

Outros modelos de regressão linear e métodos de estimação

Prof. Caio Azevedo

Introdução

- Para os exemplo 2 vimos que considerar uma distribuição com caudas mais pesadas do que a normal para os erros, pode ser mais apropriado para modelar os dados em questão através de um modelo de regressão linear.
- Uma alternativa é o modelo de regressão t de Student.
- Vamos considerar a família t de Student de três parâmetros em que os graus de liberdade são conhecidos.

Distribuição t de Student de 3 parâmetros

- Dizemos que $X \sim t_{(\mu, \psi, \nu)}$ se sua fdp é da forma

$$f(x) = \frac{\Gamma\left(\frac{\nu+1}{2}\right)}{\sqrt{\psi\nu\pi}\Gamma\left(\frac{\nu}{2}\right)} \left(1 + \frac{(x-\mu)^2}{\psi\nu}\right)^{-\frac{\nu+1}{2}} \mathbb{1}_{(-\infty, \infty)}(x)$$

- Temos que $\mathcal{E}(X) = \mu$ e $\mathcal{V}(X) = \psi\frac{\nu}{\nu-2}$. Se $\mu = 0$ e $\psi = 1$, então

$$X \sim t_{(\nu)}.$$

- Se $\nu \rightarrow \infty$ então $X \xrightarrow{D} N(\mu, \psi)$


- Representação estocástica: se $X \sim t_{(0, \psi, \nu)}$, então

$X|W = w \sim N(0, \psi w^{-1})$ e $W \sim \text{gama}(\nu/2, \nu/2)$, ou seja

$$f(x) = \int_{\mathfrak{R}^+} f(x|w)f(w)dw, \quad f(w) = \frac{(\nu/2)^{\nu/2}}{\Gamma(\nu/2)} w^{\nu/2-1} e^{-\nu w/2} \mathbb{1}_{(0, \infty)}(w)$$

- Se $X \sim t_{(\nu)}$ e $Y = \mu + \sqrt{\psi}X$, temos que $Y \sim t_{(\mu, \psi, \nu)}$

Densidades da distribuição $t_{(\nu)}$ e da distribuição normal



Exemplo 2 (modelo reduzido): desconsiderando o sexo

$$Y_{ij} = \beta_{1i}x_{ij} + \xi_{ij}, i = 1(\text{convencional}), 2(\text{hugger})(\text{tipo de escova});$$

$$j = 1, \dots, 26(\text{criança}).$$

- $\xi_{ij} \stackrel{i.i.d.}{\sim} t_{(0, \psi, \nu)}$. Assim $Y_{ij} \stackrel{ind.}{\sim} t_{(\beta_{1i}x_{ij}, \psi, \nu)}$, $\mathcal{E}(Y_{ij}) = \beta_{1i}x_{ij}$ e $\mathcal{V}(Y_{ij}) = \psi \frac{\nu}{\nu-2}$.
- x_{ij} : IPB pré-escovação da criança j utilizando a escova do tipo i .
- Y_{ij} : IPB pós-escovação da criança j utilizando a escova do tipo i .
- β_{1i} : diminuição (se $\beta_{1i} \in (0, 1)$) ou aumento (se $\beta_{1i} > 1$), no IPB quando se usa a escova do tipo i .

Estimação dos parâmetros

- Temos que estimar $\beta = (\beta_{i1}, \beta_{i2})'$ e ψ . Algumas opções são:
 - Estimar β por MQO ($\hat{\beta}_{MQO}$) e usar

$$\hat{\psi} = \frac{1}{n-2}(\mathbf{Y} - \mathbf{X}\hat{\beta}_{MQO})'(\mathbf{Y} - \mathbf{X}\hat{\beta}_{MQO})$$

. Note que para estimar os parâmetros por MQO não se faz suposições acerca da distribuição de Y_{ij} .

- Estimar β e ψ por MV (usando a verossimilhança original).
- Estimar β e ψ por MV via algoritmo EM (usando a verossimilhança completa).

Verossimilhança original

- Verossimilhança (no nosso caso, $n=26$)

$$L(\beta_{11}, \beta_{21}, \psi) \propto \psi^{-n} \prod_{i=1}^2 \prod_{j=1}^n \left(1 + \frac{(y_{ij} - \beta_{1i}x_{ij})^2}{\psi\nu} \right)^{-\frac{\nu+1}{2}}$$

- Logverossimilhança

$$l(\beta_{11}, \beta_{21}, \psi) = -n \ln \psi - \frac{\nu+1}{2} \sum_{i=1}^2 \sum_{j=1}^n \ln \left(1 + \frac{(y_{ij} - \beta_{1i}x_{ij})^2}{\psi\nu} \right) + \text{constante}$$

Sistema de equações de verossimilhança

$$\begin{cases} S(\tilde{\beta}_{11}) = 0 \\ S(\tilde{\beta}_{12}) = 0 \rightarrow \\ S(\tilde{\psi}) = 0 \end{cases}$$

$$\begin{cases} (\nu + 1) \sum_{j=1}^n h_{1j}(\tilde{\beta}_{i1}, \tilde{\psi}) \left(\frac{(y_{1j} - \tilde{\beta}_{11}x_{1j})x_{1j}}{\tilde{\psi}^\nu} \right) = 0 \\ (\nu + 1) \sum_{j=1}^n h_{2j}(\tilde{\beta}_{i1}, \tilde{\psi}) \left(\frac{(y_{2j} - \tilde{\beta}_{12}x_{2j})x_{2j}}{\tilde{\psi}^\nu} \right) = 0 \\ -\frac{n}{\tilde{\psi}} + \frac{\nu+1}{2} \sum_{i=1}^2 \sum_{j=1}^n h_{ij}(\tilde{\beta}_{i1}, \tilde{\psi}) \frac{(y_{ij} - \tilde{\beta}_{1i}x_{ij})^2}{\tilde{\psi}^{2\nu}} = 0 \end{cases}$$

$$\text{em que } h_{ij}(\tilde{\beta}_{i1}, \tilde{\psi}) = \left(1 + \frac{(y_{ij} - \tilde{\beta}_{1i}x_{ij})^2}{\tilde{\psi}^\nu} \right)^{-1}, i = 1, 2$$

Obtenção dos estimadores de máxima verossimilhança e inferência

- As equações de verossimilhança não têm solução explícita e, assim, algum método numérico tem de ser empregado para obtê-las como: Algoritmo Newton-Raphson, Escore de Fisher, Nelder-Mead, etc.
- Em nosso caso, a obtenção da informação de Fisher (esperada) é bem complicada.
- Defina $\hat{\boldsymbol{\theta}}_{MV} = (\hat{\beta}_{11}, \hat{\beta}_{12}, \hat{\psi})'$. Nesse caso, podemos usar o seguinte resultado: para n (tamanho da amostra) suficiente grande $\hat{\boldsymbol{\theta}}_{MV} \approx N_3(\boldsymbol{\theta}, \mathbf{I}^\circ(\boldsymbol{\theta})^{-1})$ em que $\mathbf{I}^\circ = -\mathbf{H}(\boldsymbol{\theta})$ e $\mathbf{H}(\boldsymbol{\theta})$ é a matriz hessiana.

Matriz Hessiana

$$H(\beta_{1i}, \beta_{1i}) = -(\nu + 1) \sum_{j=1}^n \left[\frac{2(y_{ij} - \beta_{1i}x_{ij})^2 x_{ij}^2}{\psi^2 \nu^2} + \frac{x_{ij}^2}{\psi \nu h_{ij}} \right]$$

$$H(\beta_{11}, \beta_{12}) = 0$$

$$H(\beta_{i1}, \psi) = -(\nu + 1) \sum_{j=1}^n \left[\frac{(y_{ij} - \beta_{11}x_{ij})x_{ij}}{\psi^2 \nu h_{ij}} + \frac{(y_{ij} - \beta_{11}x_{ij})^3 x_{ij}}{\psi^3 \nu^2} \right]$$

$$H(\psi, \psi) = -\frac{n}{\psi^2} - \frac{\nu+1}{2} \sum_{i=1}^2 \sum_{j=1}^n \left[\frac{2(y_{ij} - \beta_{1i}x_{ij})^2}{\psi^3 \nu h_{ij}} + \frac{(y_{ij} - \beta_{1i}x_{ij})^4}{\psi^4 \nu} \right]$$

em que $h_{ij} = h_{ij}(\tilde{\beta}_{i1}, \tilde{\psi})$

Logverossimilhança completa

- Verossimilhança completa (distribuição conjunta de $(\mathbf{y}', \mathbf{w}')'$)

$$L(\boldsymbol{\beta}, \psi, \mathbf{w}) \propto \psi^{-n} \prod_{i=1}^2 \prod_{j=1}^n w_{ij} \exp \left\{ - \sum_{i=1}^2 \sum_{j=1}^n \frac{w_{ij} (y_{ij} - \beta_{1i} x_{ij})^2}{2\psi} \right\} \\ \times \prod_{i=1}^2 \prod_{j=1}^n w_{ij}^{\nu/2-1} e^{-\sum_{i=1}^2 \sum_{j=1}^n \nu w_{ij}/2}$$

- Logverossimilhança completa

$$l(\boldsymbol{\beta}, \psi, \mathbf{w}) = -n \ln \psi + \sum_{i=1}^2 \sum_{j=1}^n \ln w_{ij} - \sum_{i=1}^2 \sum_{j=1}^n \frac{w_{ij} (y_{ij} - \beta_{1i} x_{ij})^2}{2\psi} \\ \times (\nu/2 - 1) \sum_{i=1}^2 \sum_{j=1}^n \ln w_{ij} - \sum_{i=1}^2 \sum_{j=1}^n \nu w_{ij}/2 + \text{constante}$$

em que $\mathbf{w} = (w_{11}, \dots, w_{1(26)}, w_{21}, w_{2(26)})'$.



Algoritmo EM

- Sejam \mathbf{Y} o conjunto de variáveis observadas e \mathbf{W} o conjunto de variáveis não observadas (não observáveis, dados faltantes).
- Em geral, \mathbf{Y} é chamado de dados incompletos e (\mathbf{Y}, \mathbf{W}) são os dados completos.
- Seja $l(\boldsymbol{\theta})$ a logverossimilhança em que $\boldsymbol{\theta} \in \Theta \subset \mathcal{R}^p$ é o conjunto de parâmetros a ser estimado.

Estrutura do algoritmo EM

- Sejam $l(\theta, \mathbf{y}, \mathbf{w})$ a log-verossimilhança aumentada e $\theta^{(t)}$ estimativas provisórias para θ . O algoritmo EM pode ser resumido nos seguintes passos

Passo E: Calcule a esperança condicional (na log-verossimilhança) dos dados faltantes condicionado as variáveis observadas e à estimativas provisórias de $\theta^{(t)}$, ou seja

$$Q(\theta|\theta^{(t)}) = \mathcal{E} [l(\theta, \mathbf{y}, \mathbf{w})|\mathbf{y}, \theta]$$

Passo M: Maximizar a esperança acima em relação à θ ou seja, obter

$$\theta^{(t+1)} = \operatorname{argmax}_{\theta} Q(\theta|\theta^{(t)})$$

até que algum critério de convergência seja alcançado.

Observações

- O cálculo das esperanças necessárias podem ser complicadas, exigindo o emprego de aproximações analíticas ou numéricas.
- Para a maximização pode ser necessário o emprego de métodos numéricos.
- Na família exponencial as contas ficam mais simples.
- A utilização de valores iniciais apropriados para θ auxilia na convergência do algoritmo EM.
- A introdução de variáveis “aumentadas” apropriadas, é outro fator de importância na convergência e obtenção de estimativas acuradas.

Estimando os erros-padrão

- Usar a informação de Fisher observada ou esperada (verossimilhança original).
- Identidade de Louis (para se calcular tanto a Informação de Fisher observada ou a esperada). A informação observada, é dada por:

$$\mathcal{E} \left(-H(\tilde{\theta})^* | \mathbf{y}, \theta \right) - \text{Cov} \left(S(\tilde{\theta})^* | \mathbf{y}, \theta \right)$$

- Reamostragem.

Voltando ao exemplo

■ Passo E: Calcular

$$Q(\boldsymbol{\theta}|\boldsymbol{\theta}^{(t)}) = -n \ln \psi + \sum_{i=1}^2 \sum_{j=1}^n \mathcal{E}(\ln \tilde{w}_{ij} | y_{ij}, \boldsymbol{\theta}^{(k)}) - \sum_{i=1}^2 \sum_{j=1}^n \frac{\tilde{w}_{ij}^{(k)} (y_{ij} - \beta_{1i} x_{ij})^2}{2\psi}$$
$$\times (\nu/2 - 1) \sum_{i=1}^2 \sum_{j=1}^n \mathcal{E}(\ln \tilde{w}_{ij} | y_{ij}, \boldsymbol{\theta}^{(k)}) - \sum_{i=1}^2 \sum_{j=1}^n \nu \tilde{w}_{ij}^{(k)} / 2 + \text{constante}$$

em que $\tilde{w}_{ij}^{(k)} = \mathcal{E}(W_{ij} | y_{ij}, \tilde{\boldsymbol{\theta}}^{(k)}) =$
 $\left(\frac{\nu}{2} + 1\right) \left(\frac{1}{2}(\nu + (y_{ij} - \beta_{i1}^{(k-1)} x_{ij})^2 / \psi^{(k-1)})\right)^{-1}$, pois
 $W_{ij} | y_{ij}, \tilde{\boldsymbol{\theta}}^{(k)} \sim \text{gama}(\nu/2 + 1, \nu/2 + (y_{ij} - \beta_{i1} x_{ij})^2 / 2\psi)$

Voltando ao exemplo

- Passo M: Calcular

$$\tilde{\beta}^{(k)} = \left(\mathbf{X}' \left(\mathbf{W}^{(k)} \right)^{-1} \mathbf{X} \right)^{-1} \mathbf{X}' \left(\mathbf{W}^{(k)} \right)^{-1} \mathbf{y}$$

$$\tilde{\psi}^{(k)} = \frac{1}{2n} \sum_{i=1}^2 \sum_{j=1}^n \tilde{w}_{ij}^{(k)} (y_{ij} - \tilde{\beta}_{1i} x_{ij})^2$$

em que \mathbf{X} é matriz de planejamento do modelo, \mathbf{y} o vetor com as respostas observadas e










$$\mathbf{W}^{(k)} = \psi^{(k-1)} \text{diag}(w_{11}^{(k)}, \dots, w_{1(26)}^{(k)}, w_{21}^{(k)}, \dots, w_{2(26)}^{(k)})^{-1}$$

Estudo de simulação

$$Y_{ij} = \beta_{1i}x_{ij} + \xi_{ij}, i = 1, 2; j = 1, \dots, 26(\text{criança}).$$

- ξ $\overset{i.i.d.}{\sim} t_{(0, \psi=2, \nu=5)}$
- $\beta_{11} = 0,5$ e $\beta_{12} = 1,5$.
- Foram geradas 100 réplicas de tamanho 52.
- Em cada réplica, os parâmetros β_{11} , β_{12} e ψ foram estimados por MQO, MV e MV via EM (estes dois últimos através do modelo acima).
- Para cada método de estimação e parâmetros, obtivemos a média e variância das estimativas das réplicas, bem como o vício e a raiz quadrática do erro quadrático médio (rqeqm).

Histogramas das estimativas



Mét. de est.	Par.	Valor verd.	Média	Vício	Var.	RQEQM
MQO	β_{11}	0,5	0,495	-0,005	0,005	0,074
	β_{12}	1,5	1,499	-0,001	0,005	0,071
	ψ	2	3,195	1,195	1,275	1,644
MV	β_{11}	0,5	0,494	-0,006	0,005	0,069
	β_{12}	1,5	1,498	-0,002	0,004	0,064
	ψ	2	1,883	-0,117	0,222	0,485
MV via EM	β_{11}	0,5	0,494	-0,006	0,005	0,069
	β_{12}	1,5	1,498	-0,002	0,004	0,064
	ψ	2	2,400	0,400	0,368	0,727

Exemplo 2 (modelo reduzido): desconsiderando o sexo

$$Y_{ij} = \beta_{1i}x_{ij} + \xi_{ij}, i = 1(\text{convencional}), 2(\text{hugger})(\text{tipo de escova});$$

$$j = 1, \dots, 26(\text{criança}).$$

- $\xi_{ij} \stackrel{i.i.d.}{\sim} t_{(0, \psi, \nu)}$. Assim $Y_{ij} \stackrel{ind.}{\sim} t_{(\beta_{1i}x_{ij}, \psi, \nu)}$, $\mathcal{E}(Y_{ij}) = \beta_{1i}x_{ij}$ e $\mathcal{V}(Y_{ij}) = \psi \frac{\nu}{\nu-2}$.
- x_{ij} : IPB pré-escovação da criança j utilizando a escova do tipo i .
- Y_{ij} : IPB pós-escovação da criança j utilizando a escova do tipo i .
- β_{1i} : diminuição (se $\beta_{1i} \in (0, 1)$) ou aumento (se $\beta_{1i} > 1$), no IPB quando se usa a escova do tipo i .
- Regressão “gridge”: ajustou-se um modelo para determinados valores de $\nu \in \{2, 5; 3, 5; 8; 10; 20; 30\}$.

Voltando ao exemplo 2

V1	AIC _n	BIC _n
Normal	7,90	13,76
t com $\nu = 2,5$	6,27	12,12
t com $\nu = 3$	5,93	11,79
t com $\nu = 5$	5,84	11,69
t com $\nu = 8$	6,21	12,07
t com $\nu = 10$	6,43	12,28
t com $\nu = 20$	7,03	12,88
t com $\nu = 30$	7,28	13,14

Comentários

- O modelo de regressão mais apropriado é aquele que considera uma distribuição $t_{(5)}$ graus de liberdade.
- No entanto, é necessário verificar se o modelo se ajustou bem aos dados (análise de resíduos e preditiva).
- Resíduos : adaptação dos resíduos vistos para o modelo de regressão normal linear homocedástico (ver a literatura).