

Terceira Prova - FECD

23/06/2018

- Suponha que X_1, \dots, X_n forme uma amostra aleatória de v.a.'s i.i.d. com densidade de probabilidade Rayleigh dada por

$$f(x; \theta) = (x/\theta)^2 \exp(-x^2/(2\theta^2))$$

para $x > 0$ e com $\theta \in (0, \infty)$ sendo um parâmetro desconhecido controlando a forma da densidade. Obtenha o MLE de θ .

Solução: A log-verossimilhança de θ baseada numa amostra é igual a

$$\begin{aligned}\ell(\theta) &= \log \left[\frac{\prod_i x_i^2}{\theta^{2n}} \exp \left(-\frac{\sum_i x_i^2}{2\theta^2} \right) \right] \\ &= -2n \log(\theta) + \sum_i \log(x_i^2) - \frac{1}{2\theta^2} \sum_i x_i^2.\end{aligned}$$

Derivando com respeito a θ e igualando a zero, temos

$$0 = \frac{\partial \ell(\theta)}{\partial \theta} = -\frac{2n}{\theta} + \frac{\sum_i x_i^2}{\theta^3}$$

o que implica no MLE

$$\hat{\theta} = \sqrt{\frac{\sum_i x_i^2}{2n}}$$

- Suponha que X_1, \dots, X_n forme uma amostra aleatória de v.a.'s i.i.d. com densidade de probabilidade Weibull dada por

$$f(x; \alpha, \beta) = \alpha \beta x^{\beta-1} \exp(-\alpha x^\beta)$$

para $x > 0$. Você vai usar o método de Newton para obter o MLE de $\boldsymbol{\theta} = (\alpha, \beta)$. Como valor inicial você vai usar $\boldsymbol{\theta}^{(0)} = (1/\bar{x}, 1)$.

Obtenha explicitamente a equação de iteração do algoritmo de Newton com a densidade acima (mas não precisa inverter a matriz).

DICA: A derivada em β da função x^β é igual a

$$\frac{d}{d\beta} (x^\beta) = \log(x) x^\beta$$

onde \log é o logaritmo na base e .

Solução: A log-verossimilhança de $\boldsymbol{\theta} = (\alpha, \beta)$ baseada numa amostra é igual a

$$\begin{aligned}\ell(\alpha, \beta) &= \log \left[\alpha^n \beta^n \left(\prod_i x_i^{\beta-1} \right) \exp \left(-\alpha \sum_i x_i^\beta \right) \right] \\ &= n \log(\alpha) + n \log(\beta) + (\beta - 1) \sum_i \log(x_i) - \alpha \sum_i x_i^\beta.\end{aligned}$$

Derivando com respeito a α e depois com respeito a β encontramos o vetor gradiente:

$$\nabla \ell(\boldsymbol{\theta}) = \frac{\partial \ell}{\partial \boldsymbol{\theta}} = \begin{bmatrix} \frac{\partial \ell(\alpha, \beta)}{\partial \alpha} \\ \frac{\partial \ell(\alpha, \beta)}{\partial \beta} \end{bmatrix} = \begin{bmatrix} \frac{n}{\alpha} - \sum_i x_i^\beta \\ \frac{n}{\beta} + \sum_i \log(x_i) - \alpha \sum_i (\log(x_i) x_i^\beta) \end{bmatrix}$$

Não é possível obter o MLE de forma explícita. Devemos usar métodos numéricos. Para usar o método de Newton precisamos da matriz de derivadas parciais de segunda ordem (o Hessiano da função $\ell(\boldsymbol{\theta})$):

$$\begin{aligned} D^2(\boldsymbol{\theta}) &= \frac{\partial^2 \ell(\boldsymbol{\theta})}{\partial \boldsymbol{\theta}^2} \\ &= \begin{bmatrix} \frac{\partial^2 \ell(\alpha, \beta)}{\partial \alpha^2} & \frac{\partial^2 \ell(\alpha, \beta)}{\partial \alpha \partial \beta} \\ \frac{\partial^2 \ell(\alpha, \beta)}{\partial \beta \partial \alpha} & \frac{\partial^2 \ell(\alpha, \beta)}{\partial \beta^2} \end{bmatrix} \\ &= \begin{bmatrix} -\frac{n}{\alpha^2} & -\sum_i (\log(x_i) x_i^\beta) \\ -\sum_i (\log(x_i) x_i^\beta) & -\frac{n}{\beta^2} - \alpha \sum_i (\log^2(x_i) x_i^\beta) \end{bmatrix} \end{aligned}$$

O MLE é encontrado aplicando iterativamente a seguinte atualização:

$$\boldsymbol{\theta}^{(k+1)} = \boldsymbol{\theta}^{(k)} - [D^2(\boldsymbol{\theta}^{(k)})]^{-1} \nabla \ell(\boldsymbol{\theta}^{(k)})$$

3. No modelo de regressão logística com uma única feature numérica x , temos variáveis aleatórias binárias Y_1, \dots, Y_n em que a probabilidade de sucesso do item i depende de sua feature x_i da seguinte forma:

$$p_i = p(x_i) = \frac{1}{1 + \exp(-\beta_0 - \beta_1 x_i)}$$

- Mostre que $p_i = \frac{\exp(\beta_0 + \beta_1 x_i)}{1 + \exp(\beta_0 + \beta_1 x_i)}$
- Obtenha a função log-verossimilhança de $\boldsymbol{\beta} = (\beta_0, \beta_1)$ mostrando que ela é igual a

$$\ell(\boldsymbol{\beta}) = \beta_0 \sum_i y_i + \beta_1 \sum_i x_i y_i - \sum_i \log(1 + e^{\beta_0 + \beta_1 x_i})$$

(Não precisa obter a derivada da log-verossimilhança).

Solução: Multiplicando o numerador e o denominador de p_i por $\exp(\beta_0 + \beta_1 x_i)$ temos

$$p_i = \frac{\exp(\beta_0 + \beta_1 x_i)}{\exp(\beta_0 + \beta_1 x_i) + \exp(\beta_0 + \beta_1 x_i) \exp(-\beta_0 - \beta_1 x_i)} = \frac{\exp(\beta_0 + \beta_1 x_i)}{\exp(\beta_0 + \beta_1 x_i) + 1}$$

Para a função log-verossimilhança temos

$$\begin{aligned} \ell(\boldsymbol{\beta}) &= \log \prod_i [\mathbb{P}(Y_i = y_i | \boldsymbol{\beta})] \\ &= \sum_i \log [p_i^{y_i} (1 - p_i)^{1 - y_i}] \\ &= \sum_i [y_i \log(p_i) + (1 - y_i) \log(1 - p_i)] \\ &= \sum_i [y_i \log(p_i) + (1 - y_i) \log(1 - p_i)] \\ &= \sum_i \left[y_i \log \left(\frac{\exp(\beta_0 + \beta_1 x_i)}{1 + \exp(\beta_0 + \beta_1 x_i)} \right) + (1 - y_i) \log \left(\frac{1}{1 + \exp(\beta_0 + \beta_1 x_i)} \right) \right] \\ &= \sum_i [y_i(\beta_0 + \beta_1 x_i) - y_i \log(1 + \exp(\beta_0 + \beta_1 x_i)) - (1 - y_i) \log(1 + \exp(\beta_0 + \beta_1 x_i))] \\ &= \sum_i [y_i(\beta_0 + \beta_1 x_i) - \log(1 + \exp(\beta_0 + \beta_1 x_i))] \\ &= \beta_0 \sum_i y_i + \beta_1 \sum_i (y_i x_i) - \sum_i \log(1 + \exp(\beta_0 + \beta_1 x_i)) \end{aligned}$$

4. Considere o modelo de regressão usual com matriz de desenho \mathbf{X} de dimensão $n \times p$ cuja primeira coluna é o vetor $\mathbf{1}$. As colunas são linearmente independentes. O estimador de mínimos quadrados dos coeficientes $\boldsymbol{\beta} = (\beta_0, \beta_1, \dots, \beta_p)$ coincide o MLE e é igual a $\hat{\boldsymbol{\beta}} = (\mathbf{X}'\mathbf{X})^{-1}\mathbf{X}'\mathbf{Y}$.

- Para avaliar se o modelo de regressão linear é adequado, costuma-se tralhar com o vetor de resíduos \mathbf{r} . Tendo \mathbf{X} e \mathbf{Y} , quais as contas matriciais você precisa fazer para obter o vetor \mathbf{r} ? Isto é, qual a expressão matricial do vetor \mathbf{r} em função de \mathbf{X} e \mathbf{Y} ?
- Mostre que o vetor de resíduos \mathbf{r} é ortogonal ao vetor de valores preditos $\hat{\mathbf{Y}}$.
- A partir do item acima, conclua que a soma dos resíduos $\sum_i r_i$ é igual a zero quando a primeira coluna de \mathbf{X} é o vetor $\mathbf{1}$.

Solução: Como o resíduo é o vetor diferença entre as observações \mathbf{Y} e os vetor de predições $\mathbf{X}\hat{\boldsymbol{\beta}}$, temos

$$\mathbf{r} = \mathbf{Y} - \mathbf{X}\hat{\boldsymbol{\beta}} = \mathbf{Y} - \mathbf{X}(\mathbf{X}'\mathbf{X})^{-1}\mathbf{X}'\mathbf{Y}$$

O vetor \mathbf{r} é ortogonal ao vetor de valores preditos $\hat{\mathbf{Y}}$ pois o seu produto interno é zero. Existem muitas maneiras de provar isto, uma delas sendo:

$$\hat{\mathbf{Y}}'\mathbf{r} = (\mathbf{X}\hat{\boldsymbol{\beta}})'(\mathbf{Y} - \mathbf{X}\hat{\boldsymbol{\beta}}) = \hat{\boldsymbol{\beta}}'\mathbf{X}'(\mathbf{Y} - \mathbf{X}\hat{\boldsymbol{\beta}}) = \hat{\boldsymbol{\beta}}'\mathbf{X}'\mathbf{Y} - \hat{\boldsymbol{\beta}}'\mathbf{X}'\mathbf{X}\hat{\boldsymbol{\beta}} \quad (1)$$

Use agora a expressão fornecida $\hat{\boldsymbol{\beta}} = (\mathbf{X}'\mathbf{X})^{-1}\mathbf{X}'\mathbf{Y}$ para obter

$$\hat{\boldsymbol{\beta}}'\mathbf{X}'\mathbf{X}\hat{\boldsymbol{\beta}} = \hat{\boldsymbol{\beta}}'\mathbf{X}'\mathbf{X}(\mathbf{X}'\mathbf{X})^{-1}\mathbf{X}'\mathbf{Y} = \hat{\boldsymbol{\beta}}'\mathbf{X}'\mathbf{Y}$$

Portanto, o produto interno em (1) é zero.

Novamente, existem muitas maneira distintas de provar este último resultado. Aqui está uma delas. Como \mathbf{r} está no espaço ortogonal das colunas de \mathbf{X} , o produto interno de \mathbf{r} com estas coluna é zero. Como $\mathbf{1}$ é uma das colunas de \mathbf{X} , temos $0 = \mathbf{1}'\mathbf{r} = \sum_i r_i$.

Outra maneira, apenas manipulando as fórmulas dos itens acima:

$$\mathbf{X}'\mathbf{r} = \mathbf{X}'(\mathbf{Y} - \mathbf{X}\hat{\boldsymbol{\beta}}) = \mathbf{X}'\mathbf{Y} - \mathbf{X}'\mathbf{X}\hat{\boldsymbol{\beta}} = \mathbf{X}'\mathbf{Y} - \mathbf{X}'\mathbf{X}(\mathbf{X}'\mathbf{X})^{-1}\mathbf{X}'\mathbf{Y} = \mathbf{X}'\mathbf{Y} - \mathbf{X}'\mathbf{Y} = \mathbf{0}$$

Assim, cada linha de \mathbf{X}' é ortogonal a \mathbf{r} . Isto é, cada coluna de \mathbf{X} é ortogonal a \mathbf{r} e, como $\mathbf{1}$ é uma das colunas de \mathbf{X} , temos $0 = \mathbf{1}'\mathbf{r} = \sum_i r_i$.
