

Modelos de regressão paramétrica II

Vicente Garibay Cancho

O modelo log-logística

A distribuição log-logística acomoda um modelo TFA, mas não um modelo RP.


A função de risco

$$h(t) = \frac{\alpha \lambda t^{\alpha-1}}{1 + \lambda t^{\alpha}},$$

com $\alpha > 0$ e $\lambda > 0$.

Formas da função de risco

- ▶ $\alpha \leq 1$: é decrescente;
- ▶ $\alpha > 1$: é unimodal.



O modelo log-logística

A função de sobrevivência é dada por

$$S(t) = (1 + \lambda t^\alpha)^{-1},$$

e correspondente f.d.p é dada por

$$f(t) = \frac{\alpha \lambda t^{\alpha-1}}{(1 + \lambda t^\alpha)^2}.$$

O p -ésimo quantil, denotado por t_p

$$t_p = \lambda^{-1/\alpha} \left[\frac{p}{1-p} \right]^{1/\alpha}, \quad 0 < p < 1.$$

A mediana

$$t_{0,5} = \lambda^{-1/\alpha}.$$

O modelo logistica

Se T é uma v.a. que segue uma distribuição log-logístico com parâmetros $\alpha, \lambda > 0$, então a v.a. $Y = \log(T)$ segue uma distribuição logística com f.d.p. dada por

$$f(y) = \frac{1}{\sigma} \exp\left\{\frac{y - \mu}{\sigma}\right\} \left(1 + \exp\left\{\frac{y - \mu}{\sigma}\right\}\right)^{-2}, \quad y \in R,$$

com $\mu \in R$ e $\sigma > 0$ os parâmetros de localização e escala, respectivamente.

Os parâmetros da distribuição log-logistica e logistica relacionadas pelas mesmas funções apresentadas no modelo Weibull, is é,

$$\alpha = 1/\sigma, \quad e\lambda = \exp\{-\mu/\sigma\}.$$

O modelo logística

As funções de sobrevivência e de risco são respectivamente,

$$S(y) = \left(1 + \exp\left\{\frac{y - \mu}{\sigma}\right\}\right)^{-1}$$

e

$$h(y) = \frac{1}{\sigma} \exp\left\{\frac{y - \mu}{\sigma}\right\} \left(1 + \exp\left\{\frac{y - \mu}{\sigma}\right\}\right)^{-1}, \quad y \in \mathbb{R},$$

Como no modelo valor extremo, a distribuição logística tem a seguinte representação estocástica

$$y = \mu + \sigma\varepsilon,$$

onde ε é uma v.a. com distribuição logístico padrão ($\mu = 0$ e $\sigma = 1$), com f.d.p dada por

$$f(z) = \exp\{z\} (1 + \exp\{z\})^{-2}, \quad z \in \mathbb{R},$$

Modelos de chances proporcionais "proportional odds (PO)"

Em um modelo de sobrevivência de PO, a razão de chances é constante ao longo do tempo

- ▶ Chances de sobrevivência: chances de sobreviver além do tempo t

$$\frac{S(t)}{1 - S(t)} = \frac{P(T > t)}{P(T \leq t)}.$$

- ▶ Chances de falhas: chances de obter o evento no tempo t

$$\frac{F(t)}{1 - F(t)} = \frac{1 - S(t)}{S(t)} = \frac{P(T \leq t)}{P(T > t)}.$$

Modelo PO

A chance de falha do modelo log-logística é dada por

$$\frac{1 - S(t)}{S(t)} = \frac{\lambda t^\alpha (1 + \lambda t^\alpha)^{-1}}{(1 + \lambda t^\alpha)^{-1}} = \lambda t^\alpha.$$

A razão de chance (odds ratio ,OR) para dois diferentes grupos (1 e 2) com α fixo, é

$$OR(1 \text{ vs } 2) = \frac{\frac{1-S_1(t)}{S_1(t)}}{\frac{1-S_2(t)}{S_2(t)}} = \frac{\lambda_1 t^\alpha}{\lambda_2 t^\alpha} = \frac{\lambda_1}{\lambda_2}$$

Daí o modelo log-logístico é um modelo de PO.

Adequabilidade do modelo log-logístico

O log da chance de falha pode-se escrever como

$$\log \left(\frac{1 - S(t)}{S(t)} \right) = \log \lambda + \alpha \log t,$$

a qual é uma função linear em relação $\log(t)$.

- ▶ Esta propriedade permite uma avaliação gráfica da adequação de um modelo log-logístico plotando

$$\log \left(\frac{1 - \widehat{S}(t)}{\widehat{S}(t)} \right) \text{ vs } \log(t)$$

onde $\widehat{S}(t)$ é a estimativa K-M da função de sobrevivência.

Dados de Leucemia


Os dados correspondem a um estudo de tempos de remissão (em semanas) de pacientes de leucemia

	Tratamento		Placebo	
	time	log WBC	time	log WBC
1	6.00	2.31	1.00	2.80
2	6.00	4.06	1.00	5.00
3	6.00	3.28	2.00	4.91
4	7.00	4.43	2.00	4.48
5	10.00	2.96	3.00	4.01
6	13.00	2.88	4.00	4.36
7	16.00	3.60	4.00	2.42
8	22.00	2.32	5.00	3.49
9	23.00	2.57	5.00	3.97
10	6.00+	3.20	8.00	3.52
11	9.00+	2.80	8.00	3.05
12	10.00+	2.70	8.00	2.32
13	11.00+	2.60	8.00	3.26
14	17.00+	2.16	11.00	3.49
15	19.00+	2.05	11.00	2.12
16	20.00+	2.01	12.00	1.50
17	25.00+	1.78	12.00	3.06
18	32.00+	2.20	15.00	2.30
19	32.00+	2.53	17.00	2.95
20	34.00+	1.47	22.00	2.73
21	35.00+	1.45	23.00	1.97

Dados de Leucemia

A covariável $\log(WBC)$ foi categorizado

- ▶ $x = 1$, se $\log WBC < 2$,
- ▶ $x = 2$ se $\log WBC \geq 2$



⇒ linhas aproximadamente retas indica o modelo log-logístico

O modelo TFA log-logística

O modelo TFA log-logística com um único preditor x

$$S(t) = \frac{1}{1 + \lambda t^\alpha} = \frac{1}{1 + (\lambda^{\frac{1}{\alpha}} t)^\alpha}$$

resolvendo em t tem-se

$$t = \left[\frac{1}{S(t)} - 1 \right]^{\frac{1}{\alpha}} \times \frac{1}{\lambda^{1/\alpha}}.$$

Parametrizamos o fator da direita como

$$\frac{1}{\lambda^{1/\alpha}} = \exp\{\beta_0 + \beta_1 x\}.$$

Dai tem-se

$$t = \left[\frac{1}{S(t)} - 1 \right]^{\frac{1}{\alpha}} \times \exp\{\beta_0 + \beta_1 x\}.$$

O modelo TFA log-logística: Fator de aceleração

Em termos de qualquer probabilidade fixa $S(t_q) = q$ obtemos

$$t_q = [q^{-1} - 1]^{\frac{1}{\alpha}} \times \exp\{\beta_0 + \beta_1 x\}.$$

O tempo mediano

$$t_{0,5} = [2 - 1]^{\frac{1}{\alpha}} \times \exp\{\beta_0 + \beta_1 x\} = \exp\{\beta_0 + \beta_1 x\}$$

O fator de aceleração γ para $S(t_q) = q$

$$\gamma(x = 2 \text{ vs } x = 1) = \frac{[q^{-1} - 1]^{\frac{1}{\alpha}} \exp\{\beta_0 + 2\beta_1\}}{[q^{-1} - 1]^{\frac{1}{\alpha}} \exp\{\beta_0 + \beta_1\}} = \exp\{\beta_1\}$$

Código em R e Saída

```
fit=survreg(Surv(t, delta)~x1, dist="loglogistic")
```

```
summary(fit)
```

```
Call: survreg(formula = Surv(t, delta) ~ x1, dist = "loglogistic")
```

	Value	Std. Error	z	p
(Intercept)	4.094	0.586	6.98	2.92e-12
x1	-0.987	0.337	-2.93	3.40e-03
Log(scale)	-0.564	0.154	-3.67	2.41e-04

```
Scale= 0.569
```

```
Log logistic distribution
```

```
Loglik(model)= -111.2 Loglik(intercept only)= -115.4
```

```
Chisq= 8.28 on 1 degrees of freedom, p= 0.004
```

```
Number of Newton-Raphson Iterations: 4
```

```
n= 42
```

Código em R e Saída: Fator de aceleração

O fator de aceleração estimada comparando $x = 2$ (alta contagem) e $x = 1$ (contagem média) é agora:

$$\hat{\gamma} = \exp\{\hat{\beta}_1\} > \exp(\text{fit}\$coefficient[2])$$

x1
0.3728214

$$\implies, S_1(t) = S_2(0.37t)$$

Interpretação

O tempo de sobrevivência para o grupo com alta contagem ($x = 2$) é "Acelerada" por um factor de 0,37 em comparação com o grupo com contagem média ($x = 1$).

Comparação dos modelos PO e TFA log-logístico

- ▶ Modelo TFA: $\frac{1}{\lambda^{1/\alpha}} = \exp\{\beta_0 + \beta_1 x\}$.
- ▶ Modelo PO: $\lambda = \exp\{b_0 + b_1 x\}$.

Daí temos a seguinte relação

$$b_0 = -\alpha\beta_0, \text{ e } b_1 = -\alpha\beta_1.$$


Nota: Se α é fixo: $TFA \iff PO$

Assim, podemos calcular a estimativa da razão de chances (odds ratio, OR) com os coeficientes de regressão estimada do modelo TFA por:

$$\begin{aligned}\widehat{OR} &= \exp\{\hat{b}_1\} \\ &= \exp\{-\hat{\alpha}\hat{\beta}_1\} = 5,66.\end{aligned}$$

```
> beta1 <- fit$coefficient[2]
> alpha <- -1/fit$scale
> exp(-beta1*alpha)
5.662691
```

Avaliação gráfica



Avaliação gráfica

Proposição

1. Linhas retas \implies Log-logística.
2. Retas paralellas e log-logística \implies PO.
3. Log-logística e PO \implies TFA.

Prova: Considere dois grupos (1 e 2)

1. $\log\left(\frac{1-S(t)}{S(t)}\right) = \log(\lambda) + \alpha \log(t)$.
2. Retas paralellas $\implies \alpha$ é a mesma para ambos grupos \implies
 $OR = \frac{t^\alpha \lambda_1}{t^\alpha \lambda_2} = \frac{\lambda_1}{\lambda_2}$
3. Para $S(t_q) = q$, o fator de aceleração γ

$$\gamma = \frac{[q^{-1} - 1]^{\frac{1}{\alpha}} \lambda_1}{[q^{-1} - 1]^{\frac{1}{\alpha}} \lambda_2} = \frac{\lambda_1}{\lambda_2}$$

Modelo log-Normal

Uma v.a T tem distribuição log-normal se sua f.d.p é dada por

$$f(t) = \frac{1}{\sqrt{2\pi t\sigma}} \exp\left\{-\frac{1}{2} \left(\frac{\log t - \mu}{\sigma}\right)^2\right\}, \quad t > 0,$$

onde $\mu \in R$ é média de $\log T$, assim como $\sigma > 0$ é o desvio padrão, ou seja, $\log T \sim N(\mu, \sigma^2)$.

A média e variância

$$E(T) = \exp\{\mu + \sigma^2/2\}, \quad e \quad \text{Var}(T) = \exp\{2\mu + \sigma^2\}(\exp\{\sigma^2\} - 1).$$

O q-ésimo quantil

$$t_q = \exp\{\mu + \sigma z_q\}$$

onde z_q é q-ésimo quantil da distribuição normal padrão.

Modelo log-Normal


A função de sobrevivência não tem uma forma analítica explícita e é representado por

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

onde $\Phi(\cdot)$ é a função de distribuição acumulada da distribuição normal padrão.

A correspondente função de risco é dado por:

$$h(t) = \frac{\exp \left\{ -\frac{1}{2} \left(\frac{\log t - \mu}{\sigma} \right)^2 \right\}}{\sqrt{2\pi} t \sigma \Phi \left(-\frac{\log t - \mu}{\sigma} \right)}.$$



Adequabilidade do log-Normal

- ▶ $\Phi^{-1}(S(t))$ é linear em relação a $\log(t)$.


$$S(t) = \Phi\left(-\frac{\log t - \mu}{\sigma}\right), \implies \Phi^{-1}(S(t)) = -\frac{\log t - \mu}{\sigma}$$
$$\implies \log(-\log(S(t))) = \frac{\mu}{\sigma} - \frac{\log t}{\sigma}.$$

- ▶ Esta propriedade permite uma avaliação gráfica da adequação de um modelo Log-normal plotando

$$\Phi^{-1}(\widehat{S}(t)) \text{ vs } \log(t)$$

onde $\widehat{S}(t)$ é a estimativa K-M da função de sobrevivência.

Gráfico da $\Phi^{-1}(\widehat{S}(t))$ vs $\log(t)$ para os dados de leucemia.



▷ Linha reta \implies log-normal.

O modelo TFA log-normal

O modelo TFA log-normal com um único preditor x

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

resolvendo em t tem-se

$$t = \exp \{ \Phi^{-1} (S(t)) \sigma + \mu \} .$$

Parametrizamos o parâmetro de localização, μ

$$\mu = \beta_0 + \beta_1 x .$$

Dai tem-se

$$t = \exp \{ \Phi^{-1} (S(t)) \sigma \} \exp \{ \beta_0 + \beta_1 x \} .$$

O modelo TFA log-normal: Fator de aceleração

Em termos de qualquer probabilidade fixa, $S(t_q) = q$ obtemos

$$t = \exp \{ \Phi^{-1}(q) \sigma \} \exp \{ \beta_0 + \beta_1 x \}.$$

O tempo mediano

$$t_{0,5} = \exp \{ \Phi^{-1}(0,5) \sigma \} \exp \{ \beta_0 + \beta_1 x \} = \exp \{ \beta_0 + \beta_1 x \}$$

O fator de aceleração γ para $S(t_q) = q$

$$\gamma(x = 2 \text{ vs } x = 1) = \frac{\exp \{ \Phi^{-1}(q) \sigma \} \exp \{ \beta_0 + 2\beta_1 \}}{\exp \{ \Phi^{-1}(q) \sigma \} \exp \{ \beta_0 + \beta_1 \}} = \exp \{ \beta_1 \}$$

Ajuste dos dados de Leucemia do modelo TFA log-normal

```
fit.ln=survreg(Surv(t, delta)~x1, dist="lognormal")
```

```
summary(fit.ln)
```

```
Call: survreg(formula = Surv(t, delta)~ x1, dist = "lognormal")
```

	Value	Std. Error	z	p
(Intercept)	4.1851	0.598	6.9926	2.70e-12
x1	-1.0540	0.343	-3.0760	2.10e-03
Log(scale)	-0.0127	0.135	-0.0942	9.25e-01

```
Scale= 0.987
```

```
Log Normal distribution
```

```
Loglik(model)= -110.9509 Loglik(intercept only)= -115.4
```

```
Chisq= 8.88 on 1 degrees of freedom, p= 0.0029
```

```
Number of Newton-Raphson Iterations: 4
```

```
n= 42
```

Código em R e Saída: Fator de aceleração

O fator de aceleração estimada comparando $x = 2$ (alta contagem) e $x = 1$ (contagem média) é agora:

$$\hat{\gamma} = \exp\{-\hat{\beta}_1\} = 0,35$$

```
> exp(fit.ln$coefficient[2])  
x1  
0.3485551
```

$$\implies, S_1(t) = S_2(0.35t)$$

Interpretação

O tempo de sobrevivência para o grupo com alta contagem ($x = 2$) é "Acelerada" por um factor de 0,35 em comparação com o grupo com contagem média ($x = 1$). Então x elevado tem efeito negativo no tempo mediano.

Modelando o parâmetro de forma

Muitos modelos paramétricos contem um parâmetro de forma, que é geralmente considerado fixo

Exemplo

1. O modelo Weibull

Relembre $h(t) = \alpha \lambda t^{\alpha-1}$, onde $\lambda = \exp\{b_0 + b_1 TRAT\}$ e α parâmetro de forma não é afetado por covariável.

2. Alternativamente o modelo Weibull $h(t) = \alpha \lambda t^{\alpha-1}$, onde $\lambda = \exp\{b_0 + b_1 TRAT\}$ e $\alpha = \exp\{\delta_0 + \delta_1 TRAT\}$.

- ▶ Se $\delta_1 \neq 0$ o valor de α difere para TRT.
- ▶ Se $\delta_1 \neq 0$ o modelo não é TFA e RP.

Critérios de seleção de modelos

- ▶ Ao selecionarmos modelos é preciso ter em mente que não existem modelos verdadeiros. Há apenas modelos aproximados da realidade.
- ▶ Deste modo, é necessário fazer a seleção do ?melhor? modelo, dentre aqueles que foram ajustados, para explicar o fenômeno sob estudo.
- ▶ Akaike (1974) utilizou a Informação de Kullback-Leibler para testar se um dado modelo é adequado.

Critério de informação de Akaike - AIC

O AIC é definido por

$$AIC = -2\ell(\hat{\theta}) + 2p$$

onde $\ell(\cdot)$ é a log-verossimilhança e p número de parâmetros do modelo.

Critérios de seleção de modelos

Critério de informação bayesiano - BIC

O BIC proposto por Schwarz (1978) é definido por

$$BIC = -2\ell(\hat{\theta}) + p \log n$$

onde $\ell(\cdot)$ é a log-verossimilhança e p número de parâmetros do modelo e n tamanho da amostra.

O melhor modelo é aquele AIC ou BIC com menor valor.

Comparação entre os modelos TFA log-logístico e log-normal

Na Tabela apresenta-se as estatísticas AIC e BIC para os dados de leucemia.

	AIC	BIC
log-logístico	226.42	306.42
log-normal	225.90	305.90

Ambos critérios indicam o modelo log-normal que ajusta melhor os dados de leucemia.

Exercícios

1. Ajuste os modelos de TFA e de PO log-logístico aos dados de leucemia com as duas covariáveis, interprete os parâmetros em termos do problema e faça um estudo de adequabilidade do modelo.
2. Ajuste o modelo de TFA log-normal aos dados de leucemia com as duas covariáveis interprete os parâmetros em termos do problema e faça um estudo de adequabilidade do modelo.