

# Estimação

Tiago M. Magalhães

Departamento de Estatística - ICE-UFJF

Juiz de Fora, 20 de março de 2024



# Roteiro

- 1 Introdução
- 2 Método dos mínimos quadrados
- 3 Método da máxima verossimilhança
- 4 Aplicações
- 5 Estudo de simulação
- 6 Referências bibliográficas



# Roteiro

- 1 Introdução
- 2 Método dos mínimos quadrados
- 3 Método da máxima verossimilhança
- 4 Aplicações
- 5 Estudo de simulação
- 6 Referências bibliográficas



# Modelo de regressão linear

Suponham que  $Y_1, Y_2, \dots, Y_n$  tais que

$$Y_l = \mathbf{x}_l^T \boldsymbol{\beta} + \varepsilon_l, \quad (1)$$



# Modelo de regressão linear

Suponham que  $Y_1, Y_2, \dots, Y_n$  tais que

$$Y_\ell = \mathbf{x}_\ell^\top \boldsymbol{\beta} + \varepsilon_\ell, \quad (1)$$

em que  $\mathbf{x}_\ell = (x_{\ell 1}, x_{\ell 2}, \dots, x_{\ell p})^\top$  é conhecido,  $\boldsymbol{\beta} = (\beta_1, \beta_2, \dots, \beta_p)^\top$  é um vetor de parâmetros desconhecidos a serem estimados,  $\varepsilon_\ell \sim \mathcal{D}(0, \sigma^2)$ ,  $\ell = 1, 2, \dots, n$ ,  $\varepsilon_1, \varepsilon_2, \dots, \varepsilon_n$  são variáveis aleatórias independentes e com a mesma variância  $\sigma^2$ , também desconhecida, a ser estimada.



# Modelo de regressão linear

Suponham que  $Y_1, Y_2, \dots, Y_n$  tais que

$$Y_\ell = \mathbf{x}_\ell^\top \boldsymbol{\beta} + \varepsilon_\ell, \quad (1)$$

em que  $\mathbf{x}_\ell = (x_{\ell 1}, x_{\ell 2}, \dots, x_{\ell p})^\top$  é conhecido,  $\boldsymbol{\beta} = (\beta_1, \beta_2, \dots, \beta_p)^\top$  é um vetor de parâmetros desconhecidos a serem estimados,  $\varepsilon_\ell \sim \mathcal{D}(0, \sigma^2)$ ,  $\ell = 1, 2, \dots, n$ ,  $\varepsilon_1, \varepsilon_2, \dots, \varepsilon_n$  são variáveis aleatórias independentes e com a mesma variância  $\sigma^2$ , também desconhecida, a ser estimada.



# Forma matricial

A Equação (1), que nós definimos como **modelo de regressão linear** (MRL), podendo ser escrita de forma matricial, da seguinte forma:

$$Y = X\beta + \varepsilon, \quad (2)$$



# Forma matricial

A Equação (1), que nós definimos como **modelo de regressão linear** (MRL), podendo ser escrita de forma matricial, da seguinte forma:

$$\mathbf{Y} = \mathbf{X}\boldsymbol{\beta} + \boldsymbol{\varepsilon}, \quad (2)$$

em que  $\mathbf{Y} = (Y_1, Y_2, \dots, Y_n)^\top$  e  $\boldsymbol{\varepsilon} = (\varepsilon_1, \varepsilon_2, \dots, \varepsilon_n)^\top$ ,  $\boldsymbol{\varepsilon} \sim \mathcal{D}_n(\mathbf{0}, \sigma^2 \mathbf{I}_n)$ , sendo  $\mathbf{0}$  o vetor nulo de dimensão  $n$ ,  $\mathbf{I}_n$  a matriz identidade de ordem  $n$  e  $\mathbf{X} = (\mathbf{x}_1, \mathbf{x}_2, \dots, \mathbf{x}_n)^\top$





# Forma matricial

A Equação (1), que nós definimos como **modelo de regressão linear** (MRL), podendo ser escrita de forma matricial, da seguinte forma:

$$\mathbf{Y} = \mathbf{X}\boldsymbol{\beta} + \boldsymbol{\varepsilon}, \quad (2)$$

em que  $\mathbf{Y} = (Y_1, Y_2, \dots, Y_n)^\top$  e  $\boldsymbol{\varepsilon} = (\varepsilon_1, \varepsilon_2, \dots, \varepsilon_n)^\top$ ,  $\boldsymbol{\varepsilon} \sim \mathcal{D}_n(\mathbf{0}, \sigma^2 \mathbf{I}_n)$ , sendo  $\mathbf{0}$  o vetor nulo de dimensão  $n$ ,  $\mathbf{I}_n$  a matriz identidade de ordem  $n$  e  $\mathbf{X} = (\mathbf{x}_1, \mathbf{x}_2, \dots, \mathbf{x}_n)^\top$



# Forma matricial

ou

$$\mathbf{X} = \begin{bmatrix} x_{11} & x_{12} & \cdots & x_{1p} \\ x_{21} & x_{22} & \cdots & x_{2p} \\ \vdots & \vdots & \ddots & \vdots \\ x_{n1} & x_{n2} & \cdots & x_{np} \end{bmatrix}.$$

A matriz  $\mathbf{X}$  tem  $n$  linhas (tamanho da amostra) e  $p$  colunas (número de variáveis preditoras), de posto  $p$  ( $n \geq p$ ),  $\mathbf{X}$  é chamada de matriz de planejamento.



# Forma matricial

ou

$$\mathbf{X} = \begin{bmatrix} x_{11} & x_{12} & \cdots & x_{1p} \\ x_{21} & x_{22} & \cdots & x_{2p} \\ \vdots & \vdots & \ddots & \vdots \\ x_{n1} & x_{n2} & \cdots & x_{np} \end{bmatrix}.$$

A matriz  $\mathbf{X}$  tem  $n$  linhas (tamanho da amostra) e  $p$  colunas (número de variáveis preditoras), de posto  $p$  ( $n \geq p$ ),  $\mathbf{X}$  é chamada de matriz de planejamento.



# Modelo de regressão normal linear

Para que procedimentos inferenciais possam ser aplicados, nós precisamos assumir que,  $\varepsilon_\ell \sim \mathcal{N}(0, \sigma^2)$ ,  $\ell = 1, 2, \dots, n$  e  $\varepsilon \sim \mathcal{N}_n(\mathbf{0}, \sigma^2 \mathbf{I}_n)$ , em (1) e (2), respectivamente. O MRL passa a ser denominado de **modelo de regressão normal linear** (MNL).



# Modelo de regressão normal linear

Para que procedimentos inferenciais possam ser aplicados, nós precisamos assumir que,  $\varepsilon_\ell \sim \mathcal{N}(0, \sigma^2)$ ,  $\ell = 1, 2, \dots, n$  e  $\varepsilon \sim \mathcal{N}_n(\mathbf{0}, \sigma^2 \mathbf{I}_n)$ , em (1) e (2), respectivamente. O MRL passa a ser denominado de **modelo de regressão normal linear** (MNL).



# Roteiro

- 1 Introdução
- 2 Método dos mínimos quadrados**
- 3 Método da máxima verossimilhança
- 4 Aplicações
- 5 Estudo de simulação
- 6 Referências bibliográficas



# Método dos mínimos quadrados

## Definição

Os estimadores de mínimos quadrados (EMQ) obtém estimativas para os parâmetros desconhecidos **minimizando** a soma de quadrado dos erros.



# Método dos mínimos quadrados

## Definição

Os estimadores de mínimos quadrados (EMQ) obtém estimativas para os parâmetros desconhecidos **minimizando** a soma de quadrado dos erros.



# Método dos mínimos quadrados

Se  $\hat{\beta} = (\hat{\beta}_1, \hat{\beta}_2, \dots, \hat{\beta}_p)^\top$  é o EMQ de  $\beta$ , ele deve ser tal que minimize

$$Q = \sum_{\ell=1}^n [Y_\ell - (\beta_1 x_{\ell 1} + \beta_2 x_{\ell 2} + \dots + \beta_p x_{\ell p})]^2. \quad (3)$$

# Método dos mínimos quadrados

Se  $\hat{\beta} = (\hat{\beta}_1, \hat{\beta}_2, \dots, \hat{\beta}_p)^\top$  é o EMQ de  $\beta$ , ele deve ser tal que minimize

$$Q = \sum_{\ell=1}^n [Y_\ell - (\beta_1 x_{\ell 1} + \beta_2 x_{\ell 2} + \dots + \beta_p x_{\ell p})]^2. \quad (3)$$

# Método dos mínimos quadrados

Derivando (3), em relação ao parâmetro  $\beta_m$ ,  $m = 1, 2, \dots, p$ , nós temos:

$$\frac{\partial Q}{\partial \beta_m} = -2 \sum_{\ell=1}^n [Y_\ell - (\beta_1 x_{\ell 1} + \beta_2 x_{\ell 2} + \dots + \beta_p x_{\ell p})] x_{\ell m}. \quad (4)$$



# Método dos mínimos quadrados

Derivando (3), em relação ao parâmetro  $\beta_m$ ,  $m = 1, 2, \dots, p$ , nós temos:

$$\frac{\partial Q}{\partial \beta_m} = -2 \sum_{\ell=1}^n [Y_\ell - (\beta_1 x_{\ell 1} + \beta_2 x_{\ell 2} + \dots + \beta_p x_{\ell p})] x_{\ell m}. \quad (4)$$

Igualando (4) a zero,



# Método dos mínimos quadrados

Derivando (3), em relação ao parâmetro  $\beta_m$ ,  $m = 1, 2, \dots, p$ , nós temos:

$$\frac{\partial Q}{\partial \beta_m} = -2 \sum_{\ell=1}^n [Y_\ell - (\beta_1 x_{\ell 1} + \beta_2 x_{\ell 2} + \dots + \beta_p x_{\ell p})] x_{\ell m}. \quad (4)$$

Igualando (4) a zero, nós temos que

$$\hat{\beta}_1 \sum_{\ell=1}^n x_{\ell 1} x_{\ell m} + \dots + \hat{\beta}_m \sum_{\ell=1}^n x_{\ell m}^2 + \dots + \hat{\beta}_p \sum_{\ell=1}^n x_{\ell p} x_{\ell m} = \sum_{\ell=1}^n x_{\ell m} Y_\ell. \quad (5)$$



# Método dos mínimos quadrados

Derivando (3), em relação ao parâmetro  $\beta_m$ ,  $m = 1, 2, \dots, p$ , nós temos:

$$\frac{\partial Q}{\partial \beta_m} = -2 \sum_{\ell=1}^n [Y_\ell - (\beta_1 x_{\ell 1} + \beta_2 x_{\ell 2} + \dots + \beta_p x_{\ell p})] x_{\ell m}. \quad (4)$$

Igualando (4) a zero, nós temos que

$$\hat{\beta}_1 \sum_{\ell=1}^n x_{\ell 1} x_{\ell m} + \dots + \hat{\beta}_m \sum_{\ell=1}^n x_{\ell m}^2 + \dots + \hat{\beta}_p \sum_{\ell=1}^n x_{\ell p} x_{\ell m} = \sum_{\ell=1}^n x_{\ell m} Y_\ell. \quad (5)$$



# Método dos mínimos quadrados

As  $p$  equações em (5) são chamadas de **equações normais**. E o **estimador de mínimos quadrados** é dado por:



# Método dos mínimos quadrados

As  $p$  equações em (5) são chamadas de **equações normais**. E o **estimador de mínimos quadrados** é dado por:

$$\hat{\beta} = (\mathbf{X}^T \mathbf{X})^{-1} \mathbf{X}^T \mathbf{Y}. \quad (6)$$





# Método dos mínimos quadrados

As  $p$  equações em (5) são chamadas de **equações normais**. E o **estimador de mínimos quadrados** é dado por:

$$\hat{\beta} = (\mathbf{X}^T \mathbf{X})^{-1} \mathbf{X}^T \mathbf{Y}. \quad (6)$$



# Método dos mínimos quadrados

Uma alternativa para a obtenção de (6), é observar que (3) pode ser escrito como:

$$Q = (\mathbf{Y} - \mathbf{X}\boldsymbol{\beta})^\top (\mathbf{Y} - \mathbf{X}\boldsymbol{\beta}).$$



# Método dos mínimos quadrados

Uma alternativa para a obtenção de (6), é observar que (3) pode ser escrito como:

$$Q = (\mathbf{Y} - \mathbf{X}\beta)^T (\mathbf{Y} - \mathbf{X}\beta).$$

e derivar  $Q$  em relação à  $\beta$ .



# Método dos mínimos quadrados

Uma alternativa para a obtenção de (6), é observar que (3) pode ser escrito como:

$$Q = (\mathbf{Y} - \mathbf{X}\beta)^\top (\mathbf{Y} - \mathbf{X}\beta).$$

e derivar  $Q$  em relação à  $\beta$ .



# Método dos mínimos quadrados

## Observação

O EMQ existirá se existir a inversa  $(\mathbf{X}^T \mathbf{X})^{-1}$ .

# Método dos mínimos quadrados

## Observação

O EMQ existirá se existir a inversa  $(\mathbf{X}^T \mathbf{X})^{-1}$ . E a matriz  $(\mathbf{X}^T \mathbf{X})^{-1}$  existe se as variáveis preditoras forem linearmente independentes, isto é, se nenhuma coluna da matriz  $\mathbf{X}$  é uma combinação linear das outras.



# Método dos mínimos quadrados

## Observação

O EMQ existirá se existir a inversa  $(\mathbf{X}^T \mathbf{X})^{-1}$ . E a matriz  $(\mathbf{X}^T \mathbf{X})^{-1}$  existe se as variáveis preditoras forem linearmente independentes, isto é, se nenhuma coluna da matriz  $\mathbf{X}$  é uma combinação linear das outras.

# Propriedades do EMQ

A esperança de  $\hat{\beta}$  é dada por

$$\begin{aligned}\mathbb{E}(\hat{\beta}) &= (\mathbf{X}^T \mathbf{X})^{-1} \mathbf{X}^T \mathbb{E}(\mathbf{Y}) = (\mathbf{X}^T \mathbf{X})^{-1} \mathbf{X}^T \mathbb{E}(\mathbf{X}\beta + \varepsilon) \\ &= (\mathbf{X}^T \mathbf{X})^{-1} \mathbf{X}^T [\mathbf{X}\beta + \mathbb{E}(\varepsilon)] \\ &= (\mathbf{X}^T \mathbf{X})^{-1} \mathbf{X}^T \mathbf{X}\beta = \beta.\end{aligned}$$





# Propriedades do EMQ

A esperança de  $\hat{\beta}$  é dada por

$$\begin{aligned}\mathbb{E}(\hat{\beta}) &= (\mathbf{X}^\top \mathbf{X})^{-1} \mathbf{X}^\top \mathbb{E}(\mathbf{Y}) = (\mathbf{X}^\top \mathbf{X})^{-1} \mathbf{X}^\top \mathbb{E}(\mathbf{X}\beta + \varepsilon) \\ &= (\mathbf{X}^\top \mathbf{X})^{-1} \mathbf{X}^\top [\mathbf{X}\beta + \mathbb{E}(\varepsilon)] \\ &= (\mathbf{X}^\top \mathbf{X})^{-1} \mathbf{X}^\top \mathbf{X}\beta = \beta.\end{aligned}$$



# Propriedades do EMQ

E a variância de  $\hat{\beta}$  é dada por

$$\begin{aligned}\text{Var}(\hat{\beta}) &= (\mathbf{X}^T \mathbf{X})^{-1} \mathbf{X}^T \text{Var}(\mathbf{Y}) \mathbf{X} (\mathbf{X}^T \mathbf{X})^{-1} \\ &= (\mathbf{X}^T \mathbf{X})^{-1} \mathbf{X}^T \text{Var}(\mathbf{X}\beta + \varepsilon) \mathbf{X} (\mathbf{X}^T \mathbf{X})^{-1} \\ &= (\mathbf{X}^T \mathbf{X})^{-1} \mathbf{X}^T \text{Var}(\varepsilon) \mathbf{X} (\mathbf{X}^T \mathbf{X})^{-1} \\ &= (\mathbf{X}^T \mathbf{X})^{-1} \mathbf{X}^T \sigma^2 I_n \mathbf{X} (\mathbf{X}^T \mathbf{X})^{-1} \\ &= \sigma^2 (\mathbf{X}^T \mathbf{X})^{-1}.\end{aligned}$$



# Propriedades do EMQ

E a variância de  $\hat{\beta}$  é dada por

$$\begin{aligned}\text{Var}(\hat{\beta}) &= (\mathbf{X}^T \mathbf{X})^{-1} \mathbf{X}^T \text{Var}(\mathbf{Y}) \mathbf{X} (\mathbf{X}^T \mathbf{X})^{-1} \\ &= (\mathbf{X}^T \mathbf{X})^{-1} \mathbf{X}^T \text{Var}(\mathbf{X}\beta + \varepsilon) \mathbf{X} (\mathbf{X}^T \mathbf{X})^{-1} \\ &= (\mathbf{X}^T \mathbf{X})^{-1} \mathbf{X}^T \text{Var}(\varepsilon) \mathbf{X} (\mathbf{X}^T \mathbf{X})^{-1} \\ &= (\mathbf{X}^T \mathbf{X})^{-1} \mathbf{X}^T \sigma^2 \mathbf{I}_n \mathbf{X} (\mathbf{X}^T \mathbf{X})^{-1} \\ &= \sigma^2 (\mathbf{X}^T \mathbf{X})^{-1}.\end{aligned}$$



# Propriedades do EMQ

Pelo Teorema de Gauss-Markov (Plackett, 1949), os EMQ

- são não viesados;



# Propriedades do EMQ

Pelo Teorema de Gauss-Markov (Plackett, 1949), os EMQ

- são não viesados;
- e têm menor variância entre todos os estimadores lineares não viesados.



# Propriedades do EMQ

Pelo Teorema de Gauss-Markov (Plackett, 1949), os EMQ

- são não viesados;
- e têm menor variância entre todos os estimadores lineares não viesados.



# Valores ajustados

E assim, o valor ajustado (estimado) da  $l$ -ésima observação é dado por



# Valores ajustados

E assim, o valor ajustado (estimado) da  $l$ -ésima observação é dado por

$$\hat{Y}_l = \mathbf{x}_l^\top \hat{\boldsymbol{\beta}},$$

$$l = 1, 2, \dots, n.$$



# Valores ajustados

E assim, o valor ajustado (estimado) da  $l$ -ésima observação é dado por

$$\hat{Y}_l = \mathbf{x}_l^\top \hat{\boldsymbol{\beta}},$$

$l = 1, 2, \dots, n$ . De forma matricial,

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

# Valores ajustados

E assim, o valor ajustado (estimado) da  $\ell$ -ésima observação é dado por

$$\hat{Y}_\ell = \mathbf{x}_\ell^\top \hat{\boldsymbol{\beta}},$$

$\ell = 1, 2, \dots, n$ . De forma matricial,

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

A matriz  $\mathbf{H}$ ,  $n \times n$ , é chamada de matriz chapéu (*hat matrix*).



# Valores ajustados

E assim, o valor ajustado (estimado) da  $\ell$ -ésima observação é dado por

$$\hat{Y}_\ell = \mathbf{x}_\ell^\top \hat{\boldsymbol{\beta}},$$

$\ell = 1, 2, \dots, n$ . De forma matricial,

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

A matriz  $\mathbf{H}$ ,  $n \times n$ , é chamada de matriz chapéu (*hat matrix*).



# Matriz chapéu

Propriedades da matriz  $H$ .

- $H$  é simétrica e idempotente;



# Matriz chapéu

Propriedades da matriz  $H$ .

- $H$  é simétrica e idempotente;
- $(I_n - H)$  é simétrica e idempotente;



# Matriz chapéu

Propriedades da matriz  $\mathbf{H}$ .

- $\mathbf{H}$  é simétrica e idempotente;
- $(\mathbf{I}_n - \mathbf{H})$  é simétrica e idempotente;
- $(\mathbf{I}_n - \mathbf{H})\mathbf{H} = \mathbf{0}$ .



# Matriz chapéu

Propriedades da matriz  $\mathbf{H}$ .

- $\mathbf{H}$  é simétrica e idempotente;
- $(\mathbf{I}_n - \mathbf{H})$  é simétrica e idempotente;
- $(\mathbf{I}_n - \mathbf{H})\mathbf{H} = \mathbf{0}$ .

**Observação:** uma matriz  $\mathbf{M}$  é dita idempotente se e somente se  $\mathbf{MM} = \mathbf{M}$ .



# Matriz chapéu

Propriedades da matriz  $\mathbf{H}$ .

- $\mathbf{H}$  é simétrica e idempotente;
- $(\mathbf{I}_n - \mathbf{H})$  é simétrica e idempotente;
- $(\mathbf{I}_n - \mathbf{H})\mathbf{H} = \mathbf{0}$ .

**Observação:** uma matriz  $\mathbf{M}$  é dita idempotente se e somente se  $\mathbf{MM} = \mathbf{M}$ .





# Resíduos

É a diferença entre o valor observado pelo correspondente valor ajustado.

$$\begin{aligned}e &= Y - \hat{Y} = Y - X\hat{\beta} \\ &= Y - HY = (I_n - H)Y,\end{aligned}$$

# Resíduos

É a diferença entre o valor observado pelo correspondente valor ajustado.

$$\begin{aligned}\mathbf{e} &= \mathbf{Y} - \hat{\mathbf{Y}} = \mathbf{Y} - \mathbf{X}\hat{\boldsymbol{\beta}} \\ &= \mathbf{Y} - \mathbf{HY} = (\mathbf{I}_n - \mathbf{H})\mathbf{Y},\end{aligned}$$

em que  $\mathbf{e} = (e_1, e_2, \dots, e_n)^\top$  e  $e_\ell = Y_\ell - \mathbf{x}_\ell^\top \hat{\boldsymbol{\beta}}$  é o  $\ell$ -ésimo resíduo,  $\ell = 1, 2, \dots, n$ .

# Resíduos

É a diferença entre o valor observado pelo correspondente valor ajustado.

$$\begin{aligned}\mathbf{e} &= \mathbf{Y} - \widehat{\mathbf{Y}} = \mathbf{Y} - \mathbf{X}\widehat{\boldsymbol{\beta}} \\ &= \mathbf{Y} - \mathbf{HY} = (\mathbf{I}_n - \mathbf{H})\mathbf{Y},\end{aligned}$$

em que  $\mathbf{e} = (e_1, e_2, \dots, e_n)^\top$  e  $e_\ell = Y_\ell - \mathbf{x}_\ell^\top \widehat{\boldsymbol{\beta}}$  é o  $\ell$ -ésimo resíduo,  $\ell = 1, 2, \dots, n$ .

A esperança de  $\mathbf{e}$  é dada por

$$\begin{aligned}\mathbb{E}(\mathbf{e}) &= (\mathbf{I}_n - \mathbf{H})\mathbb{E}(\mathbf{Y}) = (\mathbf{I}_n - \mathbf{H})\mathbb{E}(\mathbf{X}\boldsymbol{\beta} + \boldsymbol{\varepsilon}) \\ &= (\mathbf{I}_n - \mathbf{H})[\mathbf{X}\boldsymbol{\beta} + \mathbb{E}(\boldsymbol{\varepsilon})] = (\mathbf{I}_n - \mathbf{H})\mathbf{X}\boldsymbol{\beta} \\ &= \mathbf{X}\boldsymbol{\beta} - \mathbf{H}\mathbf{X}\boldsymbol{\beta} \\ &= \mathbf{X}\boldsymbol{\beta} - \mathbf{X}(\mathbf{X}^\top \mathbf{X})^{-1} \mathbf{X}^\top \mathbf{X}\boldsymbol{\beta} \\ &= \mathbf{X}\boldsymbol{\beta} - \mathbf{X}\boldsymbol{\beta} = \mathbf{0}.\end{aligned}$$

A esperança de  $\mathbf{e}$  é dada por

$$\begin{aligned}\mathbb{E}(\mathbf{e}) &= (\mathbf{I}_n - \mathbf{H})\mathbb{E}(\mathbf{Y}) = (\mathbf{I}_n - \mathbf{H})\mathbb{E}(\mathbf{X}\boldsymbol{\beta} + \boldsymbol{\varepsilon}) \\ &= (\mathbf{I}_n - \mathbf{H})[\mathbf{X}\boldsymbol{\beta} + \mathbb{E}(\boldsymbol{\varepsilon})] = (\mathbf{I}_n - \mathbf{H})\mathbf{X}\boldsymbol{\beta} \\ &= \mathbf{X}\boldsymbol{\beta} - \mathbf{H}\mathbf{X}\boldsymbol{\beta} \\ &= \mathbf{X}\boldsymbol{\beta} - \mathbf{X}(\mathbf{X}^\top \mathbf{X})^{-1} \mathbf{X}^\top \mathbf{X}\boldsymbol{\beta} \\ &= \mathbf{X}\boldsymbol{\beta} - \mathbf{X}\boldsymbol{\beta} = \mathbf{0}.\end{aligned}$$

E a variância de  $\mathbf{e}$  é dada por

$$\begin{aligned}\text{Var}(\mathbf{e}) &= (\mathbf{I}_n - \mathbf{H})\text{Var}(\mathbf{Y})(\mathbf{I}_n - \mathbf{H})^\top \\ &= (\mathbf{I}_n - \mathbf{H})\text{Var}(\mathbf{X}\boldsymbol{\beta} + \boldsymbol{\varepsilon})(\mathbf{I}_n - \mathbf{H})^\top \\ &= (\mathbf{I}_n - \mathbf{H})\text{Var}(\boldsymbol{\varepsilon})(\mathbf{I}_n - \mathbf{H})^\top \\ &= (\mathbf{I}_n - \mathbf{H})\sigma^2 \mathbf{I}_n (\mathbf{I}_n - \mathbf{H})^\top \\ &= \sigma^2 (\mathbf{I}_n - \mathbf{H}).\end{aligned}$$

E a variância de  $\mathbf{e}$  é dada por

$$\begin{aligned}\text{Var}(\mathbf{e}) &= (\mathbf{I}_n - \mathbf{H})\text{Var}(\mathbf{Y})(\mathbf{I}_n - \mathbf{H})^\top \\ &= (\mathbf{I}_n - \mathbf{H})\text{Var}(\mathbf{X}\boldsymbol{\beta} + \boldsymbol{\varepsilon})(\mathbf{I}_n - \mathbf{H})^\top \\ &= (\mathbf{I}_n - \mathbf{H})\text{Var}(\boldsymbol{\varepsilon})(\mathbf{I}_n - \mathbf{H})^\top \\ &= (\mathbf{I}_n - \mathbf{H})\sigma^2\mathbf{I}_n(\mathbf{I}_n - \mathbf{H})^\top \\ &= \sigma^2(\mathbf{I}_n - \mathbf{H}).\end{aligned}$$

Lembrando que  $(\mathbf{I}_n - \mathbf{H})$  é idempotente e simétrica.

E a variância de  $\mathbf{e}$  é dada por

$$\begin{aligned}\text{Var}(\mathbf{e}) &= (\mathbf{I}_n - \mathbf{H})\text{Var}(\mathbf{Y})(\mathbf{I}_n - \mathbf{H})^\top \\ &= (\mathbf{I}_n - \mathbf{H})\text{Var}(\mathbf{X}\boldsymbol{\beta} + \boldsymbol{\varepsilon})(\mathbf{I}_n - \mathbf{H})^\top \\ &= (\mathbf{I}_n - \mathbf{H})\text{Var}(\boldsymbol{\varepsilon})(\mathbf{I}_n - \mathbf{H})^\top \\ &= (\mathbf{I}_n - \mathbf{H})\sigma^2\mathbf{I}_n(\mathbf{I}_n - \mathbf{H})^\top \\ &= \sigma^2(\mathbf{I}_n - \mathbf{H}).\end{aligned}$$

Lembrando que  $(\mathbf{I}_n - \mathbf{H})$  é idempotente e simétrica.



# Resíduos

Seja  $h_{ij}$ , o  $(i, j)$ -ésimo termo da matriz  $\mathbf{H}$ ,  $i, j = 1, 2, \dots, n$ , então nós temos que:

- $\mathbb{E}(e_j) = 0$ ;

# Resíduos

Seja  $h_{ij}$ , o  $(i, j)$ -ésimo termo da matriz  $\mathbf{H}$ ,  $i, j = 1, 2, \dots, n$ , então nós temos que:

- $\mathbb{E}(e_j) = 0$ ;
- $\text{Var}(e_j) = \sigma^2(1 - h_{jj})$ ;

# Resíduos

Seja  $h_{ij}$ , o  $(i, j)$ -ésimo termo da matriz  $\mathbf{H}$ ,  $i, j = 1, 2, \dots, n$ , então nós temos que:

- $\mathbb{E}(e_i) = 0$ ;
- $\text{Var}(e_i) = \sigma^2(1 - h_{ii})$ ;
- $\text{Cov}(e_i, e_j) = -\sigma^2 h_{ij}$ .

# Resíduos

Seja  $h_{ij}$ , o  $(i, j)$ -ésimo termo da matriz  $\mathbf{H}$ ,  $i, j = 1, 2, \dots, n$ , então nós temos que:

- $\mathbb{E}(e_i) = 0$ ;
- $\text{Var}(e_i) = \sigma^2(1 - h_{ii})$ ;
- $\text{Cov}(e_i, e_j) = -\sigma^2 h_{ij}$ .



# Estimação da variância do erro

O estimador da variância,  $\hat{\sigma}^2$ , é dado por

$$\begin{aligned}\hat{\sigma}^2 &= \frac{\sum_{\ell=1}^n \left( Y_{\ell} - \mathbf{x}_{\ell}^{\top} \hat{\boldsymbol{\beta}} \right)^2}{n-p} = \frac{1}{n-p} \mathbf{e}^{\top} \mathbf{e} \\ &= \frac{1}{n-p} \left( \mathbf{Y} - \mathbf{X} \hat{\boldsymbol{\beta}} \right)^{\top} \left( \mathbf{Y} - \mathbf{X} \hat{\boldsymbol{\beta}} \right).\end{aligned}\tag{7}$$



## Estimação da variância do erro

O estimador da variância,  $\sigma^2$ , é dado por

$$\begin{aligned}\hat{\sigma}^2 &= \frac{\sum_{\ell=1}^n \left( Y_{\ell} - \mathbf{x}_{\ell}^{\top} \hat{\boldsymbol{\beta}} \right)^2}{n-p} = \frac{1}{n-p} \mathbf{e}^{\top} \mathbf{e} \\ &= \frac{1}{n-p} \left( \mathbf{Y} - \mathbf{X} \hat{\boldsymbol{\beta}} \right)^{\top} \left( \mathbf{Y} - \mathbf{X} \hat{\boldsymbol{\beta}} \right).\end{aligned}\tag{7}$$

O estimador  $\hat{\sigma}^2$ , dado em (7), também é denominado de **quadrado médio do resíduo** (QMRes).



## Estimação da variância do erro

O estimador da variância,  $\sigma^2$ , é dado por

$$\begin{aligned}\hat{\sigma}^2 &= \frac{\sum_{\ell=1}^n \left( Y_{\ell} - \mathbf{x}_{\ell}^{\top} \hat{\boldsymbol{\beta}} \right)^2}{n-p} = \frac{1}{n-p} \mathbf{e}^{\top} \mathbf{e} \\ &= \frac{1}{n-p} \left( \mathbf{Y} - \mathbf{X} \hat{\boldsymbol{\beta}} \right)^{\top} \left( \mathbf{Y} - \mathbf{X} \hat{\boldsymbol{\beta}} \right).\end{aligned}\quad (7)$$

O estimador  $\hat{\sigma}^2$ , dado em (7), também é denominado de **quadrado médio do resíduo** (QMRes). E  $\sum_{\ell=1}^n \left( Y_{\ell} - \mathbf{x}_{\ell}^{\top} \hat{\boldsymbol{\beta}} \right)^2$  é denominado de **soma de quadrados do resíduo** (SQRes).



## Estimação da variância do erro

O estimador da variância,  $\sigma^2$ , é dado por

$$\begin{aligned}\hat{\sigma}^2 &= \frac{\sum_{\ell=1}^n \left( Y_{\ell} - \mathbf{x}_{\ell}^{\top} \hat{\boldsymbol{\beta}} \right)^2}{n-p} = \frac{1}{n-p} \mathbf{e}^{\top} \mathbf{e} \\ &= \frac{1}{n-p} \left( \mathbf{Y} - \mathbf{X} \hat{\boldsymbol{\beta}} \right)^{\top} \left( \mathbf{Y} - \mathbf{X} \hat{\boldsymbol{\beta}} \right).\end{aligned}\tag{7}$$

O estimador  $\hat{\sigma}^2$ , dado em (7), também é denominado de **quadrado médio do resíduo** (QMRes). E  $\sum_{\ell=1}^n \left( Y_{\ell} - \mathbf{x}_{\ell}^{\top} \hat{\boldsymbol{\beta}} \right)^2$  é denominado de **soma de quadrados do resíduo** (SQRes).





# Estimação da variância do erro

A esperança de  $\hat{\sigma}^2$  é dada por

$$\begin{aligned}\mathbb{E}(\hat{\sigma}^2) &= \frac{1}{n-p} \mathbb{E}(\mathbf{e}^\top \mathbf{e}) = \frac{1}{n-p} \mathbb{E} \left\{ [(\mathbf{I}_n - \mathbf{H})\mathbf{Y}]^\top (\mathbf{I}_n - \mathbf{H})\mathbf{Y} \right\} \\ &= \frac{1}{n-p} \mathbb{E} \left\{ [(\mathbf{I}_n - \mathbf{H})(\mathbf{X}\boldsymbol{\beta} + \boldsymbol{\varepsilon})]^\top (\mathbf{I}_n - \mathbf{H})(\mathbf{X}\boldsymbol{\beta} + \boldsymbol{\varepsilon}) \right\} \\ &\stackrel{*}{=} \frac{1}{n-p} \mathbb{E} \left\{ [(\mathbf{I}_n - \mathbf{H})\boldsymbol{\varepsilon}]^\top (\mathbf{I}_n - \mathbf{H})\boldsymbol{\varepsilon} \right\} \\ &= \frac{1}{n-p} \mathbb{E} \left[ \boldsymbol{\varepsilon}^\top (\mathbf{I}_n - \mathbf{H})(\mathbf{I}_n - \mathbf{H})\boldsymbol{\varepsilon} \right] = \frac{1}{n-p} \mathbb{E} \left[ \boldsymbol{\varepsilon}^\top (\mathbf{I}_n - \mathbf{H})\boldsymbol{\varepsilon} \right] \\ &\stackrel{**}{=} \frac{1}{n-p} \text{tr} \left[ (\mathbf{I}_n - \mathbf{H})\sigma^2 \mathbf{I}_n \right] = \frac{\sigma^2}{n-p} \text{tr}(\mathbf{I}_n - \mathbf{H}) \\ &\stackrel{***}{=} \frac{\sigma^2}{n-p} (n-p) = \sigma^2.\end{aligned}$$



# Estimação da variância do erro

A esperança de  $\hat{\sigma}^2$  é dada por

$$\begin{aligned}\mathbb{E}(\hat{\sigma}^2) &= \frac{1}{n-p} \mathbb{E}(\mathbf{e}^\top \mathbf{e}) = \frac{1}{n-p} \mathbb{E} \left\{ [(\mathbf{I}_n - \mathbf{H})\mathbf{Y}]^\top (\mathbf{I}_n - \mathbf{H})\mathbf{Y} \right\} \\ &= \frac{1}{n-p} \mathbb{E} \left\{ [(\mathbf{I}_n - \mathbf{H})(\mathbf{X}\boldsymbol{\beta} + \boldsymbol{\varepsilon})]^\top (\mathbf{I}_n - \mathbf{H})(\mathbf{X}\boldsymbol{\beta} + \boldsymbol{\varepsilon}) \right\} \\ &\stackrel{*}{=} \frac{1}{n-p} \mathbb{E} \left\{ [(\mathbf{I}_n - \mathbf{H})\boldsymbol{\varepsilon}]^\top (\mathbf{I}_n - \mathbf{H})\boldsymbol{\varepsilon} \right\} \\ &= \frac{1}{n-p} \mathbb{E} \left[ \boldsymbol{\varepsilon}^\top (\mathbf{I}_n - \mathbf{H})(\mathbf{I}_n - \mathbf{H})\boldsymbol{\varepsilon} \right] = \frac{1}{n-p} \mathbb{E} \left[ \boldsymbol{\varepsilon}^\top (\mathbf{I}_n - \mathbf{H})\boldsymbol{\varepsilon} \right] \\ &\stackrel{**}{=} \frac{1}{n-p} \text{tr} \left[ (\mathbf{I}_n - \mathbf{H})\sigma^2 \mathbf{I}_n \right] = \frac{\sigma^2}{n-p} \text{tr}(\mathbf{I}_n - \mathbf{H}) \\ &\stackrel{***}{=} \frac{\sigma^2}{n-p} (n-p) = \sigma^2.\end{aligned}$$



# Estimação da variância do erro

\*: Ver  $\mathbb{E}(\mathbf{e})$ .

\*\* : Sejam  $\mathbf{v}$  um vetor aleatório de comprimento  $v$ , com vetor de médias  $\mathbf{m}$  e matriz de covariâncias  $\mathbf{C}$  e  $\mathbf{W}$  uma matriz de dimensão  $v \times v$ , então



# Estimação da variância do erro

\*: Ver  $\mathbb{E}(\mathbf{e})$ .

\*\* : Sejam  $\mathbf{v}$  um vetor aleatório de comprimento  $v$ , com vetor de médias  $\mathbf{m}$  e matriz de covariâncias  $\mathbf{C}$  e  $\mathbf{W}$  uma matriz de dimensão  $v \times v$ , então

$$\mathbb{E} \left[ \mathbf{v}^T \mathbf{W} \mathbf{v} \right] = \text{tr} [\mathbf{W} \mathbf{C}] + \mathbf{m}^T \mathbf{W} \mathbf{m}.$$



# Estimação da variância do erro

\*: Ver  $\mathbb{E}(\mathbf{e})$ .

\*\* : Sejam  $\mathbf{v}$  um vetor aleatório de comprimento  $v$ , com vetor de médias  $\mathbf{m}$  e matriz de covariâncias  $\mathbf{C}$  e  $\mathbf{W}$  uma matriz de dimensão  $v \times v$ , então

$$\mathbb{E} \left[ \mathbf{v}^T \mathbf{W} \mathbf{v} \right] = \text{tr} [\mathbf{W} \mathbf{C}] + \mathbf{m}^T \mathbf{W} \mathbf{m}.$$

\*\*\*:  $\text{tr}(\mathbf{I}_n - \mathbf{H}) = \text{tr}(\mathbf{I}_n) - \text{tr}(\mathbf{H})$ .



# Estimação da variância do erro

\*: Ver  $\mathbb{E}(\mathbf{e})$ .

\*\* : Sejam  $\mathbf{v}$  um vetor aleatório de comprimento  $v$ , com vetor de médias  $\mathbf{m}$  e matriz de covariâncias  $\mathbf{C}$  e  $\mathbf{W}$  uma matriz de dimensão  $v \times v$ , então

$$\mathbb{E} \left[ \mathbf{v}^T \mathbf{W} \mathbf{v} \right] = \text{tr} [\mathbf{W} \mathbf{C}] + \mathbf{m}^T \mathbf{W} \mathbf{m}.$$

\*\*\* :  $\text{tr}(\mathbf{I}_n - \mathbf{H}) = \text{tr}(\mathbf{I}_n) - \text{tr}(\mathbf{H})$ . Como  $\text{tr}(\mathbf{I}_n) = n$  e

$$\text{tr}(\mathbf{H}) = \text{tr} \left[ \mathbf{X}(\mathbf{X}^T \mathbf{X})^{-1} \mathbf{X}^T \right] = \text{tr} \left[ (\mathbf{X}^T \mathbf{X})^{-1} \mathbf{X}^T \mathbf{X} \right] = \text{tr}(\mathbf{I}_p) = p.$$



# Estimação da variância do erro

\*: Ver  $\mathbb{E}(\mathbf{e})$ .

\*\* : Sejam  $\mathbf{v}$  um vetor aleatório de comprimento  $v$ , com vetor de médias  $\mathbf{m}$  e matriz de covariâncias  $\mathbf{C}$  e  $\mathbf{W}$  uma matriz de dimensão  $v \times v$ , então

$$\mathbb{E} \left[ \mathbf{v}^T \mathbf{W} \mathbf{v} \right] = \text{tr} [\mathbf{W} \mathbf{C}] + \mathbf{m}^T \mathbf{W} \mathbf{m}.$$

\*\*\*:  $\text{tr}(\mathbf{I}_n - \mathbf{H}) = \text{tr}(\mathbf{I}_n) - \text{tr}(\mathbf{H})$ . Como  $\text{tr}(\mathbf{I}_n) = n$  e

$$\text{tr}(\mathbf{H}) = \text{tr} \left[ \mathbf{X}(\mathbf{X}^T \mathbf{X})^{-1} \mathbf{X}^T \right] = \text{tr} \left[ (\mathbf{X}^T \mathbf{X})^{-1} \mathbf{X}^T \mathbf{X} \right] = \text{tr}(\mathbf{I}_p) = p.$$

Logo,  $\text{tr}(\mathbf{I}_n - \mathbf{H}) = n - p$ .



# Estimação da variância do erro

\*: Ver  $\mathbb{E}(\mathbf{e})$ .

\*\* : Sejam  $\mathbf{v}$  um vetor aleatório de comprimento  $v$ , com vetor de médias  $\mathbf{m}$  e matriz de covariâncias  $\mathbf{C}$  e  $\mathbf{W}$  uma matriz de dimensão  $v \times v$ , então

$$\mathbb{E} \left[ \mathbf{v}^T \mathbf{W} \mathbf{v} \right] = \text{tr} [\mathbf{W} \mathbf{C}] + \mathbf{m}^T \mathbf{W} \mathbf{m}.$$

\*\*\*:  $\text{tr}(\mathbf{I}_n - \mathbf{H}) = \text{tr}(\mathbf{I}_n) - \text{tr}(\mathbf{H})$ . Como  $\text{tr}(\mathbf{I}_n) = n$  e

$$\text{tr}(\mathbf{H}) = \text{tr} \left[ \mathbf{X}(\mathbf{X}^T \mathbf{X})^{-1} \mathbf{X}^T \right] = \text{tr} \left[ (\mathbf{X}^T \mathbf{X})^{-1} \mathbf{X}^T \mathbf{X} \right] = \text{tr}(\mathbf{I}_p) = p.$$

Logo,  $\text{tr}(\mathbf{I}_n - \mathbf{H}) = n - p$ .





# Estimação da variância do erro

E assim, nós temos que o QMRes, dado em (7), é um estimador não viciado para  $\sigma^2$ .



# Roteiro

- 1 Introdução
- 2 Método dos mínimos quadrados
- 3 Método da máxima verossimilhança
- 4 Aplicações
- 5 Estudo de simulação
- 6 Referências bibliográficas



# Método da máxima verossimilhança

## Definição

Os estimadores de máxima verossimilhança (EMV) obtém estimativas para parâmetros desconhecidos que **maximizam** a função de verossimilhança.

# Método da máxima verossimilhança

## Definição

Os estimadores de máxima verossimilhança (EMV) obtém estimativas para parâmetros desconhecidos que **maximizam** a função de verossimilhança.

# Método da máxima verossimilhança

Sejam  $Y_1, Y_2, \dots, Y_n$  variáveis aleatórias independentes, com  $Y_\ell \sim \mathcal{N}(\mu_\ell, \sigma^2)$ ,



# Método da máxima verossimilhança

Sejam  $Y_1, Y_2, \dots, Y_n$  variáveis aleatórias independentes, com  $Y_\ell \sim \mathcal{N}(\mu_\ell, \sigma^2)$ ,  
em que  $\mu_\ell = \mathbf{x}_\ell^\top \boldsymbol{\beta}$ ,  $\ell = 1, 2, \dots, n$ ,



# Método da máxima verossimilhança

Sejam  $Y_1, Y_2, \dots, Y_n$  variáveis aleatórias independentes, com  $Y_\ell \sim \mathcal{N}(\mu_\ell, \sigma^2)$ , em que  $\mu_\ell = \mathbf{x}_\ell^\top \boldsymbol{\beta}$ ,  $\ell = 1, 2, \dots, n$ , a função de verossimilhança é dada por

$$L(\boldsymbol{\beta}, \sigma^2) = \frac{1}{(2\pi\sigma^2)^{n/2}} \exp \left\{ -\frac{1}{2\sigma^2} \sum_{\ell=1}^n (Y_\ell - \mathbf{x}_\ell^\top \boldsymbol{\beta})^2 \right\}. \quad (8)$$



# Método da máxima verossimilhança

Sejam  $Y_1, Y_2, \dots, Y_n$  variáveis aleatórias independentes, com  $Y_\ell \sim \mathcal{N}(\mu_\ell, \sigma^2)$ , em que  $\mu_\ell = \mathbf{x}_\ell^\top \boldsymbol{\beta}$ ,  $\ell = 1, 2, \dots, n$ , a função de verossimilhança é dada por

$$L(\boldsymbol{\beta}, \sigma^2) = \frac{1}{(2\pi\sigma^2)^{n/2}} \exp \left\{ -\frac{1}{2\sigma^2} \sum_{\ell=1}^n (Y_\ell - \mathbf{x}_\ell^\top \boldsymbol{\beta})^2 \right\}. \quad (8)$$





# Método da máxima verossimilhança

Maximizar (8) é equivalente a maximizar o seu logaritmo, dado por

$$l(\beta, \sigma^2) = -\frac{n}{2} \log(2\pi\sigma^2) - \frac{1}{2\sigma^2} \sum_{\ell=1}^n (Y_{\ell} - \mathbf{x}_{\ell}^{\top} \beta)^2. \quad (9)$$

# Método da máxima verossimilhança

Maximizar (8) é equivalente a maximizar o seu logaritmo, dado por

$$l(\beta, \sigma^2) = -\frac{n}{2} \log(2\pi\sigma^2) - \frac{1}{2\sigma^2} \sum_{\ell=1}^n (Y_{\ell} - \mathbf{x}_{\ell}^{\top} \beta)^2. \quad (9)$$

# Método da máxima verossimilhança

Derivando (9), em relação ao parâmetro  $\beta_m$ ,  $m = 1, 2, \dots, p$ , nós temos:

$$\frac{\partial l(\beta, \sigma^2)}{\partial \beta_m} = \frac{1}{\sigma^2} \sum_{\ell=1}^n [Y_\ell - (\beta_1 x_{\ell 1} + \beta_2 x_{\ell 2} + \dots + \beta_p x_{\ell p})] x_{\ell m}. \quad (10)$$



# Método da máxima verossimilhança

Derivando (9), em relação ao parâmetro  $\beta_m$ ,  $m = 1, 2, \dots, p$ , nós temos:

$$\frac{\partial l(\beta, \sigma^2)}{\partial \beta_m} = \frac{1}{\sigma^2} \sum_{\ell=1}^n [Y_\ell - (\beta_1 x_{\ell 1} + \beta_2 x_{\ell 2} + \dots + \beta_p x_{\ell p})] x_{\ell m}. \quad (10)$$

Igualando (10) a zero,



# Método da máxima verossimilhança

Derivando (9), em relação ao parâmetro  $\beta_m$ ,  $m = 1, 2, \dots, p$ , nós temos:

$$\frac{\partial l(\beta, \sigma^2)}{\partial \beta_m} = \frac{1}{\sigma^2} \sum_{\ell=1}^n [Y_\ell - (\beta_1 x_{\ell 1} + \beta_2 x_{\ell 2} + \dots + \beta_p x_{\ell p})] x_{\ell m}. \quad (10)$$

Igualando (10) a zero, nós temos que

$$\hat{\beta}_1 \sum_{\ell=1}^n x_{\ell 1} x_{\ell m} + \dots + \hat{\beta}_m \sum_{\ell=1}^n x_{\ell m}^2 + \dots + \hat{\beta}_p \sum_{\ell=1}^n x_{\ell p} x_{\ell m} = \sum_{\ell=1}^n x_{\ell m} Y_\ell. \quad (11)$$



# Método da máxima verossimilhança

Derivando (9), em relação ao parâmetro  $\beta_m$ ,  $m = 1, 2, \dots, p$ , nós temos:

$$\frac{\partial l(\beta, \sigma^2)}{\partial \beta_m} = \frac{1}{\sigma^2} \sum_{\ell=1}^n [Y_\ell - (\beta_1 x_{\ell 1} + \beta_2 x_{\ell 2} + \dots + \beta_p x_{\ell p})] x_{\ell m}. \quad (10)$$

Igualando (10) a zero, nós temos que

$$\hat{\beta}_1 \sum_{\ell=1}^n x_{\ell 1} x_{\ell m} + \dots + \hat{\beta}_m \sum_{\ell=1}^n x_{\ell m}^2 + \dots + \hat{\beta}_p \sum_{\ell=1}^n x_{\ell p} x_{\ell m} = \sum_{\ell=1}^n x_{\ell m} Y_\ell. \quad (11)$$



# Método da máxima verossimilhança

O **estimador de máxima verossimilhança** de  $\beta_m$ , obtido da solução das  $p$  equações em (11), é dado por:

$$\hat{\beta} = (\mathbf{X}^T \mathbf{X})^{-1} \mathbf{X}^T \mathbf{Y}. \quad (12)$$



# Método da máxima verossimilhança

O **estimador de máxima verossimilhança** de  $\beta_m$ , obtido da solução das  $p$  equações em (11), é dado por:

$$\hat{\beta} = (\mathbf{X}^T \mathbf{X})^{-1} \mathbf{X}^T \mathbf{Y}. \quad (12)$$

O EMV em (12) coincide com o EMQ, apresentado em (6).





# Método da máxima verossimilhança

O **estimador de máxima verossimilhança** de  $\beta_m$ , obtido da solução das  $p$  equações em (11), é dado por:

$$\hat{\beta} = (\mathbf{X}^T \mathbf{X})^{-1} \mathbf{X}^T \mathbf{Y}. \quad (12)$$

O EMV em (12) coincide com o EMQ, apresentado em (6).



# Método da máxima verossimilhança

Agora, derivando (9), em relação ao parâmetro  $\sigma^2$ , nós temos:

$$\frac{\partial l(\beta, \sigma^2)}{\partial \sigma^2} = -\frac{n}{2\sigma^2} + \frac{1}{2(\sigma^2)^2} \sum_{\ell=1}^n (Y_{\ell} - \mathbf{x}_{\ell}^{\top} \beta)^2. \quad (13)$$



# Método da máxima verossimilhança

Agora, derivando (9), em relação ao parâmetro  $\sigma^2$ , nós temos:

$$\frac{\partial l(\boldsymbol{\beta}, \sigma^2)}{\partial \sigma^2} = -\frac{n}{2\sigma^2} + \frac{1}{2(\sigma^2)^2} \sum_{\ell=1}^n \left( Y_{\ell} - \mathbf{x}_{\ell}^{\top} \boldsymbol{\beta} \right)^2. \quad (13)$$

Igualando (13) a zero,



# Método da máxima verossimilhança

Agora, derivando (9), em relação ao parâmetro  $\sigma^2$ , nós temos:

$$\frac{\partial l(\boldsymbol{\beta}, \sigma^2)}{\partial \sigma^2} = -\frac{n}{2\sigma^2} + \frac{1}{2(\sigma^2)^2} \sum_{\ell=1}^n \left( Y_{\ell} - \mathbf{x}_{\ell}^{\top} \boldsymbol{\beta} \right)^2. \quad (13)$$

Igualando (13) a zero, nós temos que

$$\frac{1}{2(\hat{\sigma}^2)^2} \sum_{\ell=1}^n \left( Y_{\ell} - \mathbf{x}_{\ell}^{\top} \hat{\boldsymbol{\beta}} \right)^2 = \frac{n}{2\hat{\sigma}^2}. \quad (14)$$



# Método da máxima verossimilhança

Agora, derivando (9), em relação ao parâmetro  $\sigma^2$ , nós temos:

$$\frac{\partial l(\boldsymbol{\beta}, \sigma^2)}{\partial \sigma^2} = -\frac{n}{2\sigma^2} + \frac{1}{2(\sigma^2)^2} \sum_{\ell=1}^n \left( Y_{\ell} - \mathbf{x}_{\ell}^{\top} \boldsymbol{\beta} \right)^2. \quad (13)$$

Igualando (13) a zero, nós temos que

$$\frac{1}{2(\hat{\sigma}^2)^2} \sum_{\ell=1}^n \left( Y_{\ell} - \mathbf{x}_{\ell}^{\top} \hat{\boldsymbol{\beta}} \right)^2 = \frac{n}{2\hat{\sigma}^2}. \quad (14)$$



# Método da máxima verossimilhança

O **estimador de máxima verossimilhança** de  $\sigma^2$ , obtido da solução da equação (14), é dado por:

$$\hat{\sigma}_{MV}^2 = \frac{\sum_{\ell=1}^n (Y_{\ell} - \mathbf{x}_{\ell}^{\top} \hat{\boldsymbol{\beta}})^2}{n} = \frac{n-p}{n} \text{QMRes.} \quad (15)$$



# Método da máxima verossimilhança

O **estimador de máxima verossimilhança** de  $\sigma^2$ , obtido da solução da equação (14), é dado por:

$$\hat{\sigma}_{MV}^2 = \frac{\sum_{\ell=1}^n \left( Y_{\ell} - \mathbf{x}_{\ell}^{\top} \hat{\boldsymbol{\beta}} \right)^2}{n} = \frac{n-p}{n} \text{QMRes.} \quad (15)$$



# Método da máxima verossimilhança

O estimador para  $\beta$  obtido pelo método da máxima verossimilhança coincide com o obtido pelo método dos mínimos quadrados, por conta disso, o EMV de  $\beta$  é **não viesado** e tem menor variância entre todos os estimadores lineares não viesados.





# Método da máxima verossimilhança

O estimador para  $\beta$  obtido pelo método da máxima verossimilhança coincide com o obtido pelo método dos mínimos quadrados, por conta disso, o EMV de  $\beta$  é **não viesado** e tem menor variância entre todos os estimadores lineares não viesados.



# Método da máxima verossimilhança

O mesmo não acontece com o EMV de  $\sigma^2$ . De fato,  $\hat{\sigma}_{MV}^2$  é um **estimador viciado**,



# Método da máxima verossimilhança

O mesmo não acontece com o EMV de  $\sigma^2$ . De fato,  $\hat{\sigma}_{MV}^2$  é um **estimador viciado**, para tamanhos de amostras pequenos, esse viés é considerável.



# Método da máxima verossimilhança

O mesmo não acontece com o EMV de  $\sigma^2$ . De fato,  $\hat{\sigma}_{MV}^2$  é um **estimador viciado**, para tamanhos de amostras pequenos, esse viés é considerável.

Adicionalmente, os EMV de  $\beta$  e  $\sigma^2$  são estimadores consistentes e suficientes.



# Método da máxima verossimilhança

O mesmo não acontece com o EMV de  $\sigma^2$ . De fato,  $\hat{\sigma}_{MV}^2$  é um **estimador viciado**, para tamanhos de amostras pequenos, esse viés é considerável.

Adicionalmente, os EMV de  $\beta$  e  $\sigma^2$  são estimadores consistentes e suficientes.

A suposição de normalidade e a consequente estimação por máxima verossimilhança permitem a construção de procedimentos inferenciais, como intervalos de confiança.



# Método da máxima verossimilhança

O mesmo não acontece com o EMV de  $\sigma^2$ . De fato,  $\hat{\sigma}_{MV}^2$  é um **estimador viciado**, para tamanhos de amostras pequenos, esse viés é considerável.

Adicionalmente, os EMV de  $\beta$  e  $\sigma^2$  são estimadores consistentes e suficientes.

A suposição de normalidade e a consequente estimação por máxima verossimilhança permitem a construção de procedimentos inferenciais, como intervalos de confiança.



# Método da máxima verossimilhança

Derivando (9), uma segunda vez, em relação ao parâmetro  $\beta_{m'}$ ,  $m' = 1, 2, \dots, p$ , nós temos:

$$\frac{\partial^2 l(\beta, \sigma^2)}{\partial \beta_m \partial \beta_{m'}} = -\frac{1}{\sigma^2} \sum_{l=1}^n x_{lm} x_{lm'}. \quad (16)$$

# Método da máxima verossimilhança

Derivando (9), uma segunda vez, em relação ao parâmetro  $\beta_{m'}$ ,  $m' = 1, 2, \dots, p$ , nós temos:

$$\frac{\partial^2 l(\beta, \sigma^2)}{\partial \beta_m \partial \beta_{m'}} = -\frac{1}{\sigma^2} \sum_{\ell=1}^n x_{\ell m} x_{\ell m'}. \quad (16)$$

Se nós aplicamos a esperança e multiplicamos por -1 em (16), obtemos  $(m, m')$ -ésimo elemento da matriz de informação de Fisher do EMV de  $\beta$ .





# Método da máxima verossimilhança

Derivando (9), uma segunda vez, em relação ao parâmetro  $\beta_{m'}$ ,  $m' = 1, 2, \dots, p$ , nós temos:

$$\frac{\partial^2 l(\beta, \sigma^2)}{\partial \beta_m \partial \beta_{m'}} = -\frac{1}{\sigma^2} \sum_{\ell=1}^n x_{\ell m} x_{\ell m'}. \quad (16)$$

Se nós aplicamos a esperança e multiplicamos por -1 em (16), obtemos  $(m, m')$ -ésimo elemento da matriz de informação de Fisher do EMV de  $\beta$ .



# Método da máxima verossimilhança

Lembrando que, a equação (10) é a função escore. Em notação matricial, o vetor escore e a matriz de informação de Fisher são dadas, respectivamente, por



# Método da máxima verossimilhança

Lembrando que, a equação (10) é a função escore. Em notação matricial, o vetor escore e a matriz de informação de Fisher são dadas, respectivamente, por

$$\mathbf{U}_\beta = \frac{1}{\sigma^2} \mathbf{X}^\top (\mathbf{Y} - \mathbf{X}\beta) \text{ e } \mathbf{K}_\beta = \frac{1}{\sigma^2} \mathbf{X}^\top \mathbf{X}. \quad (17)$$



# Método da máxima verossimilhança

Lembrando que, a equação (10) é a função escore. Em notação matricial, o vetor escore e a matriz de informação de Fisher são dadas, respectivamente, por

$$\mathbf{U}_\beta = \frac{1}{\sigma^2} \mathbf{X}^\top (\mathbf{Y} - \mathbf{X}\beta) \text{ e } \mathbf{K}_\beta = \frac{1}{\sigma^2} \mathbf{X}^\top \mathbf{X}. \quad (17)$$



# Considerações

Embora seja comum utilizar  $\hat{Y}_l = \mathbf{x}_l^\top \hat{\beta}$ ,

# Considerações

Embora seja comum utilizar  $\hat{Y}_\ell = \mathbf{x}_\ell^\top \hat{\boldsymbol{\beta}}$ , o que, de fato, nós estamos estimando é  $\mu_\ell$ .

# Considerações

Embora seja comum utilizar  $\hat{Y}_\ell = \mathbf{x}_\ell^\top \hat{\boldsymbol{\beta}}$ , o que, de fato, nós estamos estimando é  $\mu_\ell$ . Basta lembrar que,  $\mu_\ell = \mathbb{E}(Y_\ell) = \mathbf{x}_\ell^\top \boldsymbol{\beta}$ .



# Considerações

Embora seja comum utilizar  $\hat{Y}_\ell = \mathbf{x}_\ell^\top \hat{\boldsymbol{\beta}}$ , o que, de fato, nós estamos estimando é  $\mu_\ell$ . Basta lembrar que,  $\mu_\ell = \mathbb{E}(Y_\ell) = \mathbf{x}_\ell^\top \boldsymbol{\beta}$ .





# Roteiro

- 1 Introdução
- 2 Método dos mínimos quadrados
- 3 Método da máxima verossimilhança
- 4 Aplicações**
- 5 Estudo de simulação
- 6 Referências bibliográficas



**Aplicação 1.** Conjunto de dados *Westwood Company* (Neter et al., 1983, p. 36). Após o ajuste (estimação dos parâmetros), nós temos o seguinte modelo estimado,

$$\hat{Y}_l = 10 + 2x_{l2},$$

**Aplicação 1.** Conjunto de dados *Westwood Company* (Neter et al., 1983, p. 36). Após o ajuste (estimação dos parâmetros), nós temos o seguinte modelo estimado,

$$\hat{Y}_\ell = 10 + 2x_{\ell 2},$$

em que  $Y_\ell$ : horas trabalhadas,  $x_{\ell 2}$ : tamanho do lote,  $\ell = 1, 2, \dots, 10$  e  $QMRes = 7,5$ .

**Aplicação 1.** Conjunto de dados *Westwood Company* (Neter et al., 1983, p. 36). Após o ajuste (estimação dos parâmetros), nós temos o seguinte modelo estimado,

$$\hat{Y}_\ell = 10 + 2x_{\ell 2},$$

em que  $Y_\ell$ : horas trabalhadas,  $x_{\ell 2}$ : tamanho do lote,  $\ell = 1, 2, \dots, 10$  e  $QMRes = 7,5$ .




Figura 1: GD com a reta ajustada para os dados *Westwood Company*.

Os parâmetros podem ser interpretados da seguinte forma

- $\hat{\beta}_1 = 10$ :

Os parâmetros podem ser interpretados da seguinte forma

- $\hat{\beta}_1 = 10$ : se o tamanho do lote fosse zero, haveria 10 horas trabalhadas;

Os parâmetros podem ser interpretados da seguinte forma

- $\hat{\beta}_1 = 10$ : se o tamanho do lote fosse zero, haveria 10 horas trabalhadas;
- $\hat{\beta}_2 = 2$ :



Os parâmetros podem ser interpretados da seguinte forma

- $\hat{\beta}_1 = 10$ : se o tamanho do lote fosse zero, haveria 10 horas trabalhadas;
- $\hat{\beta}_2 = 2$ : a cada uma unidade aumentada no lote, ocorreria um aumento médio de 2 horas trabalhadas.

Os parâmetros podem ser interpretados da seguinte forma

- $\hat{\beta}_1 = 10$ : se o tamanho do lote fosse zero, haveria 10 horas trabalhadas;
- $\hat{\beta}_2 = 2$ : a cada uma unidade aumentada no lote, ocorreria um aumento médio de 2 horas trabalhadas.

**Aplicação 2.** Conjunto de dados Walker (1962). Após o ajuste, nós temos o seguinte modelo estimado,

$$\hat{Y}_\ell = -7,211 + 3,603x_{\ell 2} - 10,065x_{\ell 3},$$

**Aplicação 2.** Conjunto de dados Walker (1962). Após o ajuste, nós temos o seguinte modelo estimado,

$$\hat{Y}_\ell = -7,211 + 3,603x_{\ell 2} - 10,065x_{\ell 3},$$

em que  $Y_\ell$ : número de pulsações,  $x_{\ell 2}$ : temperatura,  $x_{\ell 3}$  a espécie do grilo,  $x_{\ell 3} \in \{Oecanthus exclamationis (ex), Oecanthus niveus (niv)\}$ ,  $\ell = 1, 2, \dots, 31$  e  $QMRes = 12,764$ .

**Aplicação 2.** Conjunto de dados Walker (1962). Após o ajuste, nós temos o seguinte modelo estimado,

$$\hat{Y}_\ell = -7,211 + 3,603x_{\ell 2} - 10,065x_{\ell 3},$$

em que  $Y_\ell$ : número de pulsações,  $x_{\ell 2}$ : temperatura,  $x_{\ell 3}$  a espécie do grilo,  $x_{\ell 3} \in \{Oecanthus exclamationis (ex), Oecanthus niveus (niv)\}$ ,  $\ell = 1, 2, \dots, 31$  e  $QMRes = 12,764$ .

Uma forma alternativa de apresentar o modelo ajustado é a seguinte:

$$\left\{ \begin{array}{l} \textit{Oecanthus niveus} : \quad \hat{Y}_\ell = -17,276 + 3,603x_{\ell 2} \\ \textit{Oecanthus exclamationis} : \quad \hat{Y}_\ell = -7,211 + 3,603x_{\ell 2} \end{array} \right.$$

Uma forma alternativa de apresentar o modelo ajustado é a seguinte:

$$\left\{ \begin{array}{l} \textit{Oecanthus niveus} : \quad \hat{Y}_\ell = -17,276 + 3,603x_{\ell 2} \\ \textit{Oecanthus exclamationis} : \quad \hat{Y}_\ell = -7,211 + 3,603x_{\ell 2} \end{array} \right. .$$




Figura 2: GD com as retas ajustadas para os dados de Walker (1962).





# Aplicações

Os parâmetros podem ser interpretados da seguinte forma

- $\hat{\beta}_1 = -7,211$ :



# Aplicações

Os parâmetros podem ser interpretados da seguinte forma

- $\hat{\beta}_1 = -7,211$ : se a temperatura fosse zero e a espécie do grilo fosse a *Oecanthus exclamationis*, o número médio de pulsações seria de -7,211 (faz sentido?);



# Aplicações

Os parâmetros podem ser interpretados da seguinte forma

- $\hat{\beta}_1 = -7,211$ : se a temperatura fosse zero e a espécie do grilo fosse a *Oecanthus exclamationis*, o número médio de pulsações seria de -7,211 (faz sentido?);
- $\hat{\beta}_2 = 3,603$ :



# Aplicações

Os parâmetros podem ser interpretados da seguinte forma

- $\hat{\beta}_1 = -7,211$ : se a temperatura fosse zero e a espécie do grilo fosse a *Oecanthus exclamationis*, o número médio de pulsações seria de -7,211 (faz sentido?);
- $\hat{\beta}_2 = 3,603$ : a cada uma unidade aumentada na temperatura, haveria um aumento médio de 3,603 nas pulsações;



# Aplicações

Os parâmetros podem ser interpretados da seguinte forma

- $\hat{\beta}_1 = -7,211$ : se a temperatura fosse zero e a espécie do grilo fosse a *Oecanthus exclamationis*, o número médio de pulsações seria de -7,211 (faz sentido?);
- $\hat{\beta}_2 = 3,603$ : a cada uma unidade aumentada na temperatura, haveria um aumento médio de 3,603 nas pulsações;
- $\hat{\beta}_3 = -10,065$ :



# Aplicações

Os parâmetros podem ser interpretados da seguinte forma

- $\hat{\beta}_1 = -7,211$ : se a temperatura fosse zero e a espécie do grilo fosse a *Oecanthus exclamationis*, o número médio de pulsações seria de -7,211 (faz sentido?);
- $\hat{\beta}_2 = 3,603$ : a cada uma unidade aumentada na temperatura, haveria um aumento médio de 3,603 nas pulsações;
- $\hat{\beta}_3 = -10,065$ : a espécie *Oecanthus niveus* tem, em média, - 10,065 pulsações a menos que a *Oecanthus exclamationis*.



# Aplicações

Os parâmetros podem ser interpretados da seguinte forma

- $\hat{\beta}_1 = -7,211$ : se a temperatura fosse zero e a espécie do grilo fosse a *Oecanthus exclamationis*, o número médio de pulsações seria de -7,211 (faz sentido?);
- $\hat{\beta}_2 = 3,603$ : a cada uma unidade aumentada na temperatura, haveria um aumento médio de 3,603 nas pulsações;
- $\hat{\beta}_3 = -10,065$ : a espécie *Oecanthus niveus* tem, em média, - 10,065 pulsações a menos que a *Oecanthus exclamationis*.



# Roteiro

- 1 Introdução
- 2 Método dos mínimos quadrados
- 3 Método da máxima verossimilhança
- 4 Aplicações
- 5 Estudo de simulação**
- 6 Referências bibliográficas





# Estudo de simulação

Suponham o seguinte MNL,

$$Y_l = 1 + x_{l2} + \varepsilon_l,$$

# Estudo de simulação

Suponham o seguinte MNL,

$$Y_\ell = 1 + x_{\ell 2} + \varepsilon_\ell,$$

em que  $x_{\ell 2}$  é quantidade conhecida e  $\varepsilon_\ell \sim \mathcal{N}(0, 4)$ ,  $\ell = 1, 2, \dots, n$ .

# Estudo de simulação

Suponham o seguinte MNL,

$$Y_\ell = 1 + x_{\ell 2} + \varepsilon_\ell,$$

em que  $x_{\ell 2}$  é quantidade conhecida e  $\varepsilon_\ell \sim \mathcal{N}(0, 4)$ ,  $\ell = 1, 2, \dots, n$ . E nós vamos assumir que  $x_{\ell 2} \sim$  uniforme no intervalo  $(0, 1)$ .

# Estudo de simulação

Suponham o seguinte MNL,

$$Y_\ell = 1 + x_{\ell 2} + \varepsilon_\ell,$$

em que  $x_{\ell 2}$  é quantidade conhecida e  $\varepsilon_\ell \sim \mathcal{N}(0, 4)$ ,  $\ell = 1, 2, \dots, n$ . E nós vamos assumir que  $x_{\ell 2} \sim$  uniforme no intervalo  $(0, 1)$ .



# Estudo de simulação

Nós faremos um estudo de Monte Carlo, com 5.000 réplicas, onde avaliaremos o viés absoluto das estimativas dos parâmetros  $\beta_1$ ,  $\beta_2$  e  $\sigma^2$ ,



# Estudo de simulação

Nós faremos um estudo de Monte Carlo, com 5.000 réplicas, onde avaliaremos o viés absoluto das estimativas dos parâmetros  $\beta_1$ ,  $\beta_2$  e  $\sigma^2$ , neste último, utilizando o QMRes e o EMV,



# Estudo de simulação

Nós faremos um estudo de Monte Carlo, com 5.000 réplicas, onde avaliaremos o viés absoluto das estimativas dos parâmetros  $\beta_1$ ,  $\beta_2$  e  $\sigma^2$ , neste último, utilizando o QMRes e o EMV, para  $n \in \{10, 20, 40, 80, 160\}$ .



# Estudo de simulação

Nós faremos um estudo de Monte Carlo, com 5.000 réplicas, onde avaliaremos o viés absoluto das estimativas dos parâmetros  $\beta_1$ ,  $\beta_2$  e  $\sigma^2$ , neste último, utilizando o QMRes e o EMV, para  $n \in \{10, 20, 40, 80, 160\}$ . Sem perda de generalidade, o viés absoluto para o estimador de  $\theta$  é dada por

$$\text{Viés absoluto} = \left| \hat{\theta}_{MC} - \theta \right|,$$





# Estudo de simulação

Nós faremos um estudo de Monte Carlo, com 5.000 réplicas, onde avaliaremos o viés absoluto das estimativas dos parâmetros  $\beta_1$ ,  $\beta_2$  e  $\sigma^2$ , neste último, utilizando o QMRes e o EMV, para  $n \in \{10, 20, 40, 80, 160\}$ . Sem perda de generalidade, o viés absoluto para o estimador de  $\theta$  é dada por

$$\text{Viés absoluto} = \left| \hat{\theta}_{MC} - \theta \right|,$$

em que  $\hat{\theta}_{MC} = 5.000^{-1} \sum_{i=1}^{5.000} \hat{\theta}_i$ .



# Estudo de simulação

Nós faremos um estudo de Monte Carlo, com 5.000 réplicas, onde avaliaremos o viés absoluto das estimativas dos parâmetros  $\beta_1$ ,  $\beta_2$  e  $\sigma^2$ , neste último, utilizando o QMRes e o EMV, para  $n \in \{10, 20, 40, 80, 160\}$ . Sem perda de generalidade, o viés absoluto para o estimador de  $\theta$  é dada por

$$\text{Viés absoluto} = \left| \hat{\theta}_{MC} - \theta \right|,$$

em que  $\hat{\theta}_{MC} = 5.000^{-1} \sum_{i=1}^{5.000} \hat{\theta}_i$ .






Figura 3: Viés absoluto para  $\beta$ .




Figura 4: Viés absoluto para  $\sigma^2$ , utilizando o QMRes e o EMV.

# Estudo de simulação

## Comentários

Pelas Figuras 3 e 4, nós podemos perceber que, a medida que o tamanho amostral cresce, o viés absoluto converge para zero.

# Estudo de simulação

## Comentários

Pelas Figuras 3 e 4, nós podemos perceber que, a medida que o tamanho amostral cresce, o viés absoluto converge para zero.

# Roteiro

- 1 Introdução
- 2 Método dos mínimos quadrados
- 3 Método da máxima verossimilhança
- 4 Aplicações
- 5 Estudo de simulação
- 6 Referências bibliográficas**



# Referências bibliográficas I

Neter, J., Wasserman, W. e Kutner, M. H. (1983), *Applied linear regression models*, Richard D. Irwin Inc, Homewood, Illinois.

Plackett, R. L. (1949), 'A historical note on the method of least squares', *Biometrika* **36**(3/4), 458–460.

Walker, T. J. (1962), 'The Taxonomy and Calling Songs of United States Tree Crickets (Orthoptera: Gryllidae: Oecanthinae). I. The Genus *Neoxabea* and the *niveus* and *varicornis* Groups of the Genus *Oecanthus*', *Annals of the Entomological Society of America* **55**(3), 303–322.





# Obrigado!

✉ tiago.magalhaes@ufjf.br

📄 ufjf.br/tiago\_magalhaes

🌐 Departamento de Estatística, Sala 319

