionalidade de todas as covariáveis)

Análise de Sobrevivência Aplicada à Saúde -- 2014

### Comentários

- Doença crônica relacionada ao enxerto deve aumentar à medida que o tempo passa
  - √ Em geral, quando proporcionalidade é rejeitada, a covariável tem forte componente temporal.
  - √ Doença tardia (ou crônica) está relacionada ao tempo
- Covariável que seja de alguma forma temporal terá comportamento tempo-dependente
  - √ Riscos não proporcionais
  - √ Ex.: número de dias internado em UTI (gravidade)

Análise de Sobrevida Aplicada à Saúde -- 2014

### Tratamento da Não Proporcionalidade

- Que fazer quando os riscos são não proporcionais?
  - √ Magnitude:
    - Não proporcionalidade é realmente importante?
    - Variação de  $b_k(t)$  pode ser pequena em relação a  $b_k$
  - √ Pontos influentes
    - Não proporcionalidade é real?
    - Pontos outliers podem influenciar significância do teste

Análise de Sobrevida Aplicada à Saúde -- 2014

- Em caso de problema de proporcionalidade:
  - √ Estratificar pela covariável tempo-dependente
    - Avaliar magnitude e pontos influentes
  - √ Particionar o eixo do tempo
    - Analisar separadamente cada trecho em que há proporcionalidade
    - Para ajustar o modelo a um trecho, censura-se todo o tempo dos outros trechos
  - √ Outro tipo de modelo
    - Modelo de tempo de vida acelerado

Análise de Sobrevida Aplicada à Saúde -- 2014

- Doença crônica é definida como a que ocorre a partir de 100 dias:
  - √ Analisar dois blocos:
    - Tempo de sobrevivência até 100 dias
    - Tempo de sobrevivência maior ou igual a 100 dias
  - √ Comandos em R:
    - Criação de novo status dos pacientes, no qual os eventos sejam censurados conforme o período de ocorrência

```
> # Tratamento da não proporcionalidade
>
> tmo$statusaguda <- ifelse(tmo$os < 100, tmo$status, 0)
> tmo$statuscronica <- ifelse(tmo$os >= 100, tmo$status, 0)
>
> m4.cronica <- coxph(formula = Surv(os, statuscronica) ~ idade + sexo +
+ fase + deag + decr, data = tmo, x = T)
>
> m4.aguda <- coxph(formula = Surv(os, statusaguda) ~ idade + sexo +
+ fase + deag + decr, data = tmo, x = T)
```

Análise de Sobrevida Aplicada à Saúde -- 2014

### √ Tempo de sobrevivência < 100 dias

```

> summary(m4.aguda)
Call:
coxph(formula = Surv(os, statusaguda) ~ idade + sexo + fase +
      deag + decr, data = tmo, x = T)
n= 96, number of events= 19

              rho      chisq      p
idade -0.0797  0.1909  0.662
sexo2  -0.2374  1.3514  0.245
fase2  -0.0381  0.0412  0.839
fase3   0.2451  1.3135  0.252
deag1   0.3164  2.5002  0.114
decr1   0.1785  0.7161  0.397
GLOBAL    NA  8.2433  0.221

> residuo.aguda <- cox.zph(m4.aguda)
> residuo.aguda
              rho      chisq      p
idade -0.0797  0.1909  0.662
sexo2  -0.2374  1.3514  0.245
fase2  -0.0381  0.0412  0.839
fase3   0.2451  1.3135  0.252
deag1   0.3164  2.5002  0.114
decr1   0.1785  0.7161  0.397
GLOBAL    NA  8.2433  0.221

Signif. codes:  0 '***' 0.001 '**' 0.01 '*' 0.05 '.' 0.1 ' ' 1

exp(coef) exp(-coef) lower .95 upper .95
idade  0.97837  1.0221  0.935857  1.0228
sexo2  0.79391  1.2596  0.284841  2.2128
fase2  1.94535  0.5140  0.629997  6.0070
fase3  1.14842  0.8708  0.288565  4.5704
deag1  3.02186  0.3309  1.025761  8.9023
decr1  0.05423  18.4402  0.007048  0.4172
Concordance= 0.843 (se = 0.067 )
Rsquare= 0.289 (max possible= 0.828 )
Likelihood ratio test= 32.72 on 6 df,  p=1.187e-05
Wald test = 16.6 on 6 df,  p=0.01088
Score (logrank) test = 29.96 on 6 df,  p=3.999e-05
    
```

Análise de Sobrevivência Aplicada à Saúde -- 2014

### √ Tempo de sobrevivência ≥ 100 dias

```

> summary(m4.cronica)
Call:
coxph(formula = Surv(os, statuscronica) ~ idade + sexo + fase +
      deag + decr, data = tmo, x = T)
n= 96, number of events= 30

              rho      chisq      p
idade  0.0001514  1.0001514  0.0212918  0.007  0.99433
sexo2 -0.2653976  0.7669010  0.4203029 -0.631  0.52775
fase2  0.6364085  1.8896819  0.4983644  1.277  0.20160
fase3  2.3998012  11.0209857  0.7808279  3.073  0.00212 **
deag1  1.0974076  2.9963880  0.4000078  2.743  0.00608 **
decr1 -0.4915840  0.6116568  0.4417682 -1.113  0.26581

Signif. codes:  0 '***' 0.001 '**' 0.01 '*' 0.05 '.' 0.1 ' ' 1

exp(coef) exp(-coef) lower .95 upper .95
idade  1.0002  0.99985  0.9593  1.043
sexo2  0.7669  1.30395  0.3365  1.748
fase2  1.8897  0.52919  0.7115  5.019
fase3  11.0210  0.09074  2.3855  50.917
deag1  2.9964  0.33374  1.3681  6.563
decr1  0.6117  1.63490  0.2573  1.454
Concordance= 0.709 (se = 0.055 )
Rsquare= 0.196 (max possible= 0.916 )
Likelihood ratio test= 20.98 on 6 df,  p=0.001851
Wald test = 25.92 on 6 df,  p=0.00023
Score (logrank) test = 38.11 on 6 df,  p=1.071e-06

> residuo.cronica <- cox.zph(m4.cronica)
> residuo.cronica
              rho      chisq      p
idade -0.2631  2.4438  0.1180
sexo2 -0.4107  5.4823  0.0192
fase2  0.0869  0.2906  0.5899
fase3  0.1547  0.9676  0.3253
deag1  0.0428  0.0601  0.8063
decr1  0.2616  3.0390  0.0813
GLOBAL    NA  8.5536  0.2003
    
```

Análise de Sobrevivência Aplicada à Saúde -- 2014

### √ Estimativas dos modelos com tempos particionado

Variável	Razão de Riscos		Res. Schoenfeld (p-valor)	
	< 100 dias	≥ 100 dias	GL	P-valor
idade	0,98	1,00	0,662	0,1180
sexo2	0,79	0,77	0,245	0,0192
fase2	1,94	1,89	0,839	0,5899
fase3	1,15	<b>11,02</b>	0,252	0,3253
deag1	<b>3,02</b>	<b>3,00</b>	0,114	0,8063
decr1	<b>0,05</b>	0,61	0,397	0,0813

- Significativo ao nível de significância de 5% (negrito)
- Significância é menor pois número de eventos se altera
- Variáveis problemáticas apresentam efeitos aumentado e deixam de ser tempo-dependentes

Análise de Sobrevivência Aplicada à Saúde -- 2014

- Tempo particionado – Resíduos de Schoenfeld

### √ Tempo de sobrevivência < 100

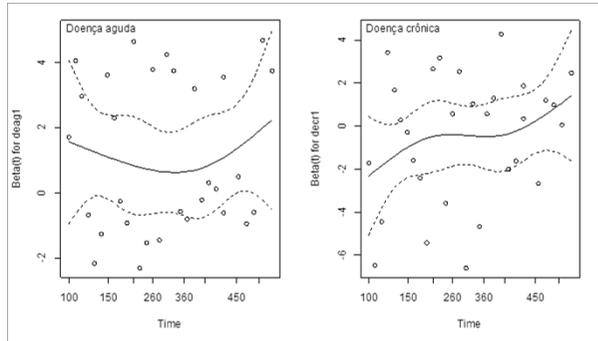
Doença aguda

Doença crônica

√ Gráficos indicam melhor ajuste

Análise de Sobrevivência Aplicada à Saúde -- 2014

- Tempo particionado – Resíduos de Schoenfeld
  - √ Tempo de sobrevivência  $\geq 100$



√ Gráficos indicam melhor ajuste

Análise de Sobrevivência Aplicada à Saúde -- 2014

## Resíduos Martingale

- Baseados no processo de contagem individual

$$M_i = N_i - E_i$$

√  $N_i$ : número de eventos observados no intervalo  $[0, \infty)$

√  $E_i$ : número de eventos esperados no intervalo  $[0, \infty)$

- Estimativa do resíduo martingale:

$$\hat{M}_i = \delta_i - \hat{\Lambda}_0(t_i) \exp\{\mathbf{x}_i \hat{\boldsymbol{\beta}}\} = \delta_i - r_{Ci}$$

√  $r_{Ci}$ : resíduo de Cox-Snell

Análise de Sobrevivência Aplicada à Saúde -- 2014

- Semelhanças com os resíduos de modelos lineares

√ Valor esperado de  $M_i$  é zero

– em torno do verdadeiro (e desconhecido)  $\beta$

√  $M_i$  são simetricamente distribuídos em torno de zero

– Variam de  $(-\infty, 1]$

– É negativo quando o tempo de sobrevivência é censurado

√ Soma dos resíduos observados é zero

– Baseados no valor estimado de  $\beta$

√  $M_i$  são não correlacionados

– Quando calculados com o verdadeiro vetor de parâmetros  $\beta$

√ Estimativas de  $M_i$  são negativamente correlacionadas, ainda que fracamente

Análise de Sobrevivência Aplicada à Saúde -- 2014

- Diferenças com os resíduos de modelos lineares

√ A soma dos quadrados dos resíduos não auxilia na avaliação global do modelo

– O melhor modelo de Cox não tem a menor soma de quadrados de resíduos martingale

√ A distribuição dos resíduos não é aproximadamente normal, nem log-normal

– Qq-plot não funciona

√ Gráfico dos resíduos vs. valores ajustados não funciona

– Resíduos tem correlação negativa com valores ajustados

Análise de Sobrevivência Aplicada à Saúde -- 2014

- Resíduos de Martingale são úteis na avaliação de:
- Pontos aberrantes:
  - √  $M_i$  vs. índice do indivíduo
    - $M_i > 0$ : → observados < esperados → modelo superestima
    - $M_i < 0$ : → observados > esperados → modelo subestima
- Forma funcional de variável contínua
  - √  $M_i$  do modelo nulo vs. covariável, com superposição de curva suavizada
    - Se curva suavizada for linear → forma funcional está correta
    - Se curva suavizada não for linear → indica necessidade de transformação da

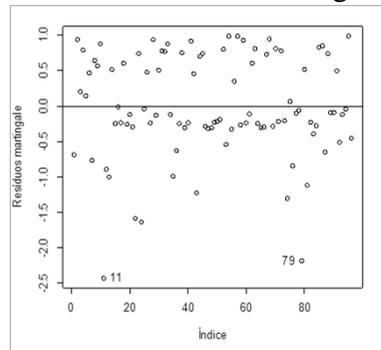
Análise de Sobrevivência Aplicada à Saúde -- 2014

- Pontos aberrantes:
  - √  $M_i$  vs. índice do indivíduo
    - $M_i > 0$ : → observados < esperados → modelo superestima
    - $M_i < 0$ : → observados > esperados → modelo subestima
- √ Comandos em R:

```
> # Pontos aberrantes
> res.mart <- resid(m4, type = "martingale")
> plot(res.mart)
> abline(h = 0)
```

Análise de Sobrevivência Aplicada à Saúde -- 2014

- Modelo m4 – Resíduos de Martingale

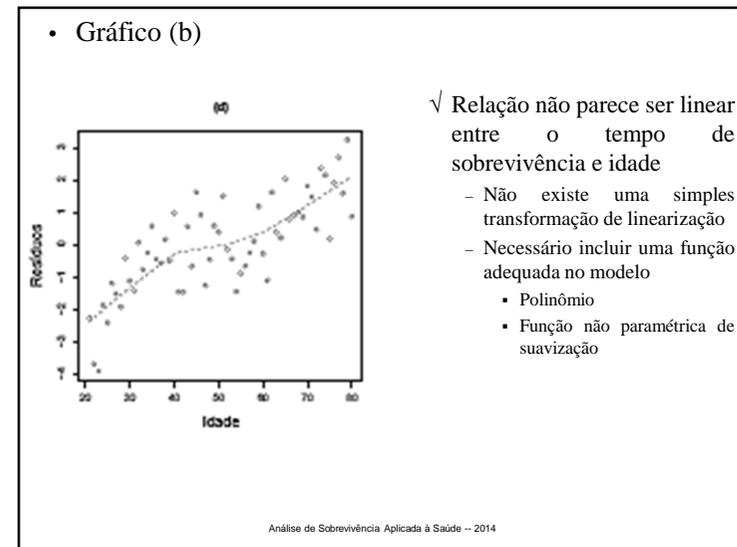
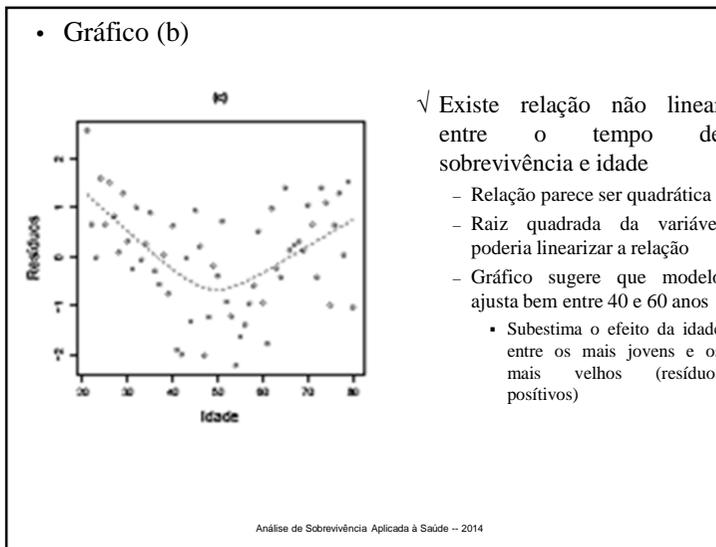
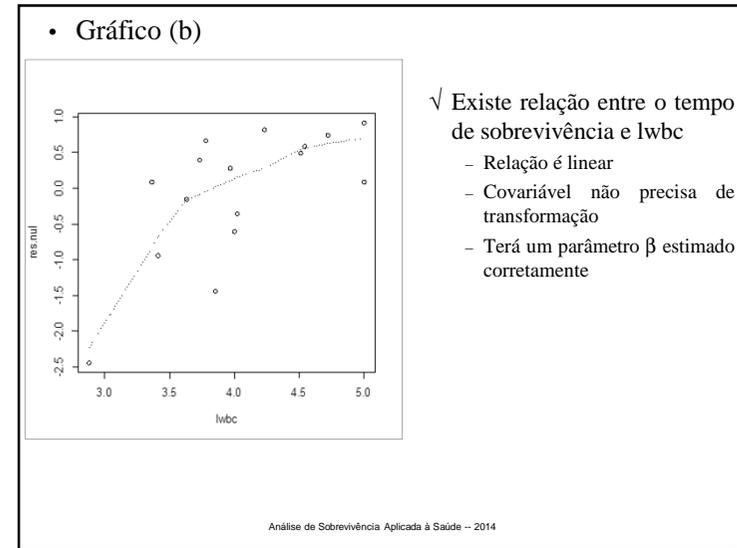
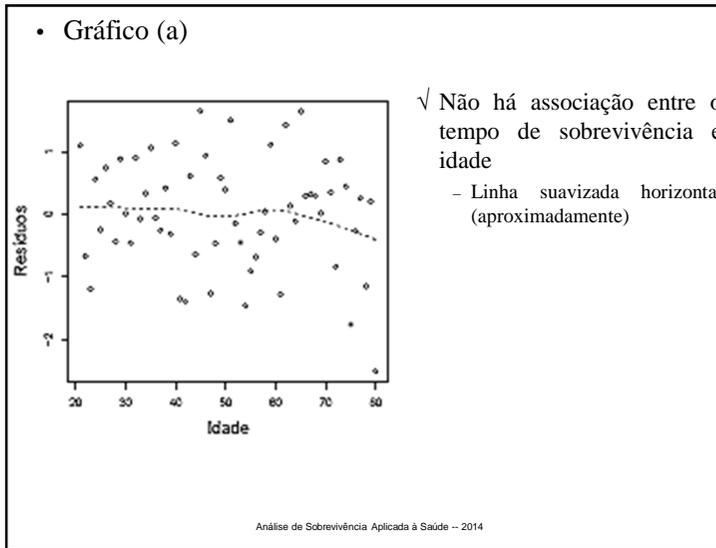


- √ Identificados indivíduos 11 e 79 (resíduos negativos)
  - Valores < -2
  - Valor máximo do resíduo martingale é 1

Análise de Sobrevivência Aplicada à Saúde -- 2014

- Forma funcional de variável contínua
  - √  $M_i$  do modelo nulo vs. covariável, com superposição de curva suavizada
    - Se curva suavizada for linear → forma funcional está correta
    - Se curva suavizada não for linear → indica necessidade de transformação da especificação da relação

Análise de Sobrevivência Aplicada à Saúde -- 2014



### Exemplo

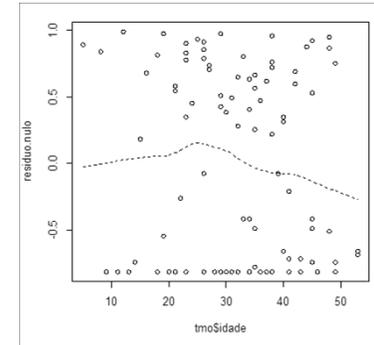
- Sobrevivência de pacientes a transplante:
  - √ Modelo m4
  - √ Objetivo: Avaliação da forma funcional da covariável idade
    - Resíduo martingale do modelo nulo vs. Idade

#### √ Comandos em R:

```
> # Forma funcional
> mod.nulo <- coxph(Surv(os, status)~1, data = tmo)
> residuo.nulo <- resid(mod.nulo, type = "martingale")
> plot(tmo$idade, residuo.nulo)
> lines(lowess(tmo$idade, residuo.nulo, iter = 0), lty = 2) # não eliminar outliers
> # iter = 0
> lines(lowess(tmo$idade, residuo.nulo), lty = 3)
> legend(x = "bottom", legend = c("Com outlier", "Sem outlier"), lty = 2:3)
```

Análise de Sobrevivência Aplicada à Saúde -- 2014

- Avaliação forma funcional – exemplo transplante
  - √ Idade contra resíduos martingale do modelo nulo



- Gráfico sugere efeito não linear:
  - Resíduos negativos a partir de aproximadamente 30 anos

Análise de Sobrevivência Aplicada à Saúde -- 2014

### Resíduos Deviance

$$D_i = \text{sinal}(\hat{M}_i) \sqrt{-2 \times (l_{i(\text{modelo})} - l_{i(\text{saturado})})}$$

- √ Resíduos com interpretação mais fácil
  - São simetricamente distribuídos em torno de zero
- √ A soma não é necessariamente zero
- √ São úteis na detecção de pontos aberrantes
  - Sem muita censura, os resíduos parecerão uma amostra aleatória normal
- √ A função desvio pode ser obtida através da soma dos quadrados dos resíduos deviance

Análise de Sobrevivência Aplicada à Saúde -- 2014

- Gráficos dos resíduos deviance:
  - √ Resíduos vs. cada observação
  - √ Resíduos vs. preditos do modelo
  - √ Resíduos vs. Gráfico quantil-quantil

Análise de Sobrevivência Aplicada à Saúde -- 2014

### Exemplo

- Sobrevivência de pacientes a transplante:
  - √ Modelo m4
  - √ Objetivo: Análise de pontos aberrantes
    - Comparação entre resíduos Martingale e Deviance
    - Gráficos: resíduos x valores preditos e qq-plot dos resíduos

Análise de Sobrevivência Aplicada à Saúde -- 2014

### √ Gráficos dos resíduos martingale e deviance:

- Comparação da identificação de indivíduos mal ajustados pelo modelo m4
- Comandos em R:

```
> windows(width=9.6, height=6)
> par(mfrow = c(1, 2))

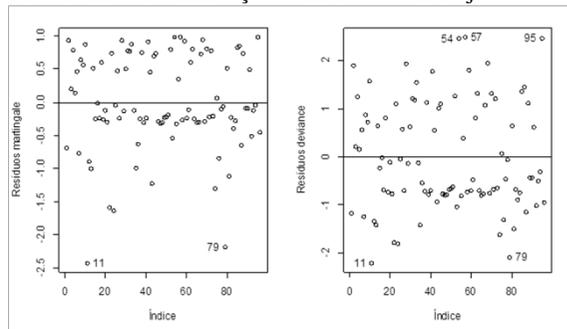
> # resíduos martingale
> res.mart <- resid(m4, type = "martingale")
> rotulo.x = "Resíduos martingale"
> rotulo.y = "Índice"
> plot(res.mart, xlab = rotulo.x, ylab = rotulo.y)
> abline(h = 0)
> indice <- 1:length(res.mart)
> idx.mart<-identify(x = indice, y = res.mart, n = 5, tolerance = 0.25)

> # resíduos vs. indice
> res.dev <- resid(m4, type = "deviance")
> rotulo.x = "Resíduos deviance"
> rotulo.y = "Índice"
> plot(indice,res.dev, xlab = rotulo.x, ylab = rotulo.y)
> abline(h = 0)
> indice <- 1:length(res.dev)
> idx.dev<-identify(x = indice, y = res.dev, n = 5, tolerance = 0.25)
```

Análise de Sobrevivência Aplicada à Saúde -- 2014

### √ Pontos Aberrantes: martingale vs. deviance

- Modelo m4 – Identificação de indivíduos mal ajustados



- Resíduo deviance detecta indivíduos com grande valor positivo
  - Não foi possível com o resíduo martingale

Análise de Sobrevivência Aplicada à Saúde -- 2014

### √ Outros gráficos dos resíduos deviance:

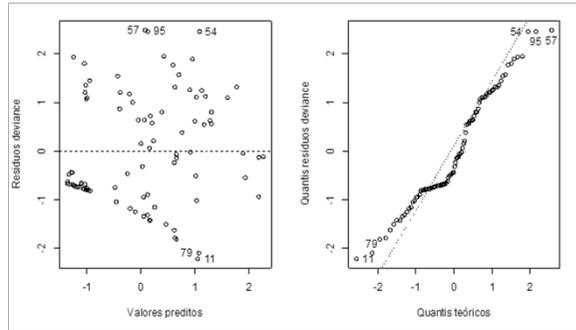
- Resíduos x preditos e qq-plot
- Comandos em R:

```
> # resíduos vs. predito
> plot(predict(m4), res.dev)
> abline(h = 0, lty = 2, lwd = 0.5)
> idx.pred <- identify( x = predict(m4), y = res.dev, n = 5, tolerance = 0.25)

> # qq-plot
> graf.qq <- qqnorm(res.dev, xlab = "Quantis teóricos",
+ ylab = "Quantis resíduos deviance")
> qqline(res.dev, lty = 3)
> idx.qq <- identify(x = graf.qq$x, y = graf.qq$y, n = 5, tolerance = 0.25)
```

Análise de Sobrevivência Aplicada à Saúde -- 2014

√ Resíduos deviance – Gráficos preditos e qq-plot



- Utilizado gráfico qq-plot (não há muita censura)
- Gráficos confirmam identificação dos indivíduos

Análise de Sobrevivência Aplicada à Saúde -- 2014

√ Indivíduos identificados como mal ajustados:

```
> idx<-as.numeric(levels(as.factor(c(idx.mart, idx.dev, idx.pred, idx.qq))))
> idx
[1] 11 54 57 79 95
> tmo[idx,c("os", "status", "sexo", "idade", "deag", "decr", "fase")]
  os status sexo idade deag decr fase
11 1000    0    2   18    1    0    1
54  31    1    2   12    1    0    1
57  32    1    1   29    0    0    1
79 531    0    2   14    1    0    1
95  32    1    1   19    0    0    1
```

- Indivíduos 11 e 79 (resíduos negativos)
  - Têm a doença de enxerto aguda e censura com tempo longo
- Indivíduos 54, 57 e 95 (resíduos positivos)
  - Morreram em tempos muito curtos
  - Indivíduos 57 e 95 não tinham doença aguda

Análise de Sobrevivência Aplicada à Saúde -- 2014

**Resíduos Escore – dfbetas**

- Verifica a influência de cada observação no ajuste do modelo
  - √ Permite a estimação robusta da variância dos coeficientes da regressão
    - Utilizada quando o indivíduo sofre mais de um evento
  - √ Influência de cada observação deve ser proporcional a  $(x_i - \bar{x}) \times$  resíduo
  - √ Vantagem:
    - Melhora a análise quando há muita censura
    - (são definidos para todos os tempos)

Análise de Sobrevivência Aplicada à Saúde -- 2014

√ Verificação da influência de cada observação nos parâmetros do modelo de Cox

- Diferença entre o vetor de parâmetros estimados pelo modelo e o mesmo estimado sem o indivíduo  $i$

$$\Delta\beta = \hat{\beta} - \hat{\beta}_{(-i)}$$

- Observação tem pouca influência na estimativa se diferença for igual a zero
- Quanto maior o valor de  $\Delta\beta_k$ , maior a influência da observação

Análise de Sobrevivência Aplicada à Saúde -- 2014

√ Gráfico dos resíduos escore para cada covariável

- Revela pontos influentes
  - Indivíduos que influenciam fortemente a estimativa do parâmetro de cada covariável
- Gráfico dos resíduos escore escalonados pelo erro padrão da respectiva covariável melhora a visualização

√ Variáveis contínuas:

- Gráfico de dispersão

√ Variáveis categóricas:

- Boxplot para cada nível da covariável

Análise de Sobrevivência Aplicada à Saúde -- 2014

**Exemplo**

• Sobrevivência de pacientes a transplante:

√ Modelo m4

√ Objetivo: Análise de pontos influentes

- Gráficos dos resíduos escore para cada covariável

√ Resíduos escore no R:

- `res.escore <- resid(modelo, type = "dfbetas")`
- Objeto `res.escore` guarda em cada coluna as variáveis incluídas no modelo na ordem em que foram colocadas
- Para conferir a ordem das variáveis veja `modelo$call`

Análise de Sobrevivência Aplicada à Saúde -- 2014

√ Comandos em R:

```
> windows(width = 14.4, height = 6)
> par(mfrow = c(2, 3))
# Idade
rotulo.x = "Idade"
variavel = tmo$idade
plot(variavel, res.escore[, 1], xlab = rotulo.x, ylab = rotulo.y)

# Sexo
rotulo.x = "Sexo"
variavel = tmo$sexo
plot(variavel, res.escore[, 2], xlab = rotulo.x, ylab = rotulo.y)

# Fase 2
rotulo.x = "Fase2"
variavel = tmo$fase
plot(variavel, res.escore[, 3], xlab = rotulo.x, ylab = rotulo.y)

# Fase 3
rotulo.x = "Fase3"
variavel = tmo$fase
plot(variavel, res.escore[, 4], xlab = rotulo.x, ylab = rotulo.y)

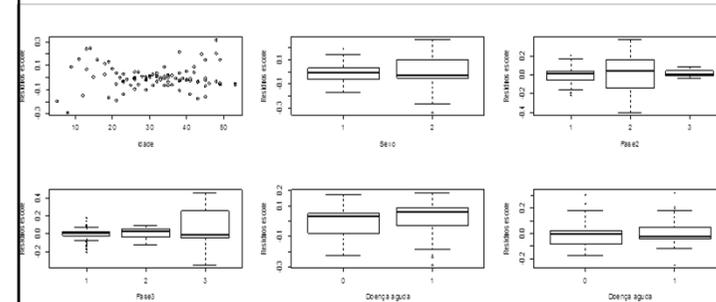
# Doença aguda
rotulo.x = "Doença aguda"
variavel = tmo$doag
plot(variavel, res.escore[, 5], xlab = rotulo.x, ylab = rotulo.y)

# Doença crônica
rotulo.x = "Doença aguda"
variavel = tmo$decr
plot(variavel, res.escore[, 6], xlab = rotulo.x, ylab = rotulo.y)
> par(mfrow = c(1, 1))
```

Para conferir a ordem das variáveis veja `m4$call`

Análise de Sobrevivência Aplicada à Saúde -- 2014

√ Resíduos escore para o modelo m4:



- Resíduo escore para todas as covariáveis
  - Apresentam escala muito reduzida e nenhuma evidência de pontos influentes

Análise de Sobrevivência Aplicada à Saúde -- 2014

## Resumo

Para:	Faça:
Avaliar proporcionalidade global	Teste de proporcionalidade global: função <code>cox.zph</code>
Avaliar proporcionalidade de cada variável	Gráfico do resíduo de Schoenfeld vs. tempo
Identificar outliers	Resíduo martingale e resíduo deviance
Estudar forma funcional da variável	Gráfico do resíduo martingale do modelo nulo vs. a covariável
Identificar pontos influentes	Gráficos do resíduo score (dfbeta) vs. a covariável

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](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 Aplicada à Saúde -- 2014