

Inferência em Análise de Sobrevivência

Adaptado de material do
Prof. Vicente G. Cancho (ICMC/USP)

Departamento de Matemática Aplicada e Estatística
Universidade de São Paulo

2023

Inferência em Análise de Sobrevida

T_1, \dots, T_n é uma amostra aleatória de uma população com f.d.p. $f(t; \theta)$, em que $\theta \in \Theta \subset \mathbb{R}^p$.

Inferência em Análise de Sobrevida

T_1, \dots, T_n é uma amostra aleatória de uma população com f.d.p. $f(t; \boldsymbol{\theta})$, em que $\boldsymbol{\theta} \in \Theta \subset \mathbb{R}^p$. A distribuição de $f(t; \boldsymbol{\theta})$ é completamente determinada por $\boldsymbol{\theta}$. Por exemplo, se T tem distribuição log-normal, então a f.d.p. é dada por

$$f(t; \boldsymbol{\theta}) = \frac{1}{\sqrt{2\pi}\sigma t} \exp\left\{-\frac{(\log(t) - \mu)^2}{\sigma^2}\right\}$$

e $\boldsymbol{\theta} = (\mu, \sigma^2)^\top$ é o vetor de parâmetros da distribuição log-normal.

Inferência em Análise de Sobrevida

T_1, \dots, T_n é uma amostra aleatória de uma população com f.d.p. $f(t; \theta)$, em que $\theta \in \Theta \subset \mathbb{R}^p$. A distribuição de $f(t; \theta)$ é completamente determinada por θ . Por exemplo, se T tem distribuição log-normal, então a f.d.p. é dada por

$$f(t; \theta) = \frac{1}{\sqrt{2\pi}\sigma t} \exp\left\{-\frac{(\log(t) - \mu)^2}{\sigma^2}\right\}$$

e $\theta = (\mu, \sigma^2)^\top$ é o vetor de parâmetros da distribuição log-normal. A função verossimilhança de θ dada a amostra observada $\mathbf{t} = (t_1, \dots, t_n)^\top$ é

$$L(\theta) = \prod_{i=1}^n \frac{1}{\sqrt{2\pi}\sigma t_i} \exp\left\{-\frac{(\log(t_i) - \mu)^2}{\sigma^2}\right\}$$

Inferência em Análise de Sobrevida

Em geral, a função verossimilhança é dada por

$$L(\boldsymbol{\theta}) = \prod_{i=1}^n f(t_i; \boldsymbol{\theta}).$$

Inferência em Análise de Sobrevida

Em geral, a função verossimilhança é dada por

$$L(\boldsymbol{\theta}) = \prod_{i=1}^n f(t_i; \boldsymbol{\theta}).$$

A função log-verossimilhança é dada por

$$\ell(\boldsymbol{\theta}) = \log(L(\boldsymbol{\theta})) = \sum_{i=1}^n \log(f(t_i; \boldsymbol{\theta})).$$

Inferência em Análise de Sobrevida

Os estimadores de máxima verossimilhança (EMV) de μ e σ^2 resultam de maximizar a função log-verossimilhança, $\ell(\boldsymbol{\theta})$. Em várias situações, a maximização equivale a resolver as equações de estimação

$$\mathbf{U}(\boldsymbol{\theta}) = \frac{\partial \ell(\boldsymbol{\theta})}{\partial \boldsymbol{\theta}} = \sum_{i=1}^n \frac{\partial \log(f(x_i; \boldsymbol{\theta}))}{\partial \boldsymbol{\theta}} = \mathbf{0}, \quad (1)$$

em que $\mathbf{U}(\boldsymbol{\theta}) = (U_1(\boldsymbol{\theta}), \dots, U_p(\boldsymbol{\theta}))^\top$ é o vetor escore com componentes $U_j(\boldsymbol{\theta}) = \frac{\partial \ell(\boldsymbol{\theta})}{\partial \theta_j}$, $j = 1, \dots, p$.

Inferência em Análise de Sobrevida

Usualmente, o EMV de $\hat{\theta}$, denotado por $\hat{\theta}$, não tem forma fechada. Nesse caso, é necessário algum procedimento iterativo, tal como o algoritmo de Newton-Rapson. O EMV de θ depende de $\mathbf{T} = (T_1, \dots, T_n)^\top$, e, portanto é uma estatística que tem uma distribuição amostral.

Inferência em Análise de Sobrevida

Usualmente, o EMV de $\hat{\theta}$, denotado por $\hat{\theta}$, não tem forma fechada. Nesse caso, é necessário algum procedimento iterativo, tal como o algoritmo de Newton-Rapson. O EMV de θ depende de $\mathbf{T} = (T_1, \dots, T_n)^\top$, e, portanto é uma estatística que tem uma distribuição amostral. Para amostras suficientemente grandes, o EMV $\hat{\theta}$ tem distribuição normal com vetor de médias θ e matriz de covariâncias \mathbf{C} , isto é,

$$\hat{\theta} \sim N_p(\theta, \mathbf{C}),$$

em que $\mathbf{C} = \mathbf{I}^{-1}(\theta)$ ou $\mathbf{C} = \mathbf{I}_0^{-1}(\theta)$ e

$$\mathbf{I}(\theta) = -E \left[\frac{\partial^2 \ell(\theta)}{\partial \theta \partial \theta^\top} \right] = \sum_{i=1}^n -E \left[\frac{\partial^2 \log(f(x_i; \theta))}{\partial \theta \partial \theta^\top} \right]$$

é a matriz de informação de Fisher (ou matriz de informação esperada).

Inferência em Análise de Sobrevida

e

$$I_0(\boldsymbol{\theta}) = -\frac{\partial^2 \ell(\boldsymbol{\theta})}{\partial \boldsymbol{\theta} \partial \boldsymbol{\theta}^T} = -\sum_{i=1}^n \frac{\partial^2 \log(f(x_i; \boldsymbol{\theta}))}{\partial \boldsymbol{\theta} \partial \boldsymbol{\theta}^T}$$

é a matriz de informação observada. Podemos utilizar $I(\boldsymbol{\theta})$ e/ou $I_0(\boldsymbol{\theta})$ na construção de regiões de confiança aproximadas para os parâmetros de interesse.

Inferência em Análise de Sobrevida

e

$$I_0(\boldsymbol{\theta}) = -\frac{\partial^2 \ell(\boldsymbol{\theta})}{\partial \boldsymbol{\theta} \partial \boldsymbol{\theta}^T} = -\sum_{i=1}^n \frac{\partial^2 \log(f(x_i; \boldsymbol{\theta}))}{\partial \boldsymbol{\theta} \partial \boldsymbol{\theta}^T}$$

é a matriz de informação observada. Podemos utilizar $I(\boldsymbol{\theta})$ e/ou $I_0(\boldsymbol{\theta})$ na construção de regiões de confiança aproximadas para os parâmetros de interesse.

Tomamos $\boldsymbol{\theta} = (\boldsymbol{\theta}_1^T, \boldsymbol{\theta}_2^T)^T$, em que $k \leq p$ é a dimensão de $\boldsymbol{\theta}_1$. Estamos interessados em testar

$$H_0 : \boldsymbol{\theta}_1 = \boldsymbol{\theta}_{10} \text{ versus } H_1 : \boldsymbol{\theta}_1 \neq \boldsymbol{\theta}_{10}.$$

Sob certas condições de regularidade, as seguintes estatísticas podem ser usadas para testar H_0 .

Teste de Wald

Suponha a partição de $\hat{\boldsymbol{\theta}}$ e \mathbf{C}

$$\hat{\boldsymbol{\theta}} = \begin{pmatrix} \hat{\boldsymbol{\theta}}_1 \\ \hat{\boldsymbol{\theta}}_2 \end{pmatrix} \text{ e } \mathbf{C} = \begin{bmatrix} \mathbf{C}_{11} & \mathbf{C}_{12} \\ \mathbf{C}_{12}^\top & \mathbf{C}_{22} \end{bmatrix}.$$

Teste de Wald

Suponha a partição de $\hat{\boldsymbol{\theta}}$ e \mathbf{C}

$$\hat{\boldsymbol{\theta}} = \begin{pmatrix} \hat{\boldsymbol{\theta}}_1 \\ \hat{\boldsymbol{\theta}}_2 \end{pmatrix} \text{ e } \mathbf{C} = \begin{bmatrix} \mathbf{C}_{11} & \mathbf{C}_{12} \\ \mathbf{C}_{12}^\top & \mathbf{C}_{22} \end{bmatrix}.$$

Sob H_0 ,

$$W = \left(\hat{\boldsymbol{\theta}}_1 - \boldsymbol{\theta}_{10} \right)^\top \mathbf{C}_{11}^{-1} \left(\hat{\boldsymbol{\theta}}_1 - \boldsymbol{\theta}_{10} \right) \xrightarrow{D} \chi_k^2.$$

Portanto, rejeitamos H_0 se $W > \chi_{k,1-\alpha}^2$, em que $\chi_{k,1-\alpha}^2$ é $(1 - \alpha)$ -ésimo quantil da distribuição χ_k^2 .

Teste escore

Considere a partição do vetor escore $\mathbf{U}(\boldsymbol{\theta}) = (\mathbf{U}_1(\boldsymbol{\theta})^\top, \mathbf{U}_2(\boldsymbol{\theta})^\top)^\top$ e seja $\tilde{\boldsymbol{\theta}}_2$ o EMV de $\boldsymbol{\theta}_2$ sob $H_0 : \boldsymbol{\theta}_1 = \boldsymbol{\theta}_{10}$.

Teste escore

Considere a partição do vetor escore $\mathbf{U}(\boldsymbol{\theta}) = (\mathbf{U}_1(\boldsymbol{\theta})^\top, \mathbf{U}_2(\boldsymbol{\theta})^\top)^\top$ e seja $\tilde{\boldsymbol{\theta}}_2$ o EMV de $\boldsymbol{\theta}_2$ sob $H_0 : \boldsymbol{\theta}_1 = \boldsymbol{\theta}_{10}$. Sob H_0 ,

$$S = \mathbf{U}_1^\top \mathbf{C}_{11} \mathbf{U}_1 \xrightarrow{D} \chi_k^2,$$

em que \mathbf{U}_1 e \mathbf{C}_{11} são calculados com $\boldsymbol{\theta} = (\boldsymbol{\theta}_{10}^\top, \tilde{\boldsymbol{\theta}}_2^\top)^\top$. Rejeita-se H_0 se $S > \chi_{k,1-\alpha}^2$.

Teste da razão de verossimilhanças

Sob H_0 , a estatística

$$RV = -2 \left(\ell(\tilde{\theta}) - \ell(\hat{\theta}) \right) \xrightarrow{D} \chi_k^2,$$

em que $\tilde{\theta} = (\theta_{10}^\top, \tilde{\theta}_2^\top)^\top$ é o EMV de θ sob H_0 e $\hat{\theta}$ é o EMV de θ irrestrito ($\theta \in \Theta$). Rejeita-se H_0 se $RV > \chi_{k,1-\alpha}^2$

Exemplo (Teste escore)

Os dados abaixo são referentes aos tempos de sobrevivência (em dias) de 25 pacientes com câncer de pulmão terminal.

139	304	193	248	27	210	134	203	724
50	511	22	561	580	136	308	224	482
191	144	68	683	256	441	101		

A distribuição Weibull com função de risco, $h(t) = \alpha\lambda t^{\alpha-1}$, $\alpha > 0$ e $\lambda > 0$, será utilizada

A distribuição Weibull com função de risco, $h(t) = \alpha\lambda t^{\alpha-1}$, $\alpha > 0$ e $\lambda > 0$, será utilizada (como verificar se a distribuição Weibull faz um bom ajuste?).

Temos interesse em testar as seguintes hipóteses: $H_0 : \alpha = 1$ versus $H_1 : \alpha \neq 1$.

A função verossimilhança de $\boldsymbol{\theta} = (\alpha, \lambda)^\top$ é dada por

$$\begin{aligned} L(\boldsymbol{\theta}) &= \prod_{i=1}^n \alpha \lambda t_i^{\alpha-1} \exp(-\lambda t_i^\alpha) \\ &= \alpha^n \lambda^n \left(\prod_{i=1}^n t_i \right)^{\alpha-1} \exp\left(-\lambda \sum_{i=1}^n t_i^\alpha\right). \end{aligned}$$

A distribuição Weibull com função de risco, $h(t) = \alpha\lambda t^{\alpha-1}$, $\alpha > 0$ e $\lambda > 0$, será utilizada (como verificar se a distribuição Weibull faz um bom ajuste?).

Temos interesse em testar as seguintes hipóteses: $H_0 : \alpha = 1$ versus $H_1 : \alpha \neq 1$.

A função verossimilhança de $\theta = (\alpha, \lambda)^\top$ é dada por

$$\begin{aligned} L(\theta) &= \prod_{i=1}^n \alpha \lambda t_i^{\alpha-1} \exp(-\lambda t_i^\alpha) \\ &= \alpha^n \lambda^n \left(\prod_{i=1}^n t_i \right)^{\alpha-1} \exp\left(-\lambda \sum_{i=1}^n t_i^\alpha\right). \end{aligned}$$

Portanto, a função log-verossimilhança é dada por

$$\ell(\theta) = n \log(\lambda) + n \log(\alpha) - \lambda \sum_{i=1}^n t_i^\alpha + (\alpha - 1) \sum_{i=1}^n \log(t_i).$$

Assim, os componentes do vetor escore são

$$\begin{aligned}\frac{\partial \ell(\boldsymbol{\theta})}{\partial \alpha} &= \frac{n}{\alpha} - \lambda \sum_{i=1}^n t_i^\alpha \log(t_i) + \sum_{i=1}^n \log(t_i) \quad \text{e} \\ \frac{\partial \ell(\boldsymbol{\theta})}{\partial \lambda} &= \frac{n}{\lambda} - \sum_{i=1}^n t_i^\alpha.\end{aligned}\tag{2}$$

Assim, os componentes do vetor escore são

$$\begin{aligned}\frac{\partial \ell(\boldsymbol{\theta})}{\partial \alpha} &= \frac{n}{\alpha} - \lambda \sum_{i=1}^n t_i^\alpha \log(t_i) + \sum_{i=1}^n \log(t_i) \quad \text{e} \\ \frac{\partial \ell(\boldsymbol{\theta})}{\partial \lambda} &= \frac{n}{\lambda} - \sum_{i=1}^n t_i^\alpha.\end{aligned}\tag{2}$$

Os elementos da matriz de derivadas segundas são dados por

$$\begin{aligned}\frac{\partial^2 \ell(\boldsymbol{\theta})}{\partial \alpha^2} &= -\frac{n}{\alpha^2} - \lambda \sum_{i=1}^n t_i^\alpha \log(t_i)^2, \\ \frac{\partial^2 \ell(\boldsymbol{\theta})}{\partial \alpha \partial \lambda} &= -\sum_{i=1}^n t_i^\alpha \log(t_i) \quad \text{e} \\ \frac{\partial^2 \ell(\boldsymbol{\theta})}{\partial \lambda^2} &= -\frac{n}{\lambda^2}.\end{aligned}\tag{3}$$

O EMV de λ sob H_0 é dado por $\tilde{\lambda} = n / \sum_{i=1}^n t_i$.

No exemplo, temos $n = 25$, $\sum_{i=1}^n t_i = 6940$,

$\sum_{i=1}^n \log(t_i) = 132,2484$, $\sum_{i=1}^n t_i \log(t_i) = 40870,27$ e

$\sum_{i=1}^n t_i [\log(t_i)]^2 = 243502,91$ Portanto, a estimativa de máxima verossimilhança é dada por $\tilde{\lambda} = 25/6940 = 0,0036023$, de modo que

$$\begin{aligned} U_1 &= n - \tilde{\lambda} \sum_{i=1}^n t_i \log(t_i) + \sum_{i=1}^n \log(t_i) \\ &= 25 - (0,0036023)(40870,27) + 132,2484 \\ &= 10. \end{aligned}$$

A matriz de informação observada e sua inversa são dadas por

$$I_0 = \begin{bmatrix} 902,17186 & 40870,268 \\ 40870,268 & 1926544 \end{bmatrix} \text{ e } \mathbf{C} = I_0^{-1} = \begin{bmatrix} 0,0284592 & 0,000604 \\ 0,000604 & 0,0000133 \end{bmatrix}.$$

Assim, a estatística escore resulta em

$$S = U_1 C_{11} U_1 = 10 \times 0,0284592 \times 10 = 2,8$$

e o valor- p do teste é

$$P(\chi_1^2 > 2,8) = 0,094.$$

A matriz de informação observada e sua inversa são dadas por

$$I_0 = \begin{bmatrix} 902,17186 & 40870,268 \\ 40870,268 & 1926544 \end{bmatrix} \text{ e } \mathbf{C} = I_0^{-1} = \begin{bmatrix} 0,0284592 & 0,000604 \\ 0,000604 & 0,0000133 \end{bmatrix}.$$

Assim, a estatística escore resulta em

$$S = U_1 C_{11} U_1 = 10 \times 0,0284592 \times 10 = 2,8$$

e o valor- p do teste é

$$P(\chi_1^2 > 2,8) = 0,094.$$

Com 5% de nível de significância, não rejeitamos H_0 , o que implica que os dados podem ser ajustados pela distribuição exponencial.

A função verossimilhança para dados censurados à direita

- Suponha que temos uma amostra aleatória de indivíduos de tamanho n de uma população específica cujos tempos de sobrevivência são, T_1, \dots, T_n .

¹Também chamado de indicador de censura.

A função verossimilhança para dados censurados à direita

- Suponha que temos uma amostra aleatória de indivíduos de tamanho n de uma população específica cujos tempos de sobrevivência são, T_1, \dots, T_n .
- No entanto, devido à censura à direita, o tempo de sobrevivência pode não ser observado. Denote por C_1, \dots, C_n os (potenciais) tempos de censura.

¹Também chamado de indicador de censura.

A função verossimilhança para dados censurados à direita

- Suponha que temos uma amostra aleatória de indivíduos de tamanho n de uma população específica cujos tempos de sobrevivência são, T_1, \dots, T_n .
- No entanto, devido à censura à direita, o tempo de sobrevivência pode não ser observado. Denote por C_1, \dots, C_n os (potenciais) tempos de censura.
- Dados observados: $t_i = \min(T_i, C_i)$ e o indicador de falha¹ δ_i ,

$$\delta_i = \begin{cases} 1, & \text{se } T_i \leq C_i, \\ 0, & \text{se } T_i > C_i. \end{cases}$$

¹Também chamado de indicador de censura.

- Se a f.d.p de T é $f(t; \theta)$, com $\theta \in \Theta \subset R^p$ e a função sobrevivência de T é $S(t; \theta)$, a função de verossimilhança de θ é dada por

- Se a f.d.p de T é $f(t; \theta)$, com $\theta \in \Theta \subset R^p$ e a função sobrevivência de T é $S(t; \theta)$, a função de verossimilhança de θ é dada por

$$L(\theta) \propto \prod_{i=1}^n [f(t_i; \theta)]^{\delta_i} [S(t_i; \theta)]^{1-\delta_i} \quad (4)$$

Alternativamente,

$$L(\theta) \propto \prod_{i=1}^n [h(t_i; \theta)]^{\delta_i} S(t_i; \theta)$$

em que $h(t; \theta) = \frac{f(t; \theta)}{S(t; \theta)}$.

- Se a f.d.p de T é $f(t; \theta)$, com $\theta \in \Theta \subset R^p$ e a função sobrevivência de T é $S(t; \theta)$, a função de verossimilhança de θ é dada por

$$L(\theta) \propto \prod_{i=1}^n [f(t_i; \theta)]^{\delta_i} [S(t_i; \theta)]^{1-\delta_i} \quad (4)$$

Alternativamente,

$$L(\theta) \propto \prod_{i=1}^n [h(t_i; \theta)]^{\delta_i} S(t_i; \theta)$$

em que $h(t; \theta) = \frac{f(t; \theta)}{S(t; \theta)}$.

- A função de verossimilhança dada em (4) pode ser representando por

$$L(\theta) \propto \prod_{i \in F} f(t_i; \theta) \prod_{i \in C} S(t_i; \theta),$$

em que F é o conjunto de tempos não censurados (falhas) e C é o conjunto de tempos censurados.

Exemplo 1. Dados censurados

Os dados abaixo correspondem aos tempos de sobrevivência (em meses) de pacientes com certa doença.

3	5	6 ⁺	8	10 ⁺	11 ⁺	15	20 ⁺	22	23
29	32	35	40	26	28	33 ⁺	21	24 ⁺	27 ⁺

+ indica o dado censurado.

Assumindo que os tempos de sobrevivência tem taxa de falha constante, $\lambda > 0$. Estimar pontualmente e por intervalo: (a) o tempo mediano, (b) a proporção de pacientes com tempos de sobrevivência mais de 10 meses.

- A função de taxa de falha e a função de sobrevivência são dados por $h(t; \lambda) = \lambda$ e $S(t; \lambda) = e^{-\lambda t}$ respectivamente.
- A função de sobrevivência de λ dado os dados observados é dado por

$$L(\lambda) = \prod_{i=1}^n \lambda^{\delta_i} e^{-\lambda t_i} = \lambda^r e^{-\lambda \sum_{i=1}^n t_i}$$

onde $r = \sum_{i=1}^n \delta_i$ é número observações de tempos de sobrevivência.

- De modo que a função log-verossimilhança é dado por

$$\ell(\lambda) = r \log(\lambda) - \lambda \sum_{i=1}^n t_i.$$

- A equação de estimação é

$$U(\lambda) = \frac{r}{\lambda} - \sum_{i=1}^n t_i = 0$$

- Portanto, o EMV de λ é dado por

$$\hat{\lambda} = \frac{r}{\sum_{i=1}^n t_i}$$

Um vez que

$$\frac{\partial U(\lambda)}{\partial \lambda} = -\frac{r}{\lambda^2},$$

a informação de Fisher é

$$I(\lambda) = E \left[-\frac{\partial U(\lambda)}{\partial \lambda} \right] = \frac{E(r)}{\lambda^2} = \frac{\sum_{i=1}^n E(\delta_i)}{\lambda^2} = \frac{\sum_{i=1}^n P(T_i \leq C_i)}{\lambda^2}.$$

- Sob censura tipo I, a informação de Fisher é dada por

$$I(\lambda) = \frac{\sum_{i=1}^n (1 - e^{-\lambda c_i})}{\lambda^2}$$

- A informação observada é dada por

$$I_0(\lambda) = \frac{r}{\lambda^2}$$

- A estimativa da variância de $\hat{\lambda}$ é

$$\widehat{\text{Var}}(\hat{\lambda}) = I_0^{-1}(\hat{\lambda}) = \frac{r}{[\sum_{i=1}^n t_i]^2} = \frac{\hat{\lambda}^2}{r}$$

- Assintoticamente,

$$\hat{\lambda} \overset{a}{\sim} N\left(\lambda, \frac{\lambda^2}{r}\right)$$

- Um intervalo de 95% de confiança para λ é dado por:

$$\left(\hat{\lambda} - 1,96 \times \frac{\hat{\lambda}}{\sqrt{r}}; \hat{\lambda} + 1,96 \times \frac{\hat{\lambda}}{\sqrt{r}}\right)$$

- Algumas vezes a distribuição exponencial é parametrizada na média, $E(T) = \theta = 1/\lambda$. O EMV de θ é

$$\hat{\theta} = \frac{\sum_{i=1}^n t_i}{\sum_{i=1}^n \delta_i},$$

Assintoticamente,

$$\hat{\theta} \stackrel{a}{\sim} N\left(\theta, \frac{\hat{\theta}^2}{r}\right)$$

- Se os dados são não censurados, $\delta_i = 1$, $i = 1, \dots, n$ então

$$\hat{\theta} = \frac{\sum_{i=1}^n t_i}{n} = \bar{t},$$

- Para os dados do exemplo, temos: $r = 13$ e $\sum_{i=1}^n t_i = 418$. Portanto,

$$\hat{\lambda} = \frac{r}{\sum_{i=1}^n t_i} = \frac{13}{408} = 0,0311,$$


- O erro padrão

$$EP(\hat{\lambda}) = \frac{\hat{\lambda}}{\sqrt{r}} = \frac{0,0311}{\sqrt{13}} = 0,0086$$

- Um intervalo de 95% de confiança para λ é dado por:

$$\begin{aligned} &(\hat{\lambda} - 1,96 \times EP(\hat{\lambda}); \hat{\lambda} + 1,96 \times EP(\hat{\lambda})) = \\ &(0,0311 - 1,96 \times 0,0086; 0,0311 + 1,96 \times 0,0086) = \\ &(0,0142; 0,0480) \end{aligned}$$

Gráfico da estimativa da função de sobrevivência



Obviamente, a distribuição exponencial é um ajuste inadequado. Neste caso, podemos escolher um dos seguintes opções

- 1 Escolha um modelo mais flexível, como o modelo de Weibull.
- 2 Considerar o estimador de Kaplan-Meier que não faz qualquer hipótese quanto à forma da distribuição.
- 3 Na maioria das aplicações biomédicas, é considerado o estimador de Kaplan-Meier.

Modelo Weibull

Uma v.a. T tem a distribuição Weibull parâmetros $\lambda > 0$ (escala) e $\alpha > 0$ (forma) se sua f.d.p dada por

$$f(t; \alpha, \beta) = \alpha \lambda t^{\alpha-1} e^{-\lambda t^\alpha}, \quad t > 0 \quad (5)$$

A função de sobrevivência e função de riscos são dada por,

$$S(t; \alpha, \beta) = e^{-\lambda t^\alpha}, \quad t > 0 \quad (6)$$



e

$$h(t; \alpha, \beta) = \alpha \lambda t^{\alpha-1}, \quad t > 0 \quad (7)$$

A forma da função de risco tem as seguintes formas:

- Se $\alpha = 1$ a função de risco é constante (distribuição exponencial)
- Se $\alpha < 1$ a função de risco é decrescente,
- Se $\alpha > 1$ a função de risco é crescente.

Gráfico da f.d.p e função de sobrevivência da distribuição Weibull



Momentos e a função quantil do modelo Weibull

- O k -ésimo momento é dada por

$$E[T^k] = \lambda^{-k/\alpha} \Gamma\left(\frac{k}{\alpha} + 1\right)$$

- Média e variância

$$E(T) = \lambda^{-1/\alpha} \Gamma\left(\frac{1}{\alpha} + 1\right), \quad \text{Var}(T) = \lambda^{-2/\alpha} \left[\Gamma\left(\frac{2}{\alpha} + 1\right) - \Gamma^2\left(\frac{1}{\alpha} + 1\right) \right]$$

- O p -ésimo quantil, denotado por t_p

$$t_p = \lambda^{-1/\alpha} [-\log(1 - p)]^{1/\alpha}, \quad 0 < p < 1.$$

- A mediana, $md = t_{0,5}$

$$t_{0,5} = \lambda^{-1/\alpha} [\log(2)]^{1/\alpha}.$$

Adequação do modelo Weibull

- O $\log(-\log(S(t)))$ é linear em relação a $\log(t)$.

$$\begin{aligned} S(t) = e^{-\lambda t^\alpha}, &\implies -\log(S(t)) = \lambda t^\alpha \\ &\implies \log(-\log(S(t))) = \log(\lambda) + \alpha \log(t). \end{aligned}$$

- Esta propriedade permite uma avaliação gráfica da adequação de um modelo Weibull plotando

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

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


Exemplo 2: Dados leucemia

Os dados abaixo representam tempos de remissão (em meses) do câncer (leucemia aguda) de 42 crianças tratadas com:6-mercaptopurine (6-MP) ou placebo.

Placebo	1	22	3	12	8	17	2	11	8	12	2
	5	4	15	8	23	5	11	4	1	8	
6-MP	10	7	32 ⁺	23	22	6	16	34 ⁺	32 ⁺	25 ⁺	11 ⁺
	20 ⁺	19 ⁺	6	17 ⁺	35 ⁺	6	13	9 ⁺	6 ⁺	10 ⁺	

+ : indica tempo censurado.

Gráfico de $\log(-\log(\widehat{S}(t)))$ versus $\log(t)$
para os dados de leucemia.



- ▷ Linhas retas: modelo Weibull.
- ▷ Retas paralelas: riscos proporcionais (RP).

Modelo Weibull-RP

- Relembre que $h(t) = \alpha\lambda t^\alpha$.
- Modelo Weibull-RP
 - Tomamos $\lambda = \exp(\beta_0 + \beta_1 x)$ (modelo para λ).
 - A razão de riscos ($x = 1$ para 6-MP *versus* $x = 0$ para placebo) é

$$RR(t) = \frac{\exp(\beta_0 + \beta_1)\alpha t^\alpha}{\exp(\beta_0)\alpha t^\alpha} = \exp(\beta_1),$$

que indica que a propriedade de RP é satisfeita.

- Neste resultado, α é o mesmo valor para 6-MP e placebo.

Inferência no modelo Weibull com dados censurados

A função verossimilhança de $\boldsymbol{\theta} = (\alpha, \lambda)^\top$ é dada por

$$\begin{aligned} L(\boldsymbol{\theta}) &= \prod_{i=1}^n [\alpha \lambda t_i^{\alpha-1}]^{\delta_i} \exp\{-\lambda t_i^\alpha\} \\ &= \alpha^r \lambda^r \exp\left\{-\lambda \sum_{i=1}^n t_i^\alpha + (\alpha - 1) \sum_{i=1}^n \delta_i \log(t_i)\right\} \end{aligned}$$

em que $t_i = \min(T_i, C_i)$ $i = 1, \dots, n$ e δ_i é o indicador de falha, isto é,

$$\delta_i = \begin{cases} 1, & \text{se } T_i \leq C_i, \\ 0, & \text{se } T_i > C_i. \end{cases}$$

Portanto, a função log-verossimilhança é dada por

$$\ell(\boldsymbol{\theta}) = r \log(\lambda) + r \log(\alpha) - \lambda \sum_{i=1}^n t_i^\alpha + (\alpha - 1) \sum_{i=1}^n \delta_i \log(t_i).$$

Assim, os componentes do escore são

$$\begin{aligned}\frac{\partial \ell(\boldsymbol{\theta})}{\partial \alpha} &= \frac{r}{\alpha} - \lambda \sum_{i=1}^n t_i^\alpha \log(t_i) + \sum_{i=1}^n \delta_i \log(t_i) \text{ e} \\ \frac{\partial \ell(\boldsymbol{\theta})}{\partial \lambda} &= \frac{r}{\lambda} - \sum_{i=1}^n t_i^\alpha,\end{aligned}\tag{8}$$

e os elementos da matriz de derivadas segundas são dados por

$$\begin{aligned}\frac{\partial^2 \ell(\boldsymbol{\theta})}{\partial \alpha^2} &= -\frac{r}{\alpha^2} - \lambda \sum_{i=1}^n t_i^\alpha \log(t_i)^2, \\ \frac{\partial \ell(\boldsymbol{\theta})}{\partial \alpha \partial \lambda} &= -\sum_{i=1}^n t_i^\alpha \log(t_i) \text{ e} \\ \frac{\partial \ell(\boldsymbol{\theta})}{\partial \lambda^2} &= -\frac{r}{\lambda^2}.\end{aligned}\tag{9}$$

- As estimativas de MV são $\hat{\alpha} = 2,14943$ e $\hat{\lambda} = 0,00072$.
- A matriz de informação observada e sua inversa são dadas por

$$I_0 = \begin{bmatrix} 149,3758 & 60466,06 \\ 60466,0604 & 25148299,99 \end{bmatrix}$$

e

$$C = I_0^{-1} = \begin{bmatrix} 0,2504761623 & -0,0006022398 \\ -0,0006022398 & 1,487777 \times 10^{-6} \end{bmatrix}.$$

- Erros padrão das EMV:

$$\text{ep}(\hat{\alpha}) = 0,502257493 \text{ e } \text{ep}(\hat{\lambda}) = 0,001224176.$$

- Intervalo de 95% de confiança (aproximado):

$$\hat{\alpha} \mp 1,96\text{EP}(\hat{\alpha}) = (1,165; 3,134), \quad \hat{\lambda} \mp 1,96\text{EP}(\hat{\lambda}) = (0; 0,00312).$$

Estimação pontual e intervalar do tempo mediano $t_{0,5}$

- Pelo princípio de invariância, o EMV de $t_{0,5} = \lambda^{-1/\alpha} [\log(2)]^{1/\alpha}$ é dado por $\widehat{t}_{0,5} = \widehat{\lambda}^{-1/\widehat{\alpha}} [\log(2)]^{1/\widehat{\alpha}}$.
- A variância de $\widehat{t}_{0,5}$ é obtida pelo método delta, a qual resulta em

$$\text{Var}(\widehat{t}_{0,5}) = \begin{pmatrix} \frac{\partial t_{0,5}}{\partial \alpha} \\ \frac{\partial t_{0,5}}{\partial \lambda} \end{pmatrix}^T \begin{bmatrix} \text{Var}(\widehat{\alpha}) & \text{Cov}(\widehat{\alpha}, \widehat{\lambda}) \\ \text{Cov}(\widehat{\alpha}, \widehat{\lambda}) & \text{Var}(\widehat{\lambda}) \end{bmatrix} \begin{pmatrix} \frac{\partial t_{0,5}}{\partial \alpha} \\ \frac{\partial t_{0,5}}{\partial \lambda} \end{pmatrix},$$

em que

$$\frac{\partial t_{0,5}}{\partial \alpha} = -\frac{1}{\alpha^2} \left(\frac{\log(2)}{\lambda} \right)^{\alpha-1} \log \left(\frac{\log(2)}{\lambda} \right) e$$

$$\frac{\partial t_{0,5}}{\partial \lambda} = -\frac{1}{\alpha \lambda} \left(\frac{\log(2)}{\lambda} \right)^{\alpha-1}.$$

Estimação pontual e intervalar do tempo mediano $t_{0,5}$

Obtemos

$$\begin{aligned} \text{Var}(\widehat{t_{0.5}}) &= \text{Var}(\widehat{\alpha}) \left(\frac{\partial t_{0.5}}{\partial \alpha} \right)^2 + 2\text{Cov}(\widehat{\alpha}, \widehat{\lambda}) \frac{\partial t_{0.5}}{\partial \alpha} \frac{\partial t_{0.5}}{\partial \lambda} \\ &\quad + \text{Var}(\widehat{\lambda}) \left(\frac{\partial t_{0.5}}{\partial \lambda} \right)^2. \end{aligned}$$

Erro padrão:

$$ep(\widehat{t_{0.5}}) = \sqrt{\text{Var}(\widehat{t_{0.5}})|_{\widehat{\alpha}, \widehat{\lambda}}}.$$

Intervalo de 95% de confiança para $t_{0.5}$ (aproximado):

$$\widehat{t_{0.5}} \mp 1,96ep(\widehat{t_{0.5}}).$$

Estimação pontual e intervalar do tempo mediano $t_{0,5}$

- Para o Exemplo 1, a EMV do tempo mediano é

$$\widehat{t}_{0,5} = \widehat{\lambda}^{-1/\widehat{\alpha}} [\log(2)]^{1/\widehat{\alpha}} = 0,0072^{-1/2,14943} [\log(2)]^{1/2,14943} = 24,5.$$

- A estimativa da variância de $\widehat{t}_{0,5}$ é dada por

$$\begin{aligned} \widehat{Var}(\widehat{t}_{0,5}) &= \begin{pmatrix} -36.36386 \\ -15816.09349 \end{pmatrix}^T \begin{bmatrix} 0.2505 & -0.0006 \\ -0.0006 & 1.488 \times 10^{-6} \end{bmatrix} \begin{pmatrix} -36.36386 \\ -15816.09349 \end{pmatrix} \\ &= 10,6707. \end{aligned}$$

- Intervalo de 95% de confiança para $t_{0,5}$ é dado por

$$\widehat{t}_{0,5} \mp 1,96 \text{ ep}(\widehat{t}_{0,5}) = 24,5 \mp 1,96 \sqrt{10,6707} = (18,048; 30,853).$$

Estimação pontual e intervalar de $S(t_0)$

- Pelo princípio de invariância, o EMV de $S(t_0) = \exp\{-\lambda t_0^\alpha\}$ é dado por $\widehat{S}(t_0) = \exp\{-\widehat{\lambda} t_0^{\widehat{\alpha}}\}$.
- A variância de $\widehat{S}(t_0)$ é obtida pelo método delta, que resulta em

$$\text{Var}(\widehat{S}(t_0)) = \begin{pmatrix} \frac{\partial S(t_0)}{\partial \alpha} \\ \frac{\partial S(t_0)}{\partial \lambda} \end{pmatrix}^\top \begin{bmatrix} \text{Var}(\widehat{\alpha}) & \text{Cov}(\widehat{\alpha}, \widehat{\lambda}) \\ \text{Cov}(\widehat{\alpha}, \widehat{\lambda}) & \text{Var}(\widehat{\lambda}) \end{bmatrix} \begin{pmatrix} \frac{\partial S(t_0)}{\partial \alpha} \\ \frac{\partial S(t_0)}{\partial \lambda} \end{pmatrix}$$

em que

$$\begin{aligned} \frac{\partial S(t_0)}{\partial \alpha} &= -\lambda t_0^\alpha \log(t_0) e^{-\lambda t_0^\alpha} e \\ \frac{\partial S(t_0)}{\partial \lambda} &= -t_0^\alpha e^{-\lambda t_0^\alpha}. \end{aligned}$$

Estimação pontual e intervalar de $S(t_0)$

Variância de $\widehat{S}(t_0)$:

$$\begin{aligned} \text{Var}(\widehat{S}(t_0)) &= \text{Var}(\widehat{\alpha}) \left[\frac{\partial S(t_0)}{\partial \alpha} \right]^2 + 2\text{Cov}(\widehat{\alpha}, \widehat{\lambda}) \frac{\partial S(t_0)}{\partial \alpha} \frac{\partial S(t_0)}{\partial \lambda} \\ &\quad + \text{Var}(\widehat{\lambda}) \left[\frac{\partial S(t_0)}{\partial \lambda} \right]^2. \end{aligned}$$

Erro padrão:

$$ep(\widehat{S}(t_0)) = \sqrt{\text{Var}(\widehat{S}(t_0))|_{\widehat{\alpha}, \widehat{\lambda}}}.$$

Intervalo de 95% de confiança (aproximado) para $S(t_0)$:

$$\widehat{S}(t_0) \mp 1,96ep(\widehat{S}(t_0)).$$

Estimação pontual e intervalar de $S(t_0)$

- Para o Exemplo 1, estimar, a proporção de pacientes com tempos de sobrevivência maiores do que 10 meses, ou seja, $S(10) = \exp(-\lambda 10^\alpha)$. A EMV de $S(10)$ é $\widehat{S}(10) = \exp(-\widehat{\lambda} 10^{\widehat{\alpha}}) = \exp(-0,0072 \times 10^{2,14943}) = 0,904$.
- A estimativa da variância de $\widehat{S}(10)$ é dada por

$$\widehat{\text{Var}}(\widehat{S}(10)) = \begin{pmatrix} -0.2111 \\ -127.4430 \end{pmatrix}^\top \begin{bmatrix} 0.2505 & -0.0006 \\ -0.0006 & 1.488 \times 10^{-6} \end{bmatrix} \begin{pmatrix} -0.2111 \\ -127.4430 \end{pmatrix} \\ = 0.00294851.$$

- Intervalo de 95% de confiança para $S(10)$ (aproximado):

$$\widehat{S}(10) \mp 1,96ep(\widehat{S}(10)) = 0,904 \mp 1,96\sqrt{0.00294851} = (0,7972; 1,00).$$

Comparação entre a distribuição exponencial e distribuição Weibull

- Hipóteses”



$H_0 : \alpha = 1$ (Exponencial) versus $H_1 : \alpha \neq 1$ (Weibull).

Estatística de Wald:

$$W = \left(\frac{\hat{\alpha} - 1}{ep(\hat{\alpha})} \right)^2 = \left(\frac{2,14943 - 1}{0.502257493} \right)^2 = 5,274667.$$

- Já que valor- $p = P(\chi_1^2 > 5,27) = 0,022 < 0,05$, rejeita-se $H_0 : \alpha = 1$, isto é, rejeita-se a distribuição exponencial ao nível de significância de 5%.

Adequabilidade do modelo Weibull



- A inadequação do ajuste exponencial também é demonstrada no primeiro gráfico da Figura (panel esquerdo).
- Se o modelo exponencial modela-se bem os dados, todos os pontos (t vs $-\log(\widehat{S}(t))$) estariam acima da linha reta passando pela origem.
- Por outro lado, o plot na Figura (panel direito) mostra a adequação do modelo de Weibull, uma vez que a maioria dos pontos ($\log(t)$ vs $\log[-\log(\widehat{S}(t))]$) passam pela linha reta.
- Aqui $\widehat{S}(t)$ é o estimador de K-M de $S(t)$.

A distribuição valor extremo

- Se T tem distribuição Weibull com parâmetros α e λ e f.d.p. dada em (5) então a v.a. $Y = \log(T)$ tem distribuição valor extremo com a seguinte f.d.p.

$$f(y) = \frac{1}{\sigma} \exp \left\{ \left(\frac{y - \mu}{\sigma} \right) - \exp \left\{ \frac{y - \mu}{\sigma} \right\} \right\}, \quad y \in \mathbb{R}, \quad (10)$$

em que $\mu \in \mathbb{R}$ e $\sigma > 0$.

- Se $\mu = 0$ e $\sigma = 1$, tem-se a distribuição valor extremo padrão.
- Os parâmetros μ e σ são denominados parâmetros de localização e escala, respectivamente.
- Os parâmetros das distribuição de Weibull e valor extremo apresentam as seguintes relações:

$$\alpha = 1/\sigma, \quad e \quad \lambda = \exp(-\mu/\sigma)$$

A distribuição valor extremo

- As funções de sobrevivência e de taxa de risco da variável Y são dados por

$$S(y) = \exp \left\{ - \exp \left\{ \frac{y - \mu}{\sigma} \right\} \right\}, \quad (11)$$

e

$$h(y) = \frac{1}{\sigma} \exp \left\{ \left(\frac{y - \mu}{\sigma} \right) \right\}. \quad (12)$$

- A média e variância são respectivamente,

$$E(Y) = \mu - \nu\sigma, \quad \text{Var}(Y) = \frac{\pi^2}{6}\sigma^2.$$

onde $\nu = 0,3772$ é a constante de Euler.

- O p -ésimo quantil é dado por:

$$y_p = \mu + \sigma \log[-\log(1 - p)], \quad 0 < p < 1.$$

Observação

- A distribuição VE, tem a seguinte representação:

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

onde ε tem distribuição VE padrão, com f.d.p,

$$f(\varepsilon) = \exp\{\varepsilon - \exp\{\varepsilon\}\}$$

- A maioria dos pacotes computacionais tais como R ou SAS considera a distribuição Weibull com a seguinte função de sobrevivência

$$S(t) = \exp\left\{-\left(\frac{t}{\theta}\right)^\alpha\right\}$$

- Os parâmetros das distribuição de Weibull com parametrização acima e o valor extremo apresentam as seguintes relações de igualdade:

$$\alpha = 1/\sigma, \quad e \quad \theta = \exp(\mu)$$

Estimação dos parâmetros da distribuição a partir da distribuição valor extremo

A função de verossimilhança de μ e σ dado os dados observados

$$L(\mu, \sigma) = \prod_{i=1}^n \left[\frac{1}{\sigma} \exp \left\{ \left(\frac{y_i - \mu}{\sigma} \right) \right\} \right]^{\delta_i} \exp \left\{ - \exp \left\{ \frac{y_i - \mu}{\sigma} \right\} \right\},$$

onde $y_i = \log(t_i)$, $i = 1, \dots, n$.

A correspondente função log-verossimilhança é dada por

$$\ell(\mu, \sigma) = -r \log(\sigma) + \sum_{i=1}^n \delta_i z_i - \sum_{i=1}^n \exp \{z_i\}. \quad (13)$$

onde $z_i = \frac{y_i - \mu}{\sigma}$

Assim, os componentes do escore são

$$\begin{aligned}\frac{\partial \ell(\mu, \sigma)}{\partial \mu} &= -\frac{r}{\sigma} + \frac{1}{\sigma} \sum_{i=1}^n e^{z_i} \\ \frac{\partial \ell(\mu, \sigma)}{\partial \sigma} &= -\frac{r}{\sigma} - \frac{1}{\sigma} \sum_{i=1}^n \delta_i z_i + \frac{1}{\sigma} \sum_{i=1}^n z_i e^{z_i},\end{aligned}\tag{14}$$

e os elementos da matriz de derivadas segundas são

$$\begin{aligned}\frac{\partial^2 \ell(\mu, \sigma)}{\partial \mu^2} &= -\frac{1}{\sigma^2} \sum_{i=1}^n e^{z_i} \\ \frac{\partial^2 \ell(\mu, \sigma)}{\partial \mu \partial \sigma} &= \frac{r}{\sigma^2} - \frac{1}{\sigma^2} \sum_{i=1}^n e^{z_i} - \frac{1}{\sigma^2} \sum_{i=1}^n z_i e^{z_i} \\ \frac{\partial \ell(\mu, \sigma)}{\partial \sigma^2} &= \frac{1}{\sigma^2} \left[r - \sum_{i=1}^n \delta_i z_i - 2 \sum_{i=1}^n z_i e^{z_i} - \sum_{i=1}^n z_i^2 e^{z_i} \right]\end{aligned}\tag{15}$$

Ajuste dos dados Exemplo 1

- Com o a função `score` e a matriz de informação pode-se implementar o algoritmo de Newton-Rapson.
- O algoritmo está implementado na maioria dos pacotes estatísticos tais como R, Minitab, SAS, etc.
- A continuação o código no software R:
- $y =$
`c(3, 5, 6, 8, 10, 11, 15, 20, 22, 23, 27, 29, 32, 35, 40, 26, 28, 33, 21, 24)`
- $\delta =$
`c(1, 1, 0, 1, 0, 0, 1, 0, 1, 1, 0, 1, 1, 1, 1, 1, 0, 1, 0)`
- `fit1=survreg(Surv(y, delta) ~ 1, dist='weibull')`
- `summary(fit1)`

Ajuste dos dados Exemplo 1

Call:

```
survreg(formula = Surv(y, delta) ~ 1, dist = "weibull")
```

	Value	Std. Error	z	p-value
(Intercept)	3.367	0.129	26.07	7.36e-150
Log(scale)	-0.765	0.234	-3.27	1.06e-03

Scale= 0.465

Weibull distribution

Loglik(model)= -54.1 Loglik(intercept only)= -54.1

Number of Newton-Raphson Iterations: 7

n= 20

Ajuste dos dados Exemplo 1

Os parâmetros de escala (σ) e forma (α) das funções `rweibull`, `pweibull`, etc são dados por $\sigma = \exp(\text{Intercept})$ e $\alpha = 1/\text{Scale}$.

Na parametrização da eq. (7): $\lambda = 1/\sigma^\alpha$.

Fazendo $\mu = \text{Intercept}$ e $\sigma_* = \text{Log}(\text{scale})$, obtemos

$$\alpha = \frac{1}{\exp(\sigma_*)} \quad \text{e} \quad \lambda = e^{-\mu/\exp(\sigma_*)}.$$

Já que as EMV são $\hat{\mu} = 3,36717$ e

$\hat{\sigma} = \exp(\hat{\sigma}_*) = \exp(-0,765) = 0,46525$, as EMV de α e λ são

$$\hat{\alpha} = \frac{1}{0,465} = 2,149 \quad \text{e} \quad \hat{\lambda} = e^{-3.36717/0,465} = 0.00072.$$

O método delta é usado para calcular os erros padrão das EMV de α e λ .

Ajuste dos dados Exemplo 1

- α é função de σ_* , isto é, $\alpha = \frac{1}{\exp(\sigma_*)} = g_1(\sigma_*)$.

$$\text{Var}(\hat{\alpha}) = \left[\frac{\partial g_1(\sigma_*)}{\partial \sigma_*} \right]^2 \text{Var}(\hat{\sigma}_*) = \frac{\text{Var}(\hat{\sigma}_*)}{\exp(2\sigma_*)}.$$

- Eo erro padrão da EMV de α :

$$\text{ep}(\hat{\alpha}) = \frac{0,234}{\exp(-0,765)} = 0,50226.$$

- $\lambda = e^{-\mu/\exp\{\sigma_*\}} = g_2(\mu, \sigma_*)$ é função de μ e σ_* .

$$\text{Var}(\hat{\lambda}) = \begin{pmatrix} \frac{\partial g_2(\mu, \sigma_*)}{\partial \mu} \\ \frac{\partial g_2(\mu, \sigma_*)}{\partial \sigma_*} \end{pmatrix}^\top \begin{bmatrix} \text{Var}(\hat{\mu}) & \text{Cov}(\hat{\mu}, \hat{\sigma}_*) \\ \text{Cov}(\hat{\mu}, \hat{\sigma}_*) & \text{Var}(\hat{\sigma}_*) \end{bmatrix} \begin{pmatrix} \frac{\partial g_2(\mu, \sigma_*)}{\partial \mu} \\ \frac{\partial g_2(\mu, \sigma_*)}{\partial \sigma_*} \end{pmatrix}.$$

Ajuste dos dados do Exemplo 1

- Derivadas:

$$\frac{\partial g_2(\mu, \sigma_*)}{\partial \mu} = -e^{-\mu} e^{-\sigma_*} - \sigma_* e^{-\mu - \sigma_*}$$
$$\frac{\partial g_2(\mu, \sigma_*)}{\partial \sigma_*} = \mu e^{-\mu} e^{-\sigma_*} - \sigma_* e^{-\mu - \sigma_*}.$$

- Estimativa da variância da EMV de λ (a matriz de covariâncias abaixo é obtida com `fit1$var`):

$$\widehat{Var}(\widehat{\lambda}) = \begin{pmatrix} -0,001546 \\ 0,00521 \end{pmatrix}^T \begin{bmatrix} 0,016678010 & 0,001221347 \\ 0,001221347 & 0,054603314 \end{bmatrix} \begin{pmatrix} -0,001545 \\ 0,00521 \end{pmatrix}.$$

- Erro padrão de $\widehat{\lambda}$:

$$ep(\widehat{\lambda}) = \sqrt{\widehat{Var}(\widehat{\lambda})} = 0,001224.$$