

## Introdução à Análise de Sobrevivência

Marilia Sá Carvalho  
 Dayse Pereira Campos  
 Raquel de V.C. de Oliveira

Fundação Oswaldo Cruz, Brasil

1/228

## Métodos Avançados de Análise de Sobrevivência

- ① Modelos com efeitos não lineares – Capítulo 9
- ② Múltiplos Eventos – Capítulo 10
- ③ Eventos Competitivos – Capítulo 11
- ④ Fragilidade – Capítulo 12

5/228

## Introdução à Análise de Sobrevivência

- Introdução – Capítulo 1
- O Tempo – Capítulo 2
- Funções de Sobrevivência – Capítulo 3
- Estimação Não-Paramétrica – Capítulo 4
- Estimação Paramétrica – Capítulo 5
- Modelo de Cox – Capítulo 6
- Análise de Resíduos – Capítulo 7
- Covariável Tempo-Dependente – Capítulo 8

4/228

## Cronograma – Introdução

Dia	Tema
1º dia	Introdução, O tempo, Funções de Sobrevivência
2º dia	Estimação Não-Paramétrica, Cox
3º dia	Cox, Resíduos
4º dia	Resíduos, Tempo dependente

6/228

## Bibliografia

- Kleinbaum, D., & Klein, M. *Survival analysis : a self-learning text.* Springer, 1997.
- Therneau, T. M., & Grambsch, P. M. *Modeling survival data: extending the Cox model.* Springer, 2000.
- Carvalho, M. S., Andreozzi, V. L., Codeço, C. T., Barbosa, M. T. S. & Shimakura, S. E.. *Análise de Sobrevivência: teoria e aplicações em saúde, 2a edição.*

## Material do curso

- Notas de aula e dados para exercícios na página do livro :  
<http://sobrevida.fiocruz.br/>
- R software: [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/>

## Agradecimentos

- à Fiocruz, que viabilizou escrever, testar e publicar o livro
- às instituições e seus pesquisadores que cederam, mais do que seus dados, seus problemas, idéias, perguntas:
  - Departamento de Informação e Informática do SUS – Datasus;
  - Escola Nacional de Saúde Pública – Fundação Oswaldo Cruz;
  - Hospital Geral de Betim;
  - Hospital Universitário Clementino Fraga Filho – Universidade Federal do Rio de Janeiro;
  - Hospital Universitário Gaffrée e Guinle – Universidade Federal do Estado do Rio de Janeiro;
  - Instituto de Pesquisa Clínica Evandro Chagas – Fundação Oswaldo Cruz;
  - Instituto de Saúde Coletiva – Universidade Federal da Bahia;
  - Instituto Nacional do Câncer.

## Sobrevivência

- Em que tipo de desenho de estudo se aplica a *Análise de Sobrevivência*?
  - Coorte – observacional ou de intervenção (ensaio clínico) – pressupõe o acompanhamento dos indivíduos ao longo do tempo
- Que perguntas podemos responder com os modelos de sobrevivência (ou sobrevida)?
- Definir taxa de incidência ou força de morbidade ou risco instantâneo

## Sobrevivência

- A **análise de sobrevivência**, também chamada de **análise de sobrevida**, será utilizada quando o tempo for o objeto de interesse, seja este interpretado como **o tempo até a ocorrência de um evento** ou **o risco de ocorrência de um evento por unidade de tempo**.
- As perguntas passíveis de resposta neste tipo de abordagem são:
  - Qual o efeito de um determinado anticancerígeno sobre o tempo de sobrevivência?
  - Quais os fatores associados ao tempo de duração da amamentação?
  - Quais os fatores preditivos para reinternação hospitalar, considerando o tempo entre internações?
  - Qual o efeito da unidade assistencial na sobrevivência após um infarto agudo do miocárdio?
- Considerando a possível perda de seguimento (censura)

11/228

## Refrescando a memória

- Modelo logístico: o efeito de um fator de exposição sobre o risco de ocorrência de um desfecho é uma probabilidade condicional de experiência do desfecho, dada a exposição –  $Pr(D|E)$
- Taxa ou força de incidência ou força de morbidade ou risco instantâneo –  $\lambda(t)$  – risco em expostos sobre não expostos em cada momento no tempo.

13/228

## Refrescando a memória

Supondo que TODOS conhecem modelos de regressão...

- o que é parâmetro?
- o que é estimativa?
- o que é distribuição – normal, binomial, Poisson?
- quando se usa regressão logística?
- quando se usa regressão de Poisson?
- o que é um intervalo de confiança?
- o que é um p-valor?
- o que é efeito de variável?
- o que significa a expressão "controlando por idade e sexo"?

12/228

## Outline

- 1 Cap 1 – Introdução
- 2 Cap 2 – O tempo
- 3 Cap 3 – Funções de Sobrevida
- 4 Cap 4 – Não-Paramétrica
- 5 Cap 5 – Modelagem Paramétrica
- 6 Cap 6 – Modelo de Cox
- 7 Cap 7 – Análise de Resíduos
- 8 Cap 8 – Covariável Mudando no Tempo

15/228


## O Tempo

Tempo até ...

- óbito
- transplante
- doença
- cura

16/228

## Representar o tempo



Cada linha representa a trajetória de um paciente e o símbolo X indica a ocorrência do evento ou falha.

18/228

## Medir o tempo

Tabela : Tempo de sobrevivência (em meses) de 10 pacientes em diálise.

Paciente ( $i$ )	Tempo ( $T_i$ )
1	22
2	6
3	12
4	43
5	23
6	10
7	35
8	18
9	36
10	29

17/228

## Causas de Informação Incompleta

- óbito por outras causas – morte do paciente por causas externas;
- término do estudo;
- perda de contato – mudança de residência;
- recusa em continuar participando do estudo;
- mudança de procedimento – esquema de tratamento;
- abandono devido a efeitos adversos de tratamento;
- desconhecimento da data de início – em pacientes HIV+ com data de infecção desconhecida;
- uso de dados prevalentes – óbitos antes do início do estudo.

Censura e truncamento

19/228

## Mecanismos de censura

### Censura à direita

- É a mais comum.
- Não se observa o desfecho.
- Sabe-se que o tempo entre o início do estudo e o evento é maior do que o tempo observado.
- Nesse caso aproveita-se a informação do tempo durante o qual a pessoa esteve sob observação sem que ocorresse o evento.
- Desprezar essa informação faria com que o risco fosse superestimado, pois o tempo até a evento é desconhecido, mas o paciente estava em risco de sofrer o evento pelo menos até o último momento observado.

20/228

## Dados com censura à direita

Exemplo Visando estudar o tempo entre o diagnóstico de Aids e o óbito, 193 pacientes foram acompanhados em um ambulatório especializado de 1986 a 2000:

- 92 óbitos observados
- Ao término do estudo (dez/2000), 101 permaneciam vivos
- não há informação após essa data
- 92 eventos e 101 censuras (à direita)

<http://sobrevida.fiocruz.br/>

21/228

## Dados com censura à direita


Dados de 10 pacientes Notação Clássica:  $T_i, \delta_i$

Paciente ( $i$ )	Tempo ( $T_i$ )	Status ( $\delta_i$ )
1	22	1
2	6	0
3	12	1
4	43	0
5	23	1
6	10	1
7	35	1
8	18	0
9	36	1
10	29	1

22/228

## Dados com censura à direita

Graficamente



X indica ocorrência do evento e O corresponde à presença de censura.

23/228

## Mecanismos de censura

### Censura à esquerda

- Acontece quando não conhecemos o momento da ocorrência do evento, mas sabemos que ele ocorreu antes do tempo observado.
- Considere um estudo comunitário para investigar os fatores associados à soroconversão para leptospirose, após a entrada na comunidade onde é possível a transmissão. Caso o exame seja positivo, só podemos afirmar que a transmissão ocorreu entre a data da mudança para o local e a coleta do sangue.


24/228

## Mecanismos de censura


### Censura à Direita



### Censura à Esquerda



### Censura Intervalar



26/228

## Mecanismos de censura

### Censura intervalar

- Ocorrência do evento entre tempos conhecidos
- No exemplo anterior seria a soroconversão entre dois exames (anuais).
- O tempo até a recorrência é **maior** do que a data do exame negativo e **menor** o primeiro exame positivo.

25/228

## Informativa???

A censura ainda pode ser classificada em:

- Informativa: perda do indivíduo em decorrência de causa associada ao evento estudado.
- NÃO Informativa: quando não há razão para suspeitar que o motivo da perda de informação esteja relacionado ao desfecho.
- Avaliar a censura: comparação de censurados e não censurados segundo características.
- **Evitar** censura informativa – busca ativa!

27/228


## Truncamento

- Indivíduos não são incluídos por motivo relacionado à ocorrência do evento estudado
- O estudo só inclui quem apresentou o evento na janela temporal ( $T_E, T_D$ ),  $T_E$  – no momento do início do estudo;  $T_D$  – momento do desfecho.

28/228

## Truncamento à direita


- O critério de seleção inclui somente os que sofreram o evento, logo o risco é superestimado
- Não é problema em doenças com curta duração
- Comum em estudos que partem do óbito
- Não há censura à direita



30/228

## Truncamento à esquerda


- Indivíduos já experimentaram o evento **antes** do início do estudo
- Comum no uso de dados prevalentes, bases de dados secundários
- Como indivíduos com maior sobrevida têm mais chance de entrar no estudo, o risco é subestimado



29/228

## Coorte aberta

Momento de entrada dos pacientes na coorte varia



Trajetórias individuais de pacientes com censura e com diferentes tempos de entrada em observação.

31/228

## Processo de contagem

A formulação do processo de contagem permite provar resultados importantes na análise de sobrevivência, acomodando censuras, truncamento, eventos múltiplos.

O par  $(T_i, \delta_i)$  é substituído por  $(N_i(t), Y_i(t))$ , onde:

$N_i(t) =$  número  $(0, 1, 2, \dots)$  de eventos observados em  $[0, t]$   
 evento único (óbito)  $N_i(t) = 1$ , eventos recorrentes (ex.  
 doença oportunista)  $N_i(t) = 0, 1, 2, 3 \dots$

$Y_i(t) = 1$ , se o indivíduo  $i$  está sob observação e sujeito ao risco do evento no instante  $t$

$Y_i(t) = 0$ , se o indivíduo  $i$  não está em risco.

Entender quem está em risco a cada momento é essencial na construção do banco de dados.

32/228

## Registro do tempo

Tempo de observação de pacientes de uma coorte aberta.

Paciente	Tempo* inicial (I)	Tempo* final (F)	Tempo* (final - inicial)	T (final - inicial)	Status $\delta$
1	0	22	22	22	1
2	15	21	6	6	0
3	0	12	12	12	1
4	25	47	22	22	0
5	10	33	23	23	1
6	0	10	10	10	1
7	0	35	35	35	1
8	12	30	18	18	0
9	3	39	36	36	1
10	15	34	19	19	1

\*Registrar as **datas** de entrada e do evento para cada paciente

34/228


## Processo de contagem

Formalmente:

- um processo de contagem é um processo estocástico  $N(t)$  com  $t > 0$ , de tal forma que  $N(0) = 0$  e  $N(t) < \infty$ ;
- a trajetória de  $N(t)$  é contínua à direita a partir de uma função escada com saltos de tamanho igual a um;
- a análise de sobrevivência pode ser pensada como um processo de contagem onde  $N(t)$  é o número de eventos observados até o tempo  $t$  e  $\Delta N_i(t)$  é a diferença entre a contagem de eventos até o instante  $t$  e a contagem no momento imediatamente anterior a  $t$ .

33/228


## Graficamente



Paciente 1: Diagnosticado no mês zero, acompanhado até o mês 22. A ocorrência do evento é assinalada pelo sinal •

35/228

## Graficamente





Paciente 3: Diagnosticado no mês zero, acompanhado até o mês 12.

36/228

## Graficamente


Trajetória de dois pacientes censurados que entraram na coorte ao longo do estudo




38/228

## Graficamente

Trajetória de dois pacientes censurados



censura aos 6 meses



censura ao término do estudo

37/228

## Qual o ganho?

O que se ganha com o processo de contagem?

Possibilidade de analisar:

- Mudança no valor de covariável: mudança de esquema ARV
- Evento múltiplos: sucessivos infartos do miocárdio
- Dados prevalentes: hemodiálise

39/228

## Organização dos dados

id	tempo ( $T$ )	status ( $\delta$ )	sexo	idade
1	30	0	F	54
2	14	1	F	34
3	23	1	M	65
4	11	1	F	45
5	12	0	M	44

Tabela : Forma Clássica

40/228

## Organização dos dados

id	inicio ( $I$ )	fim ( $F$ )	status ( $\delta$ )	sexo	idade
1	0	30	0	F	54
2	5	19	1	F	34
3	3	26	1	M	65
4	0	11	1	F	45
5	4	16	0	M	44

Tabela : Forma em Contagem

41/228

## Tempo de Sobrevivência no R

- O R aceita os dois formatos de registro do tempo de sobrevivência.
- O comando `Surv()` tem como função combinar, em uma única variável, a informação referente ao tempo de sobrevivência de cada indivíduo e a informação a respeito do status do paciente.
  - Status = 1 (um), se ocorreu o evento
  - Status = 0 (zero) se o tempo foi censurado
- `require(survival)`
  - `Surv(tempo,status)`
  - `Surv(inicio,fim,status)`

42/228

## O objeto sobrevivência – formato clássico

```
> require(survival)
> ipec<-read.table("ipec.csv",header=T,sep=";")
> ipec[1:9,c("id","tempo","status")]
  id tempo status
 1  1    852    1
 2  2    123    1
 3  3   1145    1
 4  4   2755    0
 5  5   2117    0
 6  6    329    0
 7  7     60    1
 8  8    151    1
 9  9   1563    1

> Surv(ipec$tempo,ipec$status)
[1] 852 123 1145 2755+ 2117+ 329+ 60 151 1563
```

43/228

## O objeto sobrevivência – formato contagem

```
id ini fim tempo status
1 1243 2095 852 1
2 2800 2923 123 1
3 1250 2395 1145 1
4 1915 4670 2755 0
5 2653 4770 2117 0
6 3 332 329 0
7 36 96 60 1
8 1 152 151 1

> Surv(ipec$ini, ipec$fim, ipec$status)
[1] (1243,2095 ] (2800,2923 ] (1250,2395 ] (1915,4670+]
[5] (2653,4770+] ( 3, 332+] ( 36, 96 ] ( 1, 152 ]
```

44/228

## Tempo de Sobrevivência no R

- `Surv(tempo,status)` – clássico
- `Surv(inicio,fim,status)` – contagem

45/228

## Resumo

Neste capítulo, foram apresentadas as diferentes abordagens – clássica e processo de contagem – para se estudar o tempo até a ocorrência de um evento, identificando-se:

- o tempo quando ocorre o evento;
- a população em risco em cada tempo;
- a censura não informativa e informativa;
- a censura à esquerda, à direita e intervalar;
- o truncamento à esquerda e à direita.

46/228

## Outline

- 1 Cap 1 – Introdução
- 2 Cap 2 – O tempo
- 3 Cap 3 – Funções de Sobrevida
- 4 Cap 4 – Não-Paramétrica
- 5 Cap 5 – Modelagem Paramétrica
- 6 Cap 6 – Modelo de Cox
- 7 Cap 7 – Análise de Resíduos
- 8 Cap 8 – Covariável Mudando no Tempo

48/228

## Funções de sobrevivência

- Introdução
- Função de Densidade de Probabilidade
- Função de sobrevivência
- Função de Risco (instantâneo)
- Comportamento da função de risco
- Função de Risco Acumulado
- Relação entre as funções
- Função de Verossimilhança

49/228

## Função – densidade de probabilidade

- $T$  – tempo de sobrevivência (até a ocorrência de um evento);
- $T$  é uma variável aleatória contínua e positiva;
- $f(t)$  é a sua função de densidade de probabilidade;
- a função  $f(t)$  pode ser interpretada como a probabilidade de um indivíduo sofrer um evento em um intervalo instantâneo de tempo.

$$f(t) = \lim_{\epsilon \rightarrow 0^+} \frac{Pr(t \leq T \leq t + \epsilon)}{\epsilon}$$

51/228

## Introdução

- 50 pacientes, 4 anos de acompanhamento, 32 óbitos
- Taxa média de mortalidade:  $32/50 = 0,64 = 64\%$  ou 16 óbitos por 100 pessoas/ano
- Mas... essa taxa não é homogênea no tempo.
- A análise de sobrevivência responde a:
  - Qual o **risco** de um paciente diagnosticado com Aids vir a falecer **em até** três anos após o diagnóstico?
  - Qual a **probabilidade** de um paciente sobreviver por **mais de** dois anos após o diagnóstico de Aids?
  - Qual seria o **número esperado** de óbitos em uma coorte de pacientes acompanhada por cinco anos?
  - Qual o **tempo mediano** de sobrevivência?

50/228

## Estimativa de probabilidade sem censura

Se não houver censura, isto é, se **todos** os pacientes apresentarem o evento antes do fim do estudo, a função  $f(t)$  pode ser estimada a partir da tabela de frequência.

Nesta tabela, os valores observados de  $T$  são distribuídos em classes e para cada classe  $x$ , calcula-se  $f_x(t)$ :

$$\hat{f}_x(t) = \frac{n^o \text{ de ocorrências na classe } x}{(n^o \text{ total de ocorrências}) \times (\text{amplitude de } x)}$$

$$\hat{f}_x(t) = \frac{N_x(t)}{(n^o \text{ total de ocorrências}) \times \Delta_x}$$

52/228

## Tempos de sobrevivência – Aids, 32 pacientes

3	18	29	54	60	84	110	112	116	123	134
145	151	151	158	173	194	214	329	331	371	408
490	514	541	555	688	780	801	858	887	998	

53/228

## Função de sobrevivência

Qual é a probabilidade de um paciente com aids sobreviver 365 dias ou mais? Isto é, qual a probabilidade de  $T$  ser maior do que um determinado valor  $t = 365$ ? Ou, mais formalmente, qual é  $Pr(T > 365)$ ?

A função de sobrevivência,  $S(t)$ , é a probabilidade de um indivíduo sobreviver por mais do que um determinado tempo  $t$ .

$$S(t) = Pr(T > t)$$

55/228

## Estimativa de probabilidade sem censura

Intervalo	$R_x(t)$	$N_x(t)$	$\Delta_x$	$\hat{f}_x(t)$
(0,3]	32	1	3	0,010
(3,18]	31	1	15	0,002
(18,29]	30	1	11	0,003
(29,54]	29	1	25	0,001
(54,60]	28	1	6	0,005
(60,84]	27	1	24	0,001
(84,110]	26	1	26	0,001
(110,112]	25	1	2	0,016
(112,116]	24	1	4	0,008
(116,123]	23	1	7	0,004
(123,134]	22	1	11	0,003
(134,145]	21	1	11	0,003
(145,151]	20	2	6	0,010
(151,158]	18	1	7	0,004
(158,173]	17	1	15	0,002
:				

54/228

## Função de sobrevivência

Relembrando: a função de distribuição acumulada,  $F(t)$ , de uma variável aleatória é definida como a probabilidade de um evento ocorrer até o tempo  $t$ .

$$F(t) = Pr(T \leq t)$$

Logo,  $S(t)$  é o complemento da função de distribuição acumulada  $F(t)$ :

$$S(t) = Pr(T > t) = 1 - Pr(T \leq t) = 1 - F(t)$$

56/228

## Estimando a sobrevidência – sem censura

$$\hat{S}_x(t_{inf}) = \frac{\text{nº pacientes com } T > t_{inf}}{\text{nº total de pacientes}}$$

em que  $t_{inf}$  é o limite inferior do intervalo de tempo considerado  $x$ .

57/228

## Função de Risco

- Qual é o risco de um paciente com aids vir a óbito após sobreviver 365 dias?
- Esse risco de morrer aumenta ou diminui com o tempo?

$\lambda(t) \rightarrow$  probabilidade instantânea de um indivíduo sofrer o evento em um intervalo de tempo  $t$  e  $(t + \epsilon)$  dado que ele sobreviveu até o tempo  $t$ .

Sendo  $\epsilon$  infinitamente pequeno,  $\lambda(t)$  expressa o risco instantâneo de ocorrência de um evento, dado que até então o evento não tenha ocorrido.

59/228

## Cálculo da Função de sobrevidência – Aids

Intervalo	$R_x(t)$ (risco)	$N_x(t)$ (eventos)	$\hat{f}_x(t)$ (densidade)	$\hat{S}_x(t)$ (sobrevidência)
(0,3]	32	1	0,010	1,000
(3,18]	31	1	0,002	0,969
(18,29]	30	1	0,003	0,938
(29,54]	29	1	0,001	0,906
(54,60]	28	1	0,005	0,875
(60,84]	27	1	0,001	0,844
(84,110]	26	1	0,001	0,813
(110,112]	25	1	0,016	0,781
(112,116]	24	1	0,008	0,750
(116,123]	23	1	0,004	0,719
(123,134]	22	1	0,003	0,688
(134,145]	21	1	0,003	0,656
(145,151]	20	2	0,010	0,625
(151,158]	18	1	0,004	0,563
(158,173]	17	1	0,002	0,531
.				

58/228

## Função de Risco

$$\lambda(t) = \lim_{\epsilon \rightarrow 0} \frac{Pr((t < T < t + \epsilon) | T \geq t)}{\epsilon}$$

- $\lambda(t)$  também é denominada:
  - função ou taxa de incidência,
  - força de infecção,
  - taxa de falha,
  - força de mortalidade,
  - força de mortalidade condicional.
- Apesar do nome risco,  $\lambda(t)$  é uma taxa ( $\text{tempo}^{-1}$ ).
- Pode assumir qualquer valor positivo (não é probabilidade).

60/228

## Função de Risco e de sobrevivência

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

$$\lambda(t) = -\frac{d \ln(S(t))}{dt}$$

Sobrevivência e risco são inversamente proporcionais: quando o risco aumenta, a probabilidade de sobrevivência diminui e vice-versa.

61/228

## Estimando risco

Intervalo	$R_x(t)$	$N_x(t)$	$\Delta_x$	$\hat{f}_x(t)$	$\hat{S}_x(t)$	$\hat{\lambda}_x(t)$
(0,3]	32	1	3	0,010	1,000	$\frac{1}{32 \times 3} = 0,010$
(3,18]	31	1	15	0,002	0,969	$\frac{1}{31 \times 15} = 0,002$
(18,29]	30	1	11	0,003	0,938	$\frac{1}{30 \times 11} = 0,003$
(29,54]	29	1	25	0,001	0,906	$\frac{1}{29 \times 25} = 0,001$
(54,60]	28	1	6	0,005	0,875	$\frac{1}{28 \times 6} = 0,006$
(60,84]	27	1	24	0,001	0,844	$\frac{1}{27 \times 24} = 0,002$
(84,110]	26	1	26	0,001	0,813	$\frac{1}{26 \times 26} = 0,001$
(110,112]	25	1	2	0,016	0,781	$\frac{1}{25 \times 2} = 0,020$
(112,116]	24	1	4	0,008	0,750	$\frac{1}{24 \times 4} = 0,010$
(116,123]	23	1	7	0,004	0,719	$\frac{1}{23 \times 7} = 0,006$
(123,134]	22	1	11	0,003	0,688	$\frac{1}{22 \times 11} = 0,004$
(134,145]	21	1	11	0,003	0,656	$\frac{1}{21 \times 11} = 0,004$
(145,151]	20	2	6	0,010	0,625	$\frac{2}{20 \times 6} = 0,017$
(151,158]	18	1	7	0,004	0,563	$\frac{1}{18 \times 7} = 0,008$
(158,173]	17	1	15	0,002	0,531	$\frac{1}{17 \times 15} = 0,004$

63/228

## Estimando risco sem censura

$$\hat{\lambda}_x(t) = \frac{n^o \text{ ocorrências na classe } x}{R_x(t) \times (\text{amplitude de } x)}$$


- Número de eventos observados no intervalo de classe  $x$  divididos pelo número de pacientes em risco no início do intervalo  $x$  e pela amplitude de  $x$ .
- Uma maneira alternativa de estimar  $\lambda(t)$  é utilizar as relações entre  $S(t)$ ,  $f(t)$  e  $\lambda(t)$ .
- Comum nas tábuas de vida – demografia.

### Planilha tempo.ods

62/228



## Estimando risco

## Comportamento da Função de Risco





64/228

## Comportamento da Função de Risco



65/228

## Comportamento da Função de Risco



66/228

## Função de risco acumulado

- Qual o risco de um paciente com aids vir a óbito no primeiro ano após o diagnóstico?
- Qual é o risco dele vir a óbito nos primeiros 2 anos?

$\Lambda(t)$  → função de risco acumulado.

Mede o risco de ocorrência do evento até o tempo  $t$ .

É a soma (integral) de todos os riscos em todos os tempos até o tempo  $t$ .

$$\Lambda(t) = \int_0^t \lambda(u) d(u)$$

Também é uma taxa, logo não está restrita ao intervalo  $[0; 1]$ .

67/228

## Estimando risco acumulado sem censura

$$\hat{\Lambda}_x(t) = \sum_{k=1}^{x-1} \hat{\lambda}_k(t) \times \text{amplitude de } k$$

- O risco acumulado até o tempo  $t$  é igual a:
  - o risco acumulado até o tempo  $t - 1$  mais
  - o risco instantâneo do período anterior vezes o intervalo de tempo até  $t$ .

Planilha tempo.xls

68/228

## Relação entre as Funções

- Qual a probabilidade de sobreviver por mais de  $t$  unidades de tempo?
- Qual o risco de sofrer o evento no tempo  $t$  se sabemos que o paciente sobreviveu até aquele momento?
- Qual o risco de sofrer o evento até um determinado tempo  $t$ ?

## Função de verossimilhança

- A função de verossimilhança avalia o quanto os dados apoiam, concordam ou suportam cada valor possível do parâmetro a ser estimado.
- Exemplo: amostra para estimar prevalência de hipertensão.
  - 10% dos participantes são hipertensos
  - verossimilhança da proporção de hipertensos na população ser 90% é baixíssima
  - quanto mais próximo de 10%, maior a verossimilhança  $\Rightarrow$  Máxima Verossimilhança
- Pressupostos do método de Máxima Verossimilhança:
  - Observações independentes
  - Tempos de sobrevidência independentes
  - Censuras independentes

## Relação entre as funções básicas de sobrevidência

$$S(t) = 1 - F(t)$$

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

$$\lambda(t) = -\frac{d \ln(S(t))}{dt}$$

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

$$\lambda(t) = \frac{f(t)}{1-F(t)}$$

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

## Função de verossimilhança na sobrevidência

- Sem censura:  $L \propto \prod_i f(t_i)$
- Com censura à direita:  $L \propto \prod_{i \in O} f(t_i) \prod_{i \in D} S(t_i)$
- Com censura à esquerda:  
 $L \propto \prod_{i \in O} f(t_i) \prod_{i \in D} S(t_i) \prod_{i \in E} [1 - S(t_i)]$
- Com censura intervalar:  $L \propto \prod_{i \in O} f(t_i) \prod_{i \in D} S(t_i) \prod_{i \in E} [1 - S(t_i)] \prod_{i \in I} [S(t_i^-) - S(t_i^+)]$
- Com truncamento: probabilidade condicional – do indivíduo ser incluído no estudo.

## Outline

- 1 Cap 1 – Introdução
- 2 Cap 2 – O tempo
- 3 Cap 3 – Funções de Sobrevida
- 4 Cap 4 – Não-Paramétrica
- 5 Cap 5 – Modelagem Paramétrica
- 6 Cap 6 – Modelo de Cox
- 7 Cap 7 – Análise de Resíduos
- 8 Cap 8 – Covariável Mudando no Tempo

74/228

## Introdução

- Duas formas não paramétricas de estimação das funções de sobrevida:
  - Kaplan-Meier –  $S(t)$
  - Nelson-Aalen –  $\Lambda(t)$
- COM censura
- Sem suposições sobre a distribuição do tempo

76/228

## Estimação Não-Paramétrica

- Introdução
- Kaplan-Meier
- Nelson-Aalen
- Intervalos de confiança
- Tempo Mediano de sobrevida
- Kaplan-Meier com estratificação
- Teste de Log-Rank
- Teste de Peto

### Incorporando a censura

Sem suposições sobre a distribuição do tempo

75/228

## Kaplan-Meier

- A probabilidade de sobrevida até o tempo  $t$  é estimada considerando que a sobrevida até cada tempo é independente da sobrevida até outros tempos.
- A probabilidade de chegar até o tempo  $t$  é o produto da probabilidade de chegar até cada um dos tempos anteriores.
- Estimador produto (ou estimador limite produto)

77/228

## Kaplan-Meier

- Sejam  $t_1 < t_2 < \dots < t_m$  os  $m$  tempos onde ocorreram os eventos;
- $R(t_j)$  é o total de pessoas a risco no tempo  $t_j$ .
- $\Delta N(t_j)$  é o número de eventos ocorridos precisamente em  $t_j$ .
- Para os  $m$  tempos  $t_j$  em que ocorre um evento, a probabilidade de sobrevivência será estimada pelo número dos que sobreviveram até aquele tempo ( $R(t_j) - \Delta N(t_j)$ ) sobre os que estavam em risco naquele tempo ( $R(t_j)$ ).
- Como os eventos são independentes  $S(t)$  é o produto das probabilidades de sobrevivência a cada tempo  $t_j \leq t$ .

78/228

## Kaplan-Meier

$$\hat{S}_{KM}(t) = \left( \frac{R(t_1) - \Delta N(t_1)}{R(t_1)} \right) \times \left( \frac{R(t_2) - \Delta N(t_2)}{R(t_2)} \right) \times \dots \times \left( \frac{R(t_m) - \Delta N(t_m)}{R(t_m)} \right)$$

ou na forma de produtório:

$$\hat{S}_{KM}(t_j) = \prod_{j:t_j \leq t} \frac{R(t_j) - \Delta N(t_j)}{R(t_j)}$$

79/228

## Kaplan-Meier – o dado

- 21 pacientes com aids ( $n=21$ )
- 15 óbitos ( $m=15$ )
- 6 censuras (indicada pelo +)

60	84	25+	54	80+	37	18	29	50+	83	80
81+	35	52	21	40	22	85+	39	16	21+	

80/228

## Kaplan-Meier – gráfico




Figura : Função de sobrevivência dos pacientes com Aids. Os símbolos + localizam as censuras. É uma função em escada, que salta em cada tempo onde ocorre evento.

81/228

## Da sobrevida ao risco

Função de Risco Acumulado

$$\hat{\Lambda}_{KM}(t) = -\ln \hat{S}_{KM}(t)$$

Logo.... pode-se estimar qualquer das funções.

82/228

## Estimador de -Aalen

Função de Risco Acumulado


$$\hat{\Lambda}_{NA}(t) = \sum_{t_j \leq t} \frac{N(t_j)}{R(t_j)}$$

Indicado para amostras muito pequenas  
Equivalente ao K-M pra amostras grandes

[planilha exerciciokm.ods](#)

84/228

## Gráfico da Função de Risco Acumulado



83/228

## Estimativas de K-M e N-A

$t_j$	$R(t)$	$\Delta N(t)$	$S_{KM}(t)$	$\hat{\Lambda}_{km}(t)$	$\hat{\Lambda}_{na}(t)$
16	21	1	0,9524	0,0488	$(\frac{1}{21}) = 0,0476$
18	20	1	0,9048	0,1001	$(0,0476 + \frac{1}{20}) = 0,0976$
21	19	1	0,8571	0,1542	$(0,0976 + \frac{1}{19}) = 0,1503$
22	17	1	0,8067	0,2148	$(0,1502 + \frac{1}{17}) = 0,2091$
29	15	1	0,7529	0,2838	$(0,2091 + \frac{1}{15}) = 0,2757$
35	14	1	0,6992	0,3578	$(0,2757 + \frac{1}{14}) = 0,3472$
37	13	1	0,6454	0,4379	$(0,3472 + \frac{1}{13}) = 0,4241$
39	12	1	0,5916	0,5249	$(0,4241 + \frac{1}{12}) = 0,5074$
40	11	1	0,5378	0,6203	$(0,5074 + \frac{1}{11}) = 0,5983$
52	9	1	0,4781	0,7379	$(0,5983 + \frac{1}{9}) = 0,7094$
54	8	1	0,4183	0,8716	$(0,7094 + \frac{1}{8}) = 0,8344$
60	7	1	0,3585	1,0258	$(0,8344 + \frac{1}{7}) = 0,9773$
80	6	1	0,2988	1,2080	$(0,9773 + \frac{1}{6}) = 1,1440$
83	3	1	0,1992	1,6134	$(1,1439 + \frac{1}{3}) = 1,4773$
84	2	1	0,0996	2,3066	$(1,4773 + \frac{1}{2}) = 1,9773$

85/228

## Intervalos de confiança

Variância do estimador Kaplan-Meier para a sobrevida  
Estimador de Greenwood

$$Var(\hat{S}_{KM}(t)) = (\hat{S}_{KM}(t))^2 \sum_{j: t_j \leq t} \frac{\Delta N(t_j)}{R(t_j)(R(t_j) - \Delta N(t_j))}$$

86/228

## Intervalos de confiança

Construindo intervalo simétrico para o risco  
 $\ln \Lambda(t) = \ln(-\ln S(t))$ , pode-se obter um intervalo assimétrico para  $S(t)$ , porém sempre positivo e menor ou igual a 1.

88/228

## Intervalos de confiança

Assumindo erro  $\alpha$ , o intervalo fica assim:

Limite inferior

$$\hat{S}_{KM}(t) - z_{\alpha/2} \sqrt{Var(\hat{S}_{KM}(t))}$$

Limite superior

$$\hat{S}_{KM}(t) + z_{\alpha/2} \sqrt{Var(\hat{S}_{KM}(t))}$$

Entretanto, este intervalo permite valores negativos e maiores do que 1, o que é incompatível com a definição de sobrevida.

87/228

no R

- Criando o objeto sobrevida (tempo, status) (somente  $t < 90$ )

```
> tempo <- c(16, 18, 21, 21, 22, 25, 29, 35, 37,
  39, 40, 50, 52, 54, 60, 80, 80, 81, 83, 84, 85)
> status <- c(1,1,0,1,1,0,1,1,1,1,0,1,1,0,1,0,1,1,0)
# variável status=1 indica evento, 0 censura
> Surv(tempo,status)
```

16 18 21+ 21 22 25+ 29 35 37 39 40 50+ 52 54 60 80+ 80 81+ 83 84 85+

- Kaplan-Meier

```
> KM <- survfit(Surv(tempo,status) ~ 1)
> summary(KM)
> plot(KM)
```

- Nelson-Aalen

```
> sob.NA <- survfit(coxph(Surv(tempo,status)~1))
> sob.NA
> summary(sob.NA)
```

89/228

## Saídas do R – summary(KM)


time	n.risk	n.event	survival	std.err	lower95%CI	upper95%CI
16	21	1	0.9524	0.0465	0.8655	1.000
18	20	1	0.9048	0.0641	0.7875	1.000
21	19	1	0.8571	0.0764	0.7198	1.000
22	17	1	0.8067	0.0869	0.6531	0.996
29	15	1	0.7529	0.0963	0.5859	0.968
35	14	1	0.6992	0.1034	0.5232	0.934
37	13	1	0.6454	0.1085	0.4642	0.897
39	12	1	0.5916	0.1120	0.4082	0.857
40	11	1	0.5378	0.1140	0.3550	0.815
52	9	1	0.4781	0.1160	0.2972	0.769
54	8	1	0.4183	0.1158	0.2431	0.720
60	7	1	0.3585	0.1137	0.1926	0.667
80	6	1	0.2988	0.1093	0.1459	0.612
83	3	1	0.1992	0.1092	0.0680	0.583
84	2	1	0.0996	0.0891	0.0172	0.575

90/228

## Saídas do R – plot(KM)

Função de sobrevida dos pacientes com aids, utilizando o estimador produto Kaplan-Meier.

Os símbolos + localizam as censuras.



91/228

## Tempo Mediano de Sobrevivência

- Medida sumária mais comum
- Menor tempo para o qual metade dos indivíduos sofre o evento
- Com censura é tempo no qual o valor estimado da sobrevivência é  $\leq 50\%$
- Sem censura é **exatamente** 50%

$$t_{med} = \min(t_j | \hat{S}(t_j) \leq 0,5) \quad (1)$$

92/228

## Kaplan-Meier com estratificação

- Descrever a sobrevivência segundo características: sexo, faixa etária, etc.
- A sobrevivência é estimada separadamente para cada estrato, utilizando Kaplan-Meier.
- no R


```
> ipec <- read.table("ipec.csv", header=T, sep=";")
> survaisds <- survfit(Surv(tempo, status) ~ sexo, data = ipec)
> survaisds

Call: survfit(formula = resp ~ sexo, data = ipec)
```

	n	events	rmean	se(rmean)	median	0.95LCL	0.95UCL
sexo=F	49	16	2096		229	Inf	1371
sexo=M	144	74	1581		122	1116	887


93/228

## Gráfico sobrevida estratificada



Curvas de sobrevida de pacientes com aids, estratificado por sexo.

94/228



Com intervalo de confiança de 95%.

95/228

## Testes


- Log-rank ou Mantel Haenszel
- Peto

Hipótese nula: não há diferença entre estratos

$$H_0 : \lambda_1(t) = \lambda_2(t) = \dots = \lambda_k(t)$$

96/228

## Gráfico sobrevida estratificada



Com intervalo de confiança de 95%.

95/228

## Teste Log-rank

Distribuição esperada de eventos igual em todos os estratos:

$$E_k(t) = N(t) \frac{R_k(t)}{R(t)}$$

Estatística de teste log-rank para dois estratos ( $k = 2$ ):

$$\text{Log-rank} = \frac{(O_1 - E_1)^2}{\text{Var}(O_1 - E_1)}$$

$O_1$  = total de eventos **observados** no estrato 1

$E_1$  = total de eventos **esperados** no estrato 1.

97/228

## Teste log-rank

A variância, que entra no cálculo como um fator de padronização, tem a fórmula (para  $k = 2$ ):

$$Var(O_1 - E_1) = \sum_t \frac{R_1(t)R_2(t)\Delta N(t)[R(t) - \Delta N(t)]}{R(t)^2[R(t) - 1]}$$

A estatística log-rank, sob a hipótese nula, segue uma distribuição  $\chi^2$ , com  $k - 1$  graus de liberdade.

98/228

## Teste de Peto

Dá maior peso às diferenças (ou semelhanças), no início da curva, onde se concentra a maior parte dos dados e por isso é mais informativa. Usa um ponderador  $S(t)$  no estimador.

$$\text{Peto} = \frac{(O_1 - E_1)^2}{Var(O_1 - E_1)}$$

sendo que

$$O_1 - E_1 = \sum_{t_j} S(t_j)(O_1(t_j) - E_1(t_j))$$

Também a estatística Peto segue aproximadamente uma distribuição  $\chi^2$  com  $k - 1$  graus de liberdade.

99/228

## no R – Log-rank

```
> survdiff(Surv(tempo,status)~sexo, data=ipec,rho=0)
Call:
survdiff(formula = Surv(tempo, status) ~ sexo, data = ipec, rho = 0)

      N Observed Expected (0-E)^2/E (0-E)^2/V
sexo=F  49       16     24.5     2.93     4.03
sexo=M 144       74     65.5     1.09     4.03

Chisq= 4 on 1 degrees of freedom, p= 0.0447 ***
```

O argumento `rho` determina o tipo de teste a ser realizado. Para log-rank, use `rho = 0` (*default*). Para o teste Peto, use `rho = 1`.

100/228

## no R – Peto

```
> survdiff(Surv(tempo,status)~sexo, data=ipec,rho=1)
Call:
survdiff(formula = Surv(tempo, status) ~ sexo, data = ipec, rho = 1)

      N Observed Expected (0-E)^2/E (0-E)^2/V
sexo=F  49      12.1     18.2     2.011     3.54
sexo=M 144      55.1     49.0     0.746     3.54

Chisq= 3.5 on 1 degrees of freedom, p= 0.0598 *
```

101/228

## Resumo

Neste capítulo foram apresentados:

- Método não paramétrico para estimação da função de sobrevida – Kaplan-Meier;
- Método não paramétrico para estimação da função risco acumulado – Nelson-Aalen;
- Intervalos de confiança para as duas funções;
- Cálculo e interpretação do tempo de sobrevida mediano;
- Intervalos de confiança para o tempo de sobrevida mediano;
- Testes para comparação das curvas de sobrevida entre diferentes estratos – log-rank e Peto.

102/228

## Modelagem Paramétrica

- Introdução
- Distribuições estatísticas para modelar as funções de sobrevida
- Estimação
- Regressão paramétrica
- Seleção dos modelos
- Avaliação de ajuste do modelo

105/228

## Outline

- 1 Cap 1 – Introdução
- 2 Cap 2 – O tempo
- 3 Cap 3 – Funções de Sobrevida
- 4 Cap 4 – Não-Paramétrica
- 5 Cap 5 – Modelagem Paramétrica
- 6 Cap 6 – Modelo de Cox
- 7 Cap 7 – Análise de Resíduos
- 8 Cap 8 – Covariável Mudando no Tempo


104/228

## Introdução

- Os estimadores de Kaplan-Meier e Nelson-Aalen para as funções  $S(t)$  e  $\lambda(t)$  são obtidos a partir dos dados, supondo que a cada momento do tempo existe um processo diferente gerando as observações.
- Como cada intervalo de tempo é estimado de forma independente, a estimativa não-paramétrica possui tantos parâmetros quantos intervalos de tempo.
- Na abordagem paramétrica o tempo segue uma distribuição de probabilidade conhecida.
- Para estimar o efeito de covariáveis  $\rightarrow$  modelagem

106/228

## Distribuição do tempo da coorte de Aids



107/228

## Distribuições

- Distribuições estatísticas para modelar as funções de sobrevivência:
  - Exponencial
  - Weibull
  - Log-normal
  - ...
- Funções assimétricas, contínuas, positivas

109/228

## Tempo de vida acelerado

O tempo  $T$  obedece à:

$$\ln(T) = \mu + \sigma W$$

sendo:

$W$  → distribuição de probabilidade que ajusta  $T$

$\mu$  → parâmetros de média  $\ln(T)$ , também chamado **locação**

$\sigma$  → parâmetros de dispersão de  $\ln(T)$ , **escala**

108/228

## Distribuição Exponencial

Se a variável  $T$  possui uma distribuição exponencial,

- Densidade de probabilidade:

$$f(t) = \alpha \exp(-\alpha t), \quad \alpha > 0$$

- Função de sobrevivência:

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

- A função risco é **constante** para todo o tempo de observação  $t$ , ou seja:

$$\lambda(t) = \frac{f(t)}{S(t)} = \alpha = \text{constante}$$


- A função de risco acumulado é uma função linear no tempo e é dada por:

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

110/228

## Algumas exponenciais

Função de sobrevivência, de risco e de risco acumulado para a distribuição exponencial considerando diferentes valores de  $\alpha$




A distribuição exponencial é conhecida como distribuição exponencial padrão quando  $\alpha = 1$ .

111/228

## Exemplo – aids

Tempo médio de sobrevivência  $= \frac{1}{\alpha} = \frac{1}{0,000497} = 2012$  dias; Tempo mediano de sobrevivência  $= \frac{\ln(2)}{\alpha} = \frac{\ln(2)}{0,000497} = 1394$  dias.



113/228

## Interpretando risco exponencial

- média:  $E(T) = \frac{1}{\alpha}$
- variância:  $var(T) = \frac{1}{\alpha^2}$
- $T_{mediano} = \ln(2)/\alpha$
- quanto maior o risco, menor o tempo médio de sobrevivência e menor a variabilidade deste em torno da média
- como a distribuição do tempo de sobrevivência  $T$  é assimétrica, usa-se mais o tempo mediano
- o modelo exponencial é matematicamente simples, mas a suposição de risco **constante** no tempo (sem memória) é **pouco plausível**
- aplicável quando o tempo é curto para supor risco constante (por ex., o risco de acidentes domésticos de crianças entre 2 e 5 anos pode ser considerado constante neste intervalo)

112/228

## Distribuição Weibull

- permite variação do risco no tempo
- é uma generalização da distribuição exponencial:
- densidade  $\rightarrow f(t) = \gamma \alpha^\gamma t^{\gamma-1} \exp(-(\alpha t)^\gamma)$
- sobrevivência  $\rightarrow S(t) = \exp(-(\alpha t)^\gamma)$
- $\gamma$  determina a forma da função de risco  $\rightarrow$  parâmetro de forma:

$\gamma < 1$  função de risco decrescente

$\gamma > 1$  função de risco crescente


$\gamma = 1$  função de risco constante (equivalente ao modelo exponencial)

- a função de risco acumulado é:  $\Lambda(t) = -\ln S(t) = (\alpha t)^{\gamma-1}$
- o parâmetro  $\alpha$  determina a **escala** da distribuição
- **Tempo mediano:**  $S(t) = 0,5 = \exp(-(\alpha t)^\gamma)$

114/228

## Algumas Weibull

Função de sobrevivência, de risco e de risco acumulado com parâmetro escala  $\alpha = 1$  e diferentes valores do parâmetro de forma  $\gamma$



Exemplos: tumores, tempo de incubação do HIV

115/228


## Modelo de Regressão Paramétrica

- Nos modelos paramétricos, a **inclusão de covariáveis** segue a forma utilizada em modelos lineares generalizados, podendo ser tanto contínuas – pressão sanguínea, idade, dosagens bioquímicas – como categóricas – gênero, tratamento, comportamentos.
- O objetivo de um modelo de regressão é o de **estimar o efeito** de covariáveis (ou variáveis independentes ou preditores),  $x_1, x_2, \dots, x_p$ , sobre uma variável resposta (ou variável dependente),  $Y$ .
- Supondo uma distribuição da família exponencial para a variável resposta teremos um modelo linear generalizado.
- Ainda que a distribuição exponencial e a Weibull sejam parte desta família, os modelos de regressão paramétricos para tempo de sobrevivência não são parte dos GLM por causa de **dados censurados**.

117/228

## Comparando Não-paramétrico com paramétricos – Aids

$N = 21$



116/228

## Modelo de Regressão Paramétrica

- $T \rightarrow$  tempo até o evento ou censura, variável resposta
- $x \rightarrow$  vetor de covariáveis
- Função de risco:  $\lambda(t|x) = \lambda_0(t)g(x\beta)$ :  
 $\beta \rightarrow$  coeficientes estimados  
 $g(\cdot) \rightarrow$  função de ligação, positiva e contínua (exponencial, Weibull)
- Razão de riscos  $\lambda/\lambda_0$  é função das covariáveis e não depende do tempo  $\rightarrow$  riscos **proporcionais**

118/228

## Modelo de Regressão Paramétrica

- Assumimos que o parâmetro da distribuição depende de covariáveis segundo uma função
- Exemplo:  $\alpha(\mathbf{x}) = \exp(\mathbf{x}\boldsymbol{\beta})$
- Modelo Exponencial:

$$S(t|\mathbf{x}) = \exp(-\alpha(\mathbf{x})t) = \exp(-\exp(\mathbf{x}\boldsymbol{\beta})t)$$

$$\lambda(t|\mathbf{x}) = \alpha(\mathbf{x}) = \exp(\mathbf{x}\boldsymbol{\beta})$$

- Modelo Weibull:

$$S(t) = \exp(-(\alpha(\mathbf{x})t)^\gamma) = \exp(-(\exp(\mathbf{x}\boldsymbol{\beta})t)^\gamma)$$

$$\lambda(t) = \gamma\alpha(\mathbf{x})^\gamma t^{\gamma-1} = \gamma(\exp(\mathbf{x}\boldsymbol{\beta}))^\gamma t^{\gamma-1}$$

119/228

## Modelo Weibull

O tempo  $T$  segue uma distribuição de Weibull e o parâmetro de escala  $\alpha$  depende das covariáveis.

Neste caso são estimados os parâmetros:

- $\beta_0$  – cuja exponencial representa o risco médio, quando todas as covariáveis são zero;
- $\beta_1$  – cuja exponencial é a parcela de variação no tempo de sobrevivência devida à idade do paciente;
- $\gamma$  – a forma da função de risco ao longo do tempo.

121/228

## Exemplo

Assumindo que o risco de morrer é constante ao longo do tempo, pode-se estimar o efeito da *idade* na sobrevivência e no risco de 6.805 pacientes em diálise acompanhados durante um ano (1.603 morreram) através do modelo exponencial:

$$\lambda(t|idade) = \exp(\beta_0 + idade\beta_1)$$

Os parâmetros estimados são:  $\beta_0 = -6,135$  e  $\beta_1 = 0,037$ , ou seja, para cada ano a mais de vida o risco aumenta de  $\exp(0,037) = 1,0377$ .

Pode-se comparar o risco constante de morte no tempo, entre dois indivíduos submetidos à diálise, um com 30 anos e outro com 70, substituindo as estimativas dos parâmetros  $\beta$ :

$$\frac{\lambda(t|x_1 = 70)}{\lambda(t|x_1 = 30)} = \frac{\exp(\beta_0 + 70\beta_1)}{\exp(\beta_0 + 30\beta_1)} = \frac{0,000713}{0,000162} = 4,39$$

120/228

## Seleção do modelo

- Razão de Verossimilhança:  $RV = 2(l_{maior} - l_{menor})$
- Teste de Wald – testa a hipótese nula  $H_0$  de que o parâmetro  $\beta$  de cada covariável separadamente é igual a zero.
- Comparar um modelo com distribuição exponencial e outro com distribuição Weibull equivale a testar a hipótese nula de que o parâmetro de forma,  $\gamma$ , da distribuição Weibull é igual a 1. (compara-se o logaritmo da função de verossimilhança do modelo nulo exponencial com o modelo nulo Weibull)

122/228

## Qualidade do ajuste do modelo

- Deviance  $\rightarrow D = 2(l_{\text{saturado}} - l_{\text{modelo}})$
- $D \rightarrow$  assintoticamente uma  $\chi^2$ , com  $n - p - 1$  graus de liberdade

123/228

## Exemplo – Weibull

```
> survreg(formula=Surv(tempo,status)~1, data=dialise,  
          dist='weibull')  
  
Call:  
survreg(formula=Surv(tempo, status)~1, data=dialise,  
        dist="weibull")  
Coefficients:  
(Intercept)  
 4.388833  
Scale= 1.257539  
Loglik(model)= -8104.2 Loglik(intercept only)= -8104.2  
n= 6805
```

125/228

## Exemplo – exponencial

```
> survreg(formula=Surv(tempo,status)~1, data=dialise,  
          dist='exponential')  
  
Call:  
survreg(formula=Surv(tempo, status)~1, data=dialise,  
        dist="exponential")  
Coefficients:  
(Intercept)  
 4.096059  
Scale fixed at 1  
Loglik(model)= -8169 Loglik(intercept only)= -8169  
n= 6805
```

124/228

## Exemplo

Comparando:  
 $D = 2(L_{\text{weibull}} - L_{\text{exponencial}}) = 2(-8104.2 - (-8169)) = 129.6$


Como  $D$  segue uma distribuição  $\chi^2$  com um grau de liberdade,  $p = 0$ , ou seja, rejeitamos a hipótese nula de que  $\gamma = 1$ .

Isto é, o modelo de Weibull, com  $\gamma = 0,795$  é melhor do que o modelo exponencial.

126/228

## Análise Gráfica

Comparar a curva do Kaplan-Meier com as estimadas parametricamente. Quanto mais próximo o modelo paramétrico estiver da curva do Kaplan-Meier, melhor.




As três curvas em cinza referem-se aos paciente sem diabetes e as três curvas pretas aos pacientes com diabetes.

127/228

## Análise de Resíduos – Vetor de Parâmetros

Vetor de Parâmetros



129/228

## Análise de Resíduos


São três tipos de resíduos específicos dos modelos paramétricos (além dos que serão apresentados par o Modelo de Cox), que avaliam efeito de observações sobre:

- conjunto de parâmetros da regressão  $\rightarrow Idcase$
- valores preditos (em unidades de DP)  $\rightarrow Idresp$
- forma  $\rightarrow Idshape$

128/228

## Análise de Resíduos – Valores Preditos


Valores Preditos



130/228

## Análise de Resíduos – Parâmetro de Forma

### Parâmetro de Forma



131/228

## Análise de Resíduos – Casos

```
> hiv[c(9,10,49,82,182),c(4,5,6,8,13)]  
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
```

132/228

## Reajustando o modelo

```
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

133/228

## Análise de Resíduos – Retirando Casos

```
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

134/228

## Outline

- 1 Cap 1 – Introdução
- 2 Cap 2 – O tempo
- 3 Cap 3 – Funções de Sobrevida
- 4 Cap 4 – Não-Paramétrica
- 5 Cap 5 – Modelagem Paramétrica
- 6 Cap 6 – Modelo de Cox
- 7 Cap 7 – Análise de Resíduos
- 8 Cap 8 – Covariável Mudando no Tempo

136/228

## Introdução

- O interesse é modelar o efeito de covariáveis sobre o tempo de sobrevivência (hazard)
- O modelo de regressão mais amplamente utilizado para dados de sobrevivência
- Ou seja, as covariáveis têm um efeito multiplicativo na função de risco
- Usando processo de contagem modela-se situações mais complexas -> Cox estendido (curso avançado).

138/228

## Modelo de riscos proporcionais de Cox (semi-paramétrico)

- Introdução
- Riscos proporcionais
- Modelo de Cox
- Cox estratificado
- Seleção dos modelos
- Qualidade do ajuste
- Tempos de vida empataados

137/228

## Riscos Proporcionais

- Ajusta a função de risco  $\lambda(t)$ , considerando um risco basal  $\lambda_0(t)$
- Inclui o vetor de covariáveis  $\mathbf{x}$ , de forma que:

$$\lambda(t|\mathbf{x}) = \lambda_0(t) \exp(x_1\beta_1 + x_2\beta_2 + \cdots + x_p\beta_p) = \lambda_0(t) \exp(\mathbf{x}\boldsymbol{\beta})$$

A razão entre os riscos de ocorrência do evento de dois indivíduos  $i$  e  $j$ , com covariáveis  $\mathbf{x}_k = (x_{k1}, x_{k2}, \dots, x_{kp})$  e  $\mathbf{x}_j = (x_{l1}, x_{l2}, \dots, x_{lp})$  é:

$$\frac{\lambda_k(t|\mathbf{x}_k)}{\lambda_l(t|\mathbf{x}_l)} = \frac{\exp(\mathbf{x}_k\boldsymbol{\beta})}{\exp(\mathbf{x}_l\boldsymbol{\beta})}$$

Observe que esta razão de riscos NÃO varia ao longo do tempo ->  
**Modelo de Riscos Proporcionais**

139/228

## Modelo de Riscos Proporcionais

- O modelo RP também pode ser escrito em termos da função de risco acumulado ou da função de sobrevida:

$$\Lambda(t|\mathbf{x}) = \Lambda_0(t) \exp(\mathbf{x}\boldsymbol{\beta})$$
$$S(t|\mathbf{x}) = [S_0(t)]^{\exp(\mathbf{x}\boldsymbol{\beta})}$$

- O risco acumulado basal é  $\hat{\Lambda}_0(t) = \sum_{i: t_i \leq t} \frac{\Delta N_i(t)}{\sum_{j \in R(t_i)} \exp(\mathbf{x}_j \hat{\boldsymbol{\beta}})}$
- A sobrevida basal é dada por  $\hat{S}_0(t) = \exp[-\hat{\Lambda}_0(t)]$

140/228

## Modelo de Cox - Pressupostos

- As covariáveis agem multiplicativamente sobre o risco -> parte paramétrica do modelo.
- A razão de riscos é constante ao longo de tempo -> riscos proporcionais.
- Os tempos de ocorrência do evento são independentes.
- Como o tempo é contínuo, não há empates na ocorrência do evento.

142/228

## Modelo de Cox

- Partindo do pressuposto de proporcionalidade, é possível estimar os efeitos das covariáveis sem qualquer suposição a respeito da distribuição do tempo de sobrevida, e por isso o modelo de Cox é dito semi-paramétrico.
- Não se assume qualquer distribuição estatística para a função de risco basal,  $\lambda_0(t)$ , apenas que as covariáveis agem multiplicativamente sobre o risco e esta é a parte paramétrica do modelo.

141/228

## Estimativa dos coeficientes

- Para estimar os coeficientes da regressão paramétrica, a função de verossimilhança foi construída a partir da função de densidade de probabilidade calculada nos tempos de ocorrência do evento, multiplicada pela função de sobrevida calculada nos tempos de censura.
- No Modelo de Cox o vetor de parâmetros  $\boldsymbol{\beta}$  é estimado a partir de uma **verossimilhança parcial**.
- De forma semelhante ao Kaplan Meier, considera-se apenas, a cada tempo  $t$ , a informação dos indivíduos sob risco, estimando os efeitos das covariáveis no tempo de sobrevida.

143/228

## Verossimilhança parcial

- Considere  $m$  diferentes tempos até a ocorrência de um evento (sem empate), ordenados assim:  $t_1 < t_2 < \dots < t_m$ .
- A verossimilhança individual,  $L_i$ , é a razão entre o risco  $\lambda_i(t_i)$  do indivíduo  $i$  falhar em  $t_i$  e a soma dos riscos de ocorrência de evento de todos os indivíduos em risco:

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

144/228

## Verossimilhança parcial

- Sob o processo de contagem a verossimilhança individual é igual a

$$L_i = \frac{\exp(\mathbf{x}_i \boldsymbol{\beta})}{\sum_{t \geq 0} Y_j(t) \exp(\mathbf{x}_j \boldsymbol{\beta})}$$

- com  $Y_j(t)$  igual a 1 se o indivíduo  $j$  estiver em risco no tempo  $t$  e 0, caso contrário
- A função de Verossimilhança **NÃO** depende do risco basal

145/228

## Verossimilhança Parcial

- A 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 depende apenas da informação dos indivíduos que experimentam o evento
- Denominador utiliza informações a respeito de todos os indivíduos que ainda não experimentaram o evento, incluindo aqueles que serão censurados mais tarde.

146/228


## Exemplo TMO

- Avaliar os fatores prognósticos associados ao tempo de transplante de medula óssea TMO até o óbito nos pacientes com leucemia mielóide crônica tratados no INCA.
- covariáveis:
  - sexo,
  - idade,
  - fase da doença no momento do transplante (*fase*),
  - a ocorrência ou não de doença enxerto contra hospedeiro aguda (*deag*) ou crônica (*decr*).

147/228

## Proporcionalidade

Curvas de KM para avaliar o pressuposto de proporcionalidade



148/228

## Cox estratificado

- O risco basal –  $\lambda_0(t)$  – não é o mesmo para todos os indivíduos do estudo.
- $\lambda_{0A}(t) \neq \lambda_{0B}(t) \neq \lambda_{0C}(t)$ , definindo diferentes estratos
- É usado quando alguma covariável não atende à proporcionalidade
- A variável para a qual se estratifica NÃO terá o efeito estimado.

150/228

## No R

```
> tmo <- read.table("tmoclas.dat", header=T, sep=",")
> tmo$sexo<-factor(tmo$sexo)
> m1 <- coxph(Surv(os,status) ~ idade+sexo, data=tmo, x=TRUE)
> summary(m1)

[...]
            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

Rsquare= 0.03 (max possible= 0.986 )
Likelihood ratio test= 2.92 on 2 df, p=0.2320
Wald test           = 2.85 on 2 df, p=0.2408
Score (logrank) test = 2.85 on 2 df, p=0.2406
```

149/228

## Selecionando modelos

- Teste de Wald

$$H_0 : \beta_j = 0 \\ z = \hat{\beta}_j / ep(\hat{\beta}_j)$$

- Teste da Razão de Verossimilhança

$$H_0 : Mod_{maior} = Mod_{menor} \\ RV = 2(l_{maior} - l_{menor}) \\ RV \sim \chi^2_{l-k}$$

151/228

## Selecionando Modelos

- Para modelos aninhados!
- Não se pode comparar modelos estratificados com não estratificados.
- A RV é assintoticamente semelhante à estatística de Wald quando o número de observações é grande.
- Para número de observações pequenos, a análise da função desvio é mais robusta.
- Se existirem valores ausentes, modelos perdem a comparabilidade → para retirar casos com variáveis com dados missing usar a função `complete.cases()`

152/228

## Qualidade do Ajuste

- O modelo se ajusta bem aos dados?
- Qual o poder explicativo de um modelo?
- Existem poucas estatísticas de ajuste:
  - Função Desvio (Deviance)  $\propto R^2$
  - $R^2$
  - Probabilidade de concordância
  - Gráfico de Índice Prognóstico

154/228

## Comparando modelos com função desvio

```
> anova(mod1,mod2,mod3,mod4)
```

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

153/228

## Medida Global de Ajuste – $R^2$

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

$$\begin{aligned} R_{LR}^2 &= 1 - \{L(0)/L(\hat{\beta})\}^{2/n} \\ &= 1 - \exp(2\{l(0) - l(\hat{\beta})\}/n) \end{aligned}$$

- Valor mínimo possível de  $R^2$  é zero quando  $L(0) = L(\hat{\beta})$
- Valor máximo não é 1 (ou 100%), mas a razão entre as verossimilhanças do modelo saturado e do modelo nulo ( $L(0)$ ).

155/228

## Medida Global de Ajuste – $R^2$

Modelo	$l_{\text{modelo}}$	$R^2$	% Variabilidade Explicada*
Nulo	-203,40	0,000	0,0%
Saturado	-1,39	0,986	100,0%
m1: <i>idade+sexo</i>	-201,940	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%

\*  $R^2_{\text{modelo}} / R^2_{\text{saturado}}$

156/228

## Probabilidade de Concordância

- Medida global de ajuste quando o objetivo é obter um modelo preditivo
- Avalia o poder discriminatório e a acurácia preditiva do modelo
- Similar a interpretação da Área sob a curva (AUC) na curva ROC de um modelo logístico

157/228

## Probabilidade de Concordância

Concordância( $c$ )	Poder discriminatório
$0.3 < c < 0.4$	Baixo
$c = 0.5$	ao acaso
$0.6 \leq c < 0.7$	Comum
$0.7 \leq c < 0.8$	Muito bom
$0.8 \leq c < 0.9$	Excelente

158/228

## No R

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

n=96, number of events=49

[...]

Concordance=0.768 (se=0.044)
Rsquare= 0.345 (max possible= 0.986 )
Likelihood ratio test= 40.96 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
```

159/228

## Índice Prognóstico – IP

Gráfico de sobrevivência estratificado por índice de prognóstico (IP)

- IP é o preditor linear do modelo de Cox,  $x\beta$ , calculado para cada indivíduo usando as covariáveis observadas e as estimativas dos coeficientes de regressão do modelo ajustado.
- Os indivíduos são estratificados em grupos de tamanhos aproximadamente iguais (grupos de alto, médio e baixo IP)
- Os valores médios de cada uma das covariáveis dentro de cada grupo são utilizados para obtenção de curvas de sobrevivência sob o modelo ajustado.
- Espera-se, se o modelo for razoável, que o gráfico das curvas ajustadas pelo modelo em cada estrato sejam próximas das estimadas por Kaplan-Meier.

160/228

## Índice Prognóstico – IP

- Assumindo modelo *mod4*
- Indivíduo 1: sexo masculino (*sexo* = 0) com 56 anos (*idade* = 56), na fase intermediária (*fase2* = 1 e *fase3* = 0), com manifestação de doença do enxerto aguda (*deag*=1, *decr*=0)

$$\begin{aligned}\beta_{idade} \times 56 &= -0,005019 \times 56 = -0,281064 \\ \beta_{sexo} \times 0 &= -0,271984 \times 0 = 0 \\ \beta_{fase2} \times 1 &= 0,593973 \times 1 = 0,593973 \\ \beta_{fase3} \times 0 &= 0,938411 \times 0 = 0 \\ \beta_{deag} \times 1 &= 1,190381 \times 1 = 1,190381 \\ \beta_{decr} \times 0 &= -1,061750 \times 0 = 0\end{aligned}$$

---


$$\text{Total} = 1,50329$$

162/228

## Índice Prognóstico – IP

- Assumindo modelo *mod4*
- Indivíduo 1: sexo masculino (*sexo* = 0) com 56 anos (*idade* = 56), na fase intermediária (*fase2* = 1 e *fase3* = 0), com manifestação de doença do enxerto aguda (*deag*=1, *decr*=0)

$$\beta_{idade} \times 56 = -0,005019 \times 56 = -0,281064$$

$$\beta_{sexo} \times 0 = -0,271984 \times 0 = 0$$

$$\beta_{fase2} \times 1 = 0,593973 \times 1 = 0,593973$$

$$\beta_{fase3} \times 0 = 0,938411 \times 0 = 0$$

$$\beta_{deag} \times 1 = 1,190381 \times 1 = 1,190381$$

$$\beta_{decr} \times 0 = -1,061750 \times 0 = 0$$

---


$$\text{Total} = 1,50329$$

161/228

## Índice Prognóstico – IP


- Assumindo modelo *mod4*
- Indivíduo 2: sexo feminino (*sexo* = 1) com 20 anos (*idade* = 20), na fase avançada (*fase2* = 0 e *fase3* = 1) com manifestação de doença do enxerto aguda (*deag*=1, *decr*=0)

$$\begin{aligned}\beta_{idade} \times 20 &= -0,005019 \times 20 = -0,10038 \\ \beta_{sexo} \times 1 &= -0,271984 \times 1 = -0,271984 \\ \beta_{fase2} \times 0 &= 0,593973 \times 0 = 0 \\ \beta_{fase3} \times 1 &= 0,938411 \times 1 = 0,938411 \\ \beta_{deag} \times 1 &= 1,190381 \times 1 = 1,190381 \\ \beta_{decr} \times 0 &= -1,061750 \times 0 = 0\end{aligned}$$

---


$$\text{Total} = 1,756428$$

Gráfico de sobrevivência estratificado por índice de prognóstico.



Linha sólida representa o modelo ajustado e linha pontilhada a estimativa de Kaplan-Meier.

163/228

## Tempos Empatados

- Tempo é contínuo
- Na prática → DISCRETO
- Como a estimativa só é feita quando ocorre evento, empate na censura não é problema
- Se censura e evento empatados → considera-se que o evento ocorreu primeiro
- Empate de eventos → estimativa por Efron, Breslow, exata

164/228

## Resumo

O modelo de Cox pode ser escrito como  $\lambda(t|x) = \lambda_0(t) \exp(x\beta)$ , sendo que:

- não se assume distribuição de probabilidade para o tempo  $T$  de sobrevivência;
- os coeficientes  $\beta$  são estimados por máxima verossimilhança parcial;
- modelos estratificados permitem a variação do risco basal  $\lambda_0(t)$  entre os estratos;
- a avaliação da qualidade de ajuste dos modelos baseia-se na análise da função desvio, no  $R^2$  e em análises gráficas (gráfico do índice prognóstico);
- modelos aninhados são selecionados através do teste da razão de verossimilhanças.

165/228

## Outline

- 1 Cap 1 – Introdução
- 2 Cap 2 – O tempo
- 3 Cap 3 – Funções de Sobrevida
- 4 Cap 4 – Não-Paramétrica
- 5 Cap 5 – Modelagem Paramétrica
- 6 Cap 6 – Modelo de Cox
- 7 Cap 7 – Análise de Resíduos
- 8 Cap 8 – Covariável Mudando no Tempo

167/228

## Análise de Resíduos

- Premissas e ajuste de modelo quanto à:
  - proporcionalidade do risco;
  - observações mal ajustadas pelo modelo (pontos aberrantes e influentes);
  - forma funcional das covariáveis.
- Tipos de resíduos:
  - Schoenfeld;
  - martingale;
  - deviance;
  - escore.

168/228

## Introdução

- Proporcionalidade: a relação entre variável resposta e tempo é sempre a mesma, independente do momento de ocorrência do evento.
- Linearidade (log-linearidade, pois  $\lambda(t) = \lambda_0(t)e^{\beta x}$ ): 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 (ou de alavanca) podem afetar a estimativa fortemente.

**O resíduo obtido como a resposta observada menos a esperada não pode ser usado para os dados de sobrevida: a censura!!!**

169/228

## Riscos proporcionais – Schoenfeld

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

$$\begin{aligned} r_{ik} &= \delta_i(x_{ik} - a_{ik}) \\ a_{ik} &= \frac{\sum_{j \in R(t_j)} x_{ik} \exp(\mathbf{x}_i \hat{\beta})}{\sum_{j \in R(t_j)} \exp(\mathbf{x}_i \hat{\beta})} \end{aligned}$$

$R(t_j)$  é o conjunto de indivíduos em risco no tempo  $t_j$   
 $x_{ik}$  representa o valor da covariável  $k$  do indivíduo  $i$  pertencente ao grupo de risco

171/228

## Riscos proporcionais – Schoenfeld

- O efeito de uma variável é sempre o mesmo durante todo o tempo observado?
- O resíduo de Schoenfeld é a diferença entre os valores observados de covariáveis de um indivíduo com tempo de ocorrência do evento  $t_j$  e os valores esperados em  $t_j$  dado o grupo de risco  $R(t_j)$ .
- Haverá tantos vetores de resíduos quanto covariáveis ajustadas no modelo, e que estes são definidos somente nos tempos de ocorrência do evento.

170/228

## Schoenfeld

Suponha um coeficiente  $\beta_k$  ( $k$  é cada covariável) que varia com o tempo  $t$ .  $\beta_k$  pode ser dividido em duas partes:

- uma média constante –  $E[r_i(\beta_k)|R(t_i)]$ , com variância  $V(\beta_k)$
- e uma função  $U(t)$  – que varia no tempo
- 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  $r_i^*(t_j)$  versus  $(t_j)$  (ou função de  $(t_j)$ ) apresente uma reta com inclinação zero

172/228

## Schoenfeld no R

```
> residual <- cox.zph(modelo)
> plot(residual[1])
```



Atenção para a escala do tempo:

- Kaplan-Meier – nos tempos de falha
- Calendário – bom quando ajuste usando 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

A linha curva é um *lowess*.



173/228

## Gráficos de Schoenfeld - Exemplo TMO



175/228



## Gráficos de Schoenfeld - Exemplo TMO



Time

174/228

## Gráficos de Schoenfeld - Exemplo TMO



Time

176/228

## Schoenfeld - Exemplo TMO

- Testar H<sub>0</sub> de que a correlação linear entre o resíduo de Schoenfeld e o tempo de sobrevida é nula
- Equivale a testar H<sub>0</sub>: inclinação igual a zero, ou H<sub>0</sub>: log do risco relativo é constante ao longo do tempo

```
m4.sch<-cox.zph(m4)
```

```
m4.sch
```

	<i>rho</i>	<i>chisq</i>	<i>p</i>
<i>idade</i>	-0.02226	2.92e-02	0.8644
<i>sexo2</i>	-0.18004	1.86e+00	0.1721
<i>fase2</i>	-0.00212	2.81e-04	0.9866
<i>fase3</i>	0.20766	2.91e+00	0.0881
<i>deag1</i>	0.05110	1.52e-01	0.6971
<i>decr1</i>	0.35133	7.22e+00	0.0072
<i>GLOBAL</i>	NA	1.35e+01	0.0362

177/228

## Resíduos Martingale

É a diferença entre o número observado de eventos para um indivíduo e o esperado dado o modelo ajustado, o tempo de seguimento e o percurso observado de quaisquer covariáveis tempo-dependentes.

**Semelhante** aos resíduos dos modelos de regressão linear em que:

- o valor esperado = 0 em torno do verdadeiro ( $\beta$  desconhecido)
- não são simetricamente distribuídos em torno de zero, variando de  $(-\infty, 1]$  e quando o tempo de sobrevidência é censurado o resíduo é negativo;
- o somatório dos resíduos observados = 0
- os resíduos  $M_i$  são não correlacionados, mas as estimativas  $\hat{M}_i$  são negativamente correlacionadas, ainda que fracamente

179/228

## Não proporcionalidade – soluções

- Frente a problema de proporcionalidade avaliar:
  - magnitude
  - pontos influentes
- estratificar pela covariável tempo-dependente
- particionar o eixo do tempo
- outro tipo de modelo – tempo de vida acelerado.

178/228

## Martingale X resíduos de modelos lineares

**Diferentes** dos resíduos da regressão linear porque:

- a soma de quadrados dos resíduos **não** auxilia na avaliação do ajuste global do modelo (o melhor modelo de Cox ajustado não tem a menor soma de quadrados de resíduos martingale);
- a distribuição dos resíduos **não** é aproximadamente normal, nem log-normal, logo o qqplot **não** funciona;
- o gráfico de resíduos versus valores ajustados **não** funciona para resíduos martingale pois estes são negativamente correlacionados com os valores ajustados.

180/228

## Gráficos Martingale

- $M_i$  versus índice do indivíduo: permite revelar indivíduos mal ajustados pelo modelo – valores aberrantes
  - $M_i > 0 \Rightarrow$  observados > esperados  $\Rightarrow$  modelo subestima
  - $M_i < 0 \Rightarrow$  observados < esperados  $\Rightarrow$  modelo superestima
- $M_i$  do modelo nulo (sem covariáveis) versus covariável com a superposição de uma curva de alisamento: para avaliar a forma funcional da covariável contínua a ser incluída no modelo
  - se linear – OK
  - se não linear – transformar variável, quebrar, suavizar

181/228

## Martingale no R


A função para calcular o resíduo de Martingale é:

```
> res.mart <- resid(modelo, type="martingale")
```

em que *modelo* é o objeto que recebeu o modelo de Cox.

183/228

## Gráficos Martingale – Resíduo modelo nulo X Idade



182/228

## Ajuste forma funcional não linear – CURSO AVANÇADO

- Incluir uma função de alisamento: *smoothing splines*
- Vantagem sobre polinômios é ser não paramétrica
- São tratadas como covariáveis usuais, inclusive testes de hipótese para não-linearidade
- Permite estimar intervalos de confiança

184/228



## Pontos aberrantes: resíduos deviance

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

- o sinal de  $(\widehat{M}_i)$  é o sinal do resíduo martingale.
- $l_{i(\text{modelo})} - l_{i(\text{saturado})}$ : log da função de verossimilhança para cada observação  $i$  do modelo e do saturado.
- Resíduos são simetricamente distribuídos em torno do zero, portanto interpretação mais fácil.
- A soma não é necessariamente zero.
- Sem muita censura, os resíduos  $D_i$  parecerão uma amostra aleatória normal, e por isso são úteis na detecção de valores aberrantes.
- Três gráficos: resíduos deviance contra cada observação; contra preditions do modelo e gráfico quantil-quantil.



185/228

## Pontos aberrantes: Martingale X deviance



187/228

## Pontos aberrantes: Martingale X deviance



**Figura :** Resíduos martingale e deviance, identificando indivíduos mal ajustados pelo modelo m4 (TMO). Observe que o resíduo deviance detecta indivíduos com grandes resíduos positivos, o que não foi possível com o resíduo martingale



186/228

## Resíduos escore – $dfbetas$

- Verifica a influência de cada observação no ajuste do modelo
- Permite a estimativa robusta da variância dos coeficientes de regressão (útil para dados em cluster)
- A influência de cada observação deve ser proporcional a  $(x_i - \bar{x}) \times \text{resíduo}$
- O gráfico do resíduo escore para cada covariável  $\Delta\beta_k$  versus  $x$  mostra pontos de alavanca
- Vantagem – definidos para todos os tempos, mesmo onde não ocorre evento, melhorando a análise quando há muita censura



188/228

## Resíduos escore - Exemplo modelo 4 TMO





189/228

## Resíduos escore- Exemplo modelo 4 TMO



190/228

## Resíduos escore



191/228

## Resíduos escore no R

```
> res.esco <- resid(modelo, type="dfbetas")
> par(mfrow=c(1,2))
> plot(banco$var1,res.esco[,1],
+       xlab='Var1', ylab='Resíduos')
> plot(banco$var2,res.esco[,2],
+       xlab='Var2', ylab='Resíduos')
```

Observar que o objeto `res.esco` guarda em cada coluna as variáveis incluídas no modelo, na ordem em que foram colocadas. Para lembrar quais são, veja `modelo$call`

192/228

## Sumário

Para	Fazer
Avaliar proporcionalidade global	teste de proporcionalidade global: função <code>cox.zph</code>
Avaliar proporcionalidade de cada variável	gráficos resíduo de Schoenfeld vs tempo
Identificar pontos aberrantes	resíduo martingale e resíduos <i>deviance</i>
Estudar forma funcional da variável	gráficos resíduo martingale do modelo nulo vs covariável
Identificar pontos influentes	gráficos resíduo escore vs covariável

193/228

## Covariáveis Mudando no Tempo

- Introdução
- Estrutura do dado mudando no tempo
- Diagnóstico
- Dados prevalentes
- Intervalos de tempo descontínuos

196/228

## Outline

- 1 Cap 1 – Introdução
- 2 Cap 2 – O tempo
- 3 Cap 3 – Funções de Sobrevida
- 4 Cap 4 – Não-Paramétrica
- 5 Cap 5 – Modelagem Paramétrica
- 6 Cap 6 – Modelo de Cox
- 7 Cap 7 – Análise de Resíduos
- 8 Cap 8 – Covariável Mudando no Tempo

195/228

## Introdução

- Analisar a sobrevida quando as covariáveis mudam ao longo do tempo.
- Construir adequadamente o banco de dados na situação de covariáveis tempo-dependentes.
- O que muda? Tudo:
  - Idade
  - Terapia antiretroviral
  - Medicamento: crossover, efeitos colaterais
  - Hábitos: exercício, alimentação
  - Residência
  - Emprego
- Modelo de Cox Estendido – Processo de Contagem

197/228

## Modelo de Cox Estendido

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

Onde está a diferença?

198/228

## Estrutura dos dados

	Mudança			
	1 <sup>a</sup>	2 <sup>a</sup>	3 <sup>a</sup>	4 <sup>a</sup>
paciente 1	(0,9+]	(9,1000+]		
paciente 2	(0,28+]		(28,39]	
paciente 3	(0,27+]	(27,36+]	(36,268+]	(268,434]
paciente 4	(0,24+]		(24,69]	
paciente 5	(0,22+]	(22,83+]	(83,446+]	(446,672]

+ representa censura

( → intervalo aberto, NÃO inclui o limite inferior

] → intervalo fechado, inclui o limite superior

200/228


## Estrutura dos dados mudando no tempo

id	sexo	idade	status	inicio	fim	deag	decr	recplaq	fasegr
1	2	31	0	0	9	0	0	0	CP1
1	2	31	0	9	1000	0	0	1	CP1
2	2	38	0	0	28	0	0	0	CP1
2	2	38	1	28	39	1	0	0	CP1
3	1	23	0	0	27	0	0	0	CP1
3	1	23	0	27	36	0	0	1	CP1
3	1	23	0	36	268	1	0	1	CP1
3	1	23	1	268	434	1	1	1	CP1
4	2	5	0	0	24	0	0	0	CP1
4	2	5	1	24	69	1	0	0	CP1
5	2	15	0	0	22	0	0	0	CP1
5	2	15	0	22	83	1	0	0	CP1
5	2	15	0	83	446	1	0	1	CP1
5	2	15	1	446	672	1	1	1	CP1

199/228

## Gráfico da estrutura dos dados de TMO

Quais pacientes estão em risco no tempo=434 dias (linha vertical)?



201/228

## Estimação

- Não há superposição dos tempo
- A verossimilhança parcial utilizará no máximo uma observação de cada paciente em qualquer momento.
- A soma de indivíduos em risco será feita sobre um conjunto de observações independentes.

202/228

## Exemplo

```
> muda.cox <- coxph(Surv(ini,fim,status)~haart+idade+
+ escol+sexo,data=muda)
> muda.cox
Call:
coxph(formula = Surv(ini, fim, status) ~ haart +
    idade + escol + sexo, data = muda)
      coef exp(coef) se(coef)     z      p
haartS   -0.7779   0.459  0.18508 -4.203 2.6e-05
idade    0.0185   1.019  0.00754  2.448 1.4e-02
escolAnalf -0.2342   0.791  0.76547 -0.306 7.6e-01
escolGin   0.5364   1.710  0.32688  1.641 1.0e-01
escolPrim  0.7438   2.104  0.31075  2.394 1.7e-02
escolSec   0.3265   1.386  0.33905  0.963 3.4e-01
sexoM     0.2253   1.253  0.16929  1.331 1.8e-01

Likelihood ratio test=35.1 on 7 df, p=1.08e-05 n= 1377
```

204/228

## Exemplo – aids

Estudar o efeito da terapia anti-retroviral de alta potência (Haart) no tempo de sobrevida desde o diagnóstico de Aids até o óbito. Foi registrado a mudança de tratamento (haart = S ou N) ao longo do estudo. <http://sobrevida.fiocruz.br/>

reg	haart	ini	fim	sexo	escol	status	idade	
4	N	942	1448	M	Gin	0	38	
4	S	1448	1939	M	Gin	0	38	
4	N	1939	1959	M	Gin	0	38	Tempo final da
4	S	1959	3297	M	Gin	0	38	primeira linha do
11	N	2162	2988	F	Prim	0	38	paciente 33 é
11	S	2988	3297	F	Prim	0	38	diferente do tempo
32	N	665	804	F	Prim	1	36	inicial da segunda
33	S	1498	1820	M	Univ	0	76	linha. Por que?
33	S	2400	3297	M	Univ	0	76	
34	N	686	3200	M	Sec	0	33	
35	N	769	1577	M	Sec	0	30	
35	S	1577	1597	M	Sec	1	31	
36	S	3255	3297	F	Prim	0	52	



203/228

## Uso dos resíduos

- Schoenfeld:
  - são calculados para os tempos de ocorrência do evento – definição e cálculo sem alteração para processo de contagem
  - valor da covariável utilizado nos cálculos corresponde ao tempo de evento
  - escala default é k-m, trocar para o tempo  $t$  (argumento `transform = "identity"`)
- Martingale:
  - podem ser calculados para cada registro – sem alteração
  - ou para cada indivíduo (argumento `collapse = id`)
- Escore: sem alteração.



205/228

## Resíduos Schoenfeld – aids





206/228

## Resíduos Schoenfeld – aids




207/228

## Resíduos Schoenfeld – aids



208/228

## Resíduos Schoenfeld – aids



	rho	chisq	p
haarts	-0.26583	16.70605	0.000
idade	0.00627	0.00775	0.930
escolAnalf	-0.12455	2.86745	0.090
escolGin	-0.12721	3.03844	0.081
escolPrim	-0.07071	0.96321	0.326
escolSec	-0.10421	2.03111	0.154
sexoM	0.12002	2.94786	0.086
GLOBAL	NA	24.41845	0.000962

209/228

## Exemplo - TMO

Call:



```
coxph(formula = Surv(inicio, fim, status) ~ idade + sexo +
  fasegr + deag + decr + recplaq, data = tmopc)
```

	coef	exp(coef)	se(coef)	z	p
idade	-0.0206	0.980	0.0140	-1.471	1.4e-01
sexo2	-0.1766	0.838	0.3093	-0.571	5.7e-01
fasegrOther	0.9266	2.526	0.3108	2.981	2.9e-03
deag1	1.0531	2.866	0.2917	3.610	3.1e-04
decr1	0.4370	1.548	0.3859	1.133	2.6e-01
recplaq0	1.9630	7.120	0.4671	4.203	2.6e-05

Likelihood ratio test=50.3 on 6 df, p=4.05e-09 n= 259,  
number of events= 53

210/228

## Schoenfeld – TMO



212/228



## Diagnóstico – Schoenfeld – TMO

```
> tmo.sch <- cox.zph(tmo.cox)
> tmo.sch
```

	rho	chisq	P
idade	-0.08369	0.41389	0.5200
sexo2	-0.25846	3.67790	0.0551
fasegrOther	0.04967	0.16535	0.6843
deag1	-0.03694	0.06742	0.7951
decr1	0.01235	0.00958	0.9220
recplaq0	0.00507	0.00177	0.9665
GLOBAL	NA	4.41245	0.6210


211/228

## Schoenfeld – TMO



213/228


## Schoenfeld – TMO



214/228

## Resíduos martingale

Resíduos de martingale para o modelo `tmo.cox` versus índice (a) e para o resíduo do modelo nulo versus idade (b) (covariável contínua).



216/228

## Resíduos Martingale

- Podem ser calculados para cada um dos intervalos de tempo nos quais não há mudança de covariável (cada linha)
- Ou para cada um dos  $n$  indivíduos (resíduo individual = soma dos resíduos do indivíduo em cada intervalo de tempo)
- incluir argumento `collapse=id` para obter resíduo individual



215/228

## Resíduos escore

- Permite identificar pontos de alavancas por períodos de tempo (linha)
- Ou indivíduos alavancas
- `collapse=id` – para o indivíduo



217/228

## Resíduos escore – TMO





218/228

## Resíduos escore – TMO



219/228

## Resíduos escore – TMO




220/228

## Dados prevalentes

- Identificar os valores corretos das covariáveis para cada paciente em cada intervalo de tempo (construir corretamente o banco de dados): vale para dados prevalentes ou truncados à esquerda
- Definir como data de referência  $t_0$  a data mais antiga no banco de dado, ou
- Calcular o tempo de entrada na coorte de cada indivíduo: limite inferior do seu 1ºintervalo de tempo, o momento de entrada no estudo
- Cada indivíduo será analisado dentro de sua janela temporal, eliminando o viés potencial da introdução na coorte de **sobrevidentes** com tempos mais longos
- E a forma de interpretar os efeitos é condicional – dado que o indivíduo sobreviveu até entrar em observação


221/228

## Dados prevalentes



222/228

## Dados prevalentes



223/228

## Dados prevalentes

- A escolha da estratégia depende do objetivo:
  - Fatores de risco individuais – tempo de início do estudo
  - Fator presente em todos ao mesmo tempo – tempo calendário
- Tempo total de observação não deve ser usado pois não ajusta dados prevalentes.

224/228

## Tempo descontínuo

- Podem ocorrer por: ausência de informação, afastamentos por viagem, interrupção, eventos múltiplos (próximo tópico)
- O mesmo mecanismo de registrar os intervalos de tempo (início,fim) permite tratar adequadamente dados de indivíduos com risco descontínuo ao longo do estudo

225/228

## Comparando abordagens de tempo

- 6805 pacientes que iniciam hemodiálise, acompanhados por 44 meses
- analisando como se somente acompanhados a partir do 20º – 5891
- Comparando modelos com dado completo e dado truncado, nas 3 formas de incluir o tempo.

226/228

## Resumo

A principal questão é montar o banco de dados após identificar adequadamente:

- o **tempo inicial** do acompanhamento de cada indivíduo ou que define mudança no valor da covariável;
- o **tempo final**, seja do acompanhamento ou por mudança no valor da covariável;
- o **status** em cada período entre mudanças de covariável e ao final do acompanhamento do indivíduo.

228/228

## Comparando abordagens de tempo

Tabela : HR para dados prevalentes por tempo calendário, tempo de diálise e tempo total de cada indivíduo

Covariável	Dados Completos		Dados Truncados		
	Tempo total	Calendário	Tempo total	Tempo em diálise	Calendário
Idade	1,04*	1,04*	1,04*	1,04*	1,04*
Causa:					
Congênita	0,49*	0,47*	0,51*	0,56*	0,53*
Diabetes	1,34*	1,38*	1,34*	1,32*	1,35*
Outras	1,04	1,07	1,04	1,02	1,05
Renal	1,04	1,04	1,07	1,09	1,09

\* $p < 0,05$

227/228