

ANÁLISE DE SOBREVIVÊNCIA

Airlane P. Alencar – IME-USP

Alessandra C. Gouglart – FM-USP

Modelo de regressão linear usual


- $Y_i = \beta_0 + \beta_1 x_i + e_i$
- A variável resposta Y_i poderia ser o tempo até a ocorrência do evento. Mas como o tempo tem que ser positivo é usual propor transformações nos dados.
- $Y_i = \log(T_i) = \beta_0 + \beta_1 x_i + v_i$
- O modelo de T seria multiplicativo mas é linearizável, com v tendo dist.valor extremo padrão com $f(v) = \exp(v - \exp(v))$.
- $T \geq 0$ pois $T_i = \exp(\beta_0 + \beta_1 x_i + v_i)$
- $S(t|x) = P(T > t) = \exp\left[-\left(\frac{t}{\exp(\beta_0 + \beta_1 x)}\right)\right]$

Estimador de máxima verossimilhança

- Ideia: encontra os valores de parâmetros que maximizam a probabilidade ou densidade dos dados que você observou.
- Apresenta boas propriedades de consistência e variância assintótica.
- Em regressão linear usual, usamos também o método de mínimos quadrados mas como estimar a variância dos erros?

Estimador de máxima verossimilhança

- $Y_i = \beta_0 + \beta_1 x_i + e_i$
- Supondo que os erros e_i são independentes e $e_i \sim N(0, \sigma^2)$ então $Y_i \sim N(\beta_0 + \beta_1 x_i, \sigma^2)$ independentes e usamos a densidade da normal.



$$f(y_i) = \frac{1}{\sqrt{2\pi\sigma^2}} \exp\left[-\frac{(y_i - \beta_0 - \beta_1 x_i)^2}{2\sigma^2}\right]$$

- Vamos encontrar β_0 , β_1 e σ^2 que maximizam a verossimilhança da amostra y_1, \dots, y_n que temos.

Estimador MV - Normalidade

- Função de verossimilhança
- $L(\beta_0, \beta_1, \sigma^2) = f(y_1) * f(y_2) * \dots * f(y_n)$
- Em regressão linear usual os estimadores MV de β_0 e β_1 são iguais aos de mínimos quadrados e obtemos também a estimação de σ^2 como a soma de quadrados dos resíduos dividido por n.
- Análise de resíduos
Checar se os resíduos tem média 0, variância constante, são não correlacionados (séries temporais) e têm distribuição normal.

Máxima verossimilhança com censura

- Como incluir as observações censuradas?
- Usamos a densidade quando ocorreu a falha.
- Para os dados com censura à direita, sabemos que se a observação foi censurada no tempo t , $P(T > t) = S(t)$.

- 6, 6, 6, 7, 10, 13, 16, 22, 23, 6+, 9+, 10+, 11+, 17+, 19+, 20+, 25+, 32+, 32+, 34+, 35+
- Verossimilhança
- $L(\text{parâmetros}) = f(6) f(6) f(6) f(7) \dots f(23) S(6) S(9) \dots S(35)$
- Suponhamos que o tempo tenha distribuição $\text{Exp}(\lambda)$.

Distribuição Exponencial

- Densidade de probabilidade $f(t) = \lambda \exp(-\lambda t)$
- Sobrevivência: $P(S > t)$ $S(t) = \exp(-\lambda t)$
- Risco constante: $h(t) = \lambda$

Risco= Taxa de falha em t condicional a sobreviver a t ($T \geq t$)

$$h(t) = \lim_{\Delta t \rightarrow 0} \frac{P(t \leq T < t + \Delta t | T \geq t)}{\Delta t} = \lim_{\Delta t \rightarrow 0} \frac{P(t \leq T < t + \Delta t)}{\Delta t S(t)} = \frac{f(t)}{S(t)} = -\frac{S'(t)}{S(t)}$$

- Considerando $\lambda_i = \beta_0 + \beta_1 x_i$

Temos que o risco de cada pessoa i depende suas explicativas.

Weibull

- Densidade de probabilidade $f(t) = h(t)S(t)$
- Sobrevivência: $P(S > t)$ $S(t) = \exp(-\lambda t^p)$
- Risco constante: $h(t) = \lambda p t^{p-1}$
- Tem um parâmetro a mais (p).
- A taxa de risco não é mais constante

Exponencial e Weibull

- Exemplo Ovarian
- `fit <- survfit(Surv(futime, fustat)~1 , data=ovarian)`
- `summary(fit)`
- `plot(fit, xlab="t",ylab=expression(hat(S)^"(t)"))`
- `s2=survreg(Surv(futime, fustat)~1 , ovarian, dist="exponential")`
- `summary(s2)`
- `Tempo=seq(0,1200,1)`
- `lines(Tempo,1-pexp(Tempo,exp(-7.169)))`

- `s3=survreg(Surv(futime, fustat)~1 , ovarian, dist="weibul")`
- `summary(s3) # p=1/scale`
- `lines(Tempo,1-pweibull(Tempo,1/0.902,exp(7.111)), col=2)`

Diagnóstico

- Depois do modelo de Cox