

Análise de resíduos

Tiago M. Magalhães

Departamento de Estatística - ICE-UFJF

Juiz de Fora, 27 de abril de 2026



Roteiro

- 1 Introdução
- 2 Resíduos
- 3 Padronização de resíduos
- 4 Gráfico de resíduos
- 5 Estatística PRESS
- 6 Aplicação
- 7 Referências bibliográficas



Roteiro

- 1 Introdução
- 2 Resíduos
- 3 Padronização de resíduos
- 4 Gráfico de resíduos
- 5 Estatística PRESS
- 6 Aplicação
- 7 Referências bibliográficas



Modelo de regressão linear

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

$$Y_\ell = \mathbf{x}_\ell^\top \boldsymbol{\beta} + \varepsilon_\ell, \ell = 1, 2, \dots, n, \quad (1)$$



Modelo de regressão linear

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

$$Y_\ell = \mathbf{x}_\ell^\top \boldsymbol{\beta} + \varepsilon_\ell, \ell = 1, 2, \dots, n, \quad (1)$$

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, $\varepsilon_\ell \sim \mathcal{N}(0, \sigma^2)$, $\varepsilon_1, \varepsilon_2, \dots, \varepsilon_n$ são variáveis aleatórias independentes e com a mesma variância σ^2 , também desconhecida, a ser estimada.



Modelo de regressão linear

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

$$Y_\ell = \mathbf{x}_\ell^\top \boldsymbol{\beta} + \varepsilon_\ell, \ell = 1, 2, \dots, n, \quad (1)$$

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, $\varepsilon_\ell \sim \mathcal{N}(0, \sigma^2)$, $\varepsilon_1, \varepsilon_2, \dots, \varepsilon_n$ são variáveis aleatórias independentes e com a mesma variância σ^2 , também desconhecida, a ser estimada.



Forma matricial

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

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



Forma matricial

A Equação (1) é o que nós definimos como **modelo de regressão normal linear** (MNL), 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 $\boldsymbol{\varepsilon} = (\varepsilon_1, \varepsilon_2, \dots, \varepsilon_n)^\top$, $\boldsymbol{\varepsilon} \sim \mathcal{N}_n(\mathbf{0}, \sigma^2 \mathbf{I}_n)$, sendo $\mathbf{0}$ o vetor nulo de dimensão n , \mathbf{I}_n a matriz identidade de ordem n e $\mathbf{X} = (\mathbf{x}_1, \mathbf{x}_2, \dots, \mathbf{x}_n)^\top$, a matriz de planejamento.



Forma matricial

A Equação (1) é o que nós definimos como **modelo de regressão normal linear** (MNL), 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 $\boldsymbol{\varepsilon} = (\varepsilon_1, \varepsilon_2, \dots, \varepsilon_n)^\top$, $\boldsymbol{\varepsilon} \sim \mathcal{N}_n(\mathbf{0}, \sigma^2 \mathbf{I}_n)$, sendo $\mathbf{0}$ o vetor nulo de dimensão n , \mathbf{I}_n a matriz identidade de ordem n e $\mathbf{X} = (\mathbf{x}_1, \mathbf{x}_2, \dots, \mathbf{x}_n)^\top$, a matriz de planejamento.



Suposições

Resumindo,

- A relação entre as variáveis resposta e as preditoras é linear;



Suposições

Resumindo,

- A relação entre as variáveis resposta e as preditoras é linear;
- O erro tem média zero;



Suposições

Resumindo,

- A relação entre as variáveis resposta e as preditoras é linear;
- O erro tem média zero;
- O erro tem variância constante;



Suposições

Resumindo,

- A relação entre as variáveis resposta e as preditoras é linear;
- O erro tem média zero;
- O erro tem variância constante;
- Os erros não são correlacionados;



Suposições

Resumindo,

- A relação entre as variáveis resposta e as preditoras é linear;
- O erro tem média zero;
- O erro tem variância constante;
- Os erros não são correlacionados;
- Os erros têm distribuição normal, para procedimentos inferenciais.



Suposições

Resumindo,

- A relação entre as variáveis resposta e as preditoras é linear;
- O erro tem média zero;
- O erro tem variância constante;
- Os erros não são correlacionados;
- Os erros têm distribuição normal, para procedimentos inferenciais.



Método de máxima verossimilhança

O **estimador de máxima verossimilhança (EMV)** de β e σ^2 são dados, respectivamente, por:

$$\hat{\beta} = (\mathbf{X}^T \mathbf{X})^{-1} \mathbf{X}^T \mathbf{Y}, \quad (3)$$
$$\hat{\sigma}_{\text{MIV}}^2 = \frac{1}{n} (\mathbf{Y} - \mathbf{X}\hat{\beta})^T (\mathbf{Y} - \mathbf{X}\hat{\beta}).$$

Método de máxima verossimilhança

O **estimador de máxima verossimilhança (EMV)** de β e σ^2 são dados, respectivamente, por:

$$\hat{\beta} = (\mathbf{X}^T \mathbf{X})^{-1} \mathbf{X}^T \mathbf{Y}, \quad (3)$$
$$\hat{\sigma}_{\text{MV}}^2 = \frac{1}{n} (\mathbf{Y} - \mathbf{X}\hat{\beta})^T (\mathbf{Y} - \mathbf{X}\hat{\beta}).$$

Observação: o EMV de σ^2 também pode ser escrito como função do quadrado médio do resíduo (QMRes).



Método de máxima verossimilhança

O **estimador de máxima verossimilhança** (EMV) de β e σ^2 são dados, respectivamente, por:

$$\hat{\beta} = (\mathbf{X}^T \mathbf{X})^{-1} \mathbf{X}^T \mathbf{Y}, \quad (3)$$
$$\hat{\sigma}_{\text{MV}}^2 = \frac{1}{n} (\mathbf{Y} - \mathbf{X}\hat{\beta})^T (\mathbf{Y} - \mathbf{X}\hat{\beta}).$$

Observação: o EMV de σ^2 também pode ser escrito como função do quadrado médio do resíduo (QMRes).



Método de máxima verossimilhança

Sob as condições de regularidades, nós temos que:

$$\begin{aligned}\hat{\beta} &\sim \mathcal{N}_p \left\{ \beta, \sigma^2 (\mathbf{X}^\top \mathbf{X})^{-1} \right\}, \\ \hat{\sigma}_{\text{MV}}^2 &\sim \mathcal{N} \left\{ \sigma^2, \frac{2(\sigma^2)^2}{n} \right\},\end{aligned}\tag{4}$$

Método de máxima verossimilhança

Sob as condições de regularidades, nós temos que:

$$\begin{aligned}\hat{\beta} &\sim \mathcal{N}_p \left\{ \beta, \sigma^2 (\mathbf{X}^\top \mathbf{X})^{-1} \right\}, \\ \hat{\sigma}_{\text{MV}}^2 &\sim \mathcal{N} \left\{ \sigma^2, \frac{2(\sigma^2)^2}{n} \right\},\end{aligned}\tag{4}$$

quando o tamanho de amostra é grande, adicionalmente, $\hat{\beta}$ e $\hat{\sigma}_{\text{MV}}^2$ são ortogonais.

Método de máxima verossimilhança

Sob as condições de regularidades, nós temos que:

$$\begin{aligned}\hat{\beta} &\sim \mathcal{N}_p \left\{ \beta, \sigma^2 (\mathbf{X}^\top \mathbf{X})^{-1} \right\}, \\ \hat{\sigma}_{\text{MV}}^2 &\sim \mathcal{N} \left\{ \sigma^2, \frac{2(\sigma^2)^2}{n} \right\},\end{aligned}\tag{4}$$

quando o tamanho de amostra é grande, adicionalmente, $\hat{\beta}$ e $\hat{\sigma}_{\text{MV}}^2$ são ortogonais.

Roteiro

- 1 Introdução
- 2 Resíduos**
- 3 Padronização de resíduos
- 4 Gráfico de resíduos
- 5 Estatística PRESS
- 6 Aplicação
- 7 Referências bibliográficas



Resíduos

Nós definimos como o ℓ -ésimo resíduo a diferença,

$$e_\ell = Y_\ell - \hat{Y}_\ell,$$

$\ell = 1, 2, \dots, n$. Com nós vimos anteriormente, o resíduo pode ser expresso de forma matricial:

$$\mathbf{e} = \mathbf{Y} - \hat{\mathbf{Y}} = (\mathbf{I}_n - \mathbf{H})\mathbf{Y},$$

em que $\mathbf{e} = (e_1, e_2, \dots, e_n)^\top$.



Resíduos

Nós definimos como o ℓ -ésimo resíduo a diferença,

$$e_\ell = Y_\ell - \hat{Y}_\ell,$$

$\ell = 1, 2, \dots, n$. Com nós vimos anteriormente, o resíduo pode ser expresso de forma matricial:

$$\mathbf{e} = \mathbf{Y} - \hat{\mathbf{Y}} = (\mathbf{I}_n - \mathbf{H})\mathbf{Y},$$

em que $\mathbf{e} = (e_1, e_2, \dots, e_n)^\top$.



Resíduos

A esperança (o vetor de esperanças) e a variância (matriz de covariâncias) de \mathbf{e} são dadas, respectivamente, por

$$\mathbb{E}(\mathbf{e}) = \mathbf{0} \text{ e } \text{Var}(\mathbf{e}) = \sigma^2(\mathbf{I}_n - \mathbf{H}).$$



Resíduos

A esperança (o vetor de esperanças) e a variância (matriz de covariâncias) de \mathbf{e} são dada, respectivamente, por

$$\mathbb{E}(\mathbf{e}) = \mathbf{0} \text{ e } \text{Var}(\mathbf{e}) = \sigma^2(\mathbf{I}_n - \mathbf{H}).$$

Seja h_{ij} , o (i, j) -ésimo termo da matriz \mathbf{H} , então nós temos que: $\mathbb{E}(e_i) = 0$, $\text{Var}(e_i) = \sigma^2(1 - h_{ii})$ e $\text{Cov}(e_i, e_j) = -\sigma^2 h_{ij}$, $i, j = 1, 2, \dots, n$.



Resíduos

A esperança (o vetor de esperanças) e a variância (matriz de covariâncias) de \mathbf{e} são dada, respectivamente, por

$$\mathbb{E}(\mathbf{e}) = \mathbf{0} \text{ e } \text{Var}(\mathbf{e}) = \sigma^2(\mathbf{I}_n - \mathbf{H}).$$

Seja h_{ij} , o (i, j) -ésimo termo da matriz \mathbf{H} , então nós temos que: $\mathbb{E}(e_i) = 0$, $\text{Var}(e_i) = \sigma^2(1 - h_{ii})$ e $\text{Cov}(e_i, e_j) = -\sigma^2 h_{ij}$, $i, j = 1, 2, \dots, n$.



Adicionalmente, nós podemos definir uma aproximação para a variância média, da seguinte forma:

$$\sum_{\ell=1}^n \frac{(e_{\ell} - \bar{e})^2}{n - p} = \sum_{\ell=1}^n \frac{e_{\ell}^2}{n - p} = \text{QMRes.}$$

Adicionalmente, nós podemos definir uma aproximação para a variância média, da seguinte forma:

$$\sum_{\ell=1}^n \frac{(e_{\ell} - \bar{e})^2}{n - p} = \sum_{\ell=1}^n \frac{e_{\ell}^2}{n - p} = \text{QMRes.}$$

Roteiro

- 1 Introdução
- 2 Resíduos
- 3 Padronização de resíduos**
- 4 Gráfico de resíduos
- 5 Estatística PRESS
- 6 Aplicação
- 7 Referências bibliográficas



Padronização de resíduos

Padronizar os resíduos nos ajuda a identificar valores atípicos (*outliers*) e valores extremos. Nós temos quatro tipos de resíduos padronizados:

- 1 Resíduos semi-estudentizados;



Padronização de resíduos

Padronizar os resíduos nos ajuda a identificar valores atípicos (*outliers*) e valores extremos. Nós temos quatro tipos de resíduos padronizados:

- ① Resíduos semi-estudentizados;
- ② Resíduos studentizados;



Padronização de resíduos

Padronizar os resíduos nos ajuda a identificar valores atípicos (*outliers*) e valores extremos. Nós temos quatro tipos de resíduos padronizados:

- ① Resíduos semi-estudentizados;
- ② Resíduos estudentizados;
- ③ Resíduos *PRESS*;



Padronização de resíduos

Padronizar os resíduos nos ajuda a identificar valores atípicos (*outliers*) e valores extremos. Nós temos quatro tipos de resíduos padronizados:

- ① Resíduos semi-estudentizados;
- ② Resíduos estudentizados;
- ③ Resíduos *PRESS*;
- ④ Resíduos R-student.



Padronização de resíduos

Padronizar os resíduos nos ajuda a identificar valores atípicos (*outliers*) e valores extremos. Nós temos quatro tipos de resíduos padronizados:

- ① Resíduos semi-estudentizados;
- ② Resíduos estudentizados;
- ③ Resíduos *PRESS*;
- ④ Resíduos R-student.



Padronização de resíduos

Os **resíduos semi-estudentizados** ou, simplesmente, denominados de resíduos padronizados são expressos da seguinte forma:

$$d_\ell = \frac{e_\ell}{\sqrt{\sigma^2}}, \quad \ell = 1, 2, \dots, n.$$

Padronização de resíduos

Os **resíduos semi-estudentizados** ou, simplesmente, denominados de resíduos padronizados são expressos da seguinte forma:

$$d_\ell = \frac{e_\ell}{\sqrt{\sigma^2}}, \quad \ell = 1, 2, \dots, n.$$

O parâmetro σ^2 pode ser estimado pelo QMRes. d_ℓ tem média zero e variância, aproximadamente, igual a 1. Valores “grandes” de d_ℓ ($|d_\ell| > 3$) podem indicar a presença de valores atípicos.



Padronização de resíduos

Os **resíduos semi-estudentizados** ou, simplesmente, denominados de resíduos padronizados são expressos da seguinte forma:

$$d_\ell = \frac{e_\ell}{\sqrt{\sigma^2}}, \quad \ell = 1, 2, \dots, n.$$

O parâmetro σ^2 pode ser estimado pelo QMRes. d_ℓ tem média zero e variância, aproximadamente, igual a 1. Valores “grandes” de d_ℓ ($|d_\ell| > 3$) podem indicar a presença de valores atípicos.



Padronização de resíduos

Os **resíduos estudentizados** são expressos da seguinte forma:

$$r_\ell = \frac{e_\ell}{\sqrt{\sigma^2(1 - h_{\ell\ell})}}, \quad \ell = 1, 2, \dots, n.$$

Padronização de resíduos

Os **resíduos estudentizados** são expressos da seguinte forma:

$$r_\ell = \frac{e_\ell}{\sqrt{\sigma^2(1 - h_{\ell\ell})}}, \quad \ell = 1, 2, \dots, n.$$

O parâmetro σ^2 pode ser estimado pelo QMRes. r_ℓ tem média zero e variância igual a 1. Geralmente, os valores de r_ℓ são maiores do que seus correspondentes d_ℓ .



Padronização de resíduos

Os **resíduos estudentizados** são expressos da seguinte forma:

$$r_\ell = \frac{e_\ell}{\sqrt{\sigma^2(1 - h_{\ell\ell})}}, \quad \ell = 1, 2, \dots, n.$$

O parâmetro σ^2 pode ser estimado pelo QMRes. r_ℓ tem média zero e variância igual a 1. Geralmente, os valores de r_ℓ são maiores do que seus correspondentes d_ℓ .



Padronização de resíduos

Seja o ℓ -ésimo **resíduo PRESS** (*prediction error sum of squares*)

$$e_{(\ell)} = Y_{\ell} - \hat{Y}_{(\ell)}, \ell = 1, 2, \dots, n.$$



Padronização de resíduos

Seja o ℓ -ésimo **resíduo PRESS** (*prediction error sum of squares*)

$$e_{(\ell)} = Y_{\ell} - \hat{Y}_{(\ell)}, \quad \ell = 1, 2, \dots, n.$$

em que $\hat{Y}_{(\ell)}$ é a variável resposta ajustada sem a observação ℓ e a ℓ -ésima linha da matriz de planejamento. Esta definição de resíduos pode verificar o quanto incomum é a observação ℓ .



Padronização de resíduos

Seja o ℓ -ésimo **resíduo PRESS** (*prediction error sum of squares*)

$$e_{(\ell)} = Y_{\ell} - \hat{Y}_{(\ell)}, \quad \ell = 1, 2, \dots, n.$$

em que $\hat{Y}_{(\ell)}$ é a variável resposta ajustada sem a observação ℓ e a ℓ -ésima linha da matriz de planejamento. Esta definição de resíduos pode verificar o quanto incomum é a observação ℓ .



Padronização de resíduos

O ℓ -ésimo resíduo PRESS pode ser escrito da seguinte forma (ver Montgomery et al., 2021, p. 619):

$$e_{(\ell)} = \frac{e_{\ell}}{1 - h_{\ell\ell}}, \quad \ell = 1, 2, \dots, n.$$



Padronização de resíduos

O ℓ -ésimo resíduo PRESS pode ser escrito da seguinte forma (ver Montgomery et al., 2021, p. 619):

$$e_{(\ell)} = \frac{e_{\ell}}{1 - h_{\ell\ell}}, \quad \ell = 1, 2, \dots, n.$$

E não é difícil mostrar que:

$$\text{Var}(e_{(\ell)}) = \frac{\sigma^2}{1 - h_{\ell\ell}}, \quad \ell = 1, 2, \dots, n.$$

Padronização de resíduos

O ℓ -ésimo resíduo PRESS pode ser escrito da seguinte forma (ver Montgomery et al., 2021, p. 619):

$$e_{(\ell)} = \frac{e_{\ell}}{1 - h_{\ell\ell}}, \quad \ell = 1, 2, \dots, n.$$

E não é difícil mostrar que:

$$\text{Var}(e_{(\ell)}) = \frac{\sigma^2}{1 - h_{\ell\ell}}, \quad \ell = 1, 2, \dots, n.$$

Padronização de resíduos

Os **resíduos PRESS padronizados** são expressos da seguinte forma:

$$\frac{e_{(\ell)}}{\sqrt{\text{Var}(e_{(\ell)})}} = \frac{e_{\ell}}{\sqrt{\sigma^2(1 - h_{\ell\ell})}}, \ell = 1, 2, \dots, n.$$

Padronização de resíduos

Os **resíduos PRESS padronizados** são expressos da seguinte forma:

$$\frac{e_{(\ell)}}{\sqrt{\text{Var}(e_{(\ell)})}} = \frac{e_{\ell}}{\sqrt{\sigma^2(1 - h_{\ell\ell})}}, \quad \ell = 1, 2, \dots, n.$$

Notem, os resíduos PRESS padronizados coincidem com os studentizados.



Padronização de resíduos

Os **resíduos PRESS padronizados** são expressos da seguinte forma:

$$\frac{e_{(\ell)}}{\sqrt{\text{Var}(e_{(\ell)})}} = \frac{e_{\ell}}{\sqrt{\sigma^2(1 - h_{\ell\ell})}}, \quad \ell = 1, 2, \dots, n.$$

Notem, os resíduos PRESS padronizados coincidem com os studentizados.



Padronização de resíduos

Como nós estamos levando em consideração o ajuste do modelo sem a ℓ -ésima observação, é natural nós pensarmos em um estimador para σ^2 que também desconsidere a observação ℓ . Esse estimador é dado por (ver Montgomery et al., 2021, p. 621):

$$S_{(\ell)}^2 = \frac{(n-p)\text{QMRes} - \frac{e_{\ell}^2}{1-h_{\ell\ell}}}{n-p-1}, \quad \ell = 1, 2, \dots, n.$$



Padronização de resíduos

Como nós estamos levando em consideração o ajuste do modelo sem a ℓ -ésima observação, é natural nós pensarmos em um estimador para σ^2 que também desconsidere a observação ℓ . Esse estimador é dado por (ver Montgomery et al., 2021, p. 621):

$$S_{(\ell)}^2 = \frac{(n-p)\text{QMRes} - \frac{e_{\ell}^2}{1-h_{\ell\ell}}}{n-p-1}, \quad \ell = 1, 2, \dots, n.$$



Padronização de resíduos

O resíduo **R-student** é expresso da seguinte forma:

$$t_l = \frac{e_l}{\sqrt{S_{(l)}^2(1 - h_{ll})}}, \quad l = 1, 2, \dots, n.$$

Padronização de resíduos

O resíduo **R-student** é expresso da seguinte forma:

$$t_\ell = \frac{e_\ell}{\sqrt{S_{(\ell)}^2(1 - h_{\ell\ell})}}, \quad \ell = 1, 2, \dots, n.$$

Este resíduo também é denominado de resíduo estudentizado externamente.



Padronização de resíduos

O resíduo **R-student** é expresso da seguinte forma:

$$t_{\ell} = \frac{e_{\ell}}{\sqrt{S_{(\ell)}^2(1 - h_{\ell\ell})}}, \quad \ell = 1, 2, \dots, n.$$

Este resíduo também é denominado de resíduo estudentizado externamente.

Roteiro

- 1 Introdução
- 2 Resíduos
- 3 Padronização de resíduos
- 4 Gráfico de resíduos**
- 5 Estatística PRESS
- 6 Aplicação
- 7 Referências bibliográficas



Gráfico de resíduos

A disposição dos resíduos em um gráfico nos ajuda a observar o comportamento global deles e a identificar padrões.



Gráfico de resíduos

- Gráfico de probabilidade normal dos resíduos;



Gráfico de resíduos

- Gráfico de probabilidade normal dos resíduos;
 - Verifica a suposição de normalidade.

Gráfico de resíduos

- Gráfico de probabilidade normal dos resíduos;
 - Verifica a suposição de normalidade.
- Resíduos contra os valores ajustado;



Gráfico de resíduos

- Gráfico de probabilidade normal dos resíduos;
 - Verifica a suposição de normalidade.
- Resíduos contra os valores ajustado;
 - Verifica variância não constante;



Gráfico de resíduos

- Gráfico de probabilidade normal dos resíduos;
 - Verifica a suposição de normalidade.
- Resíduos contra os valores ajustado;
 - Verifica variância não constante;
 - Verifica não linearidade;



Gráfico de resíduos

- Gráfico de probabilidade normal dos resíduos;
 - Verifica a suposição de normalidade.
- Resíduos contra os valores ajustado;
 - Verifica variância não constante;
 - Verifica não linearidade;
 - Verifica possíveis valores atípicos.



Gráfico de resíduos

- Gráfico de probabilidade normal dos resíduos;
 - Verifica a suposição de normalidade.
- Resíduos contra os valores ajustado;
 - Verifica variância não constante;
 - Verifica não linearidade;
 - Verifica possíveis valores atípicos.




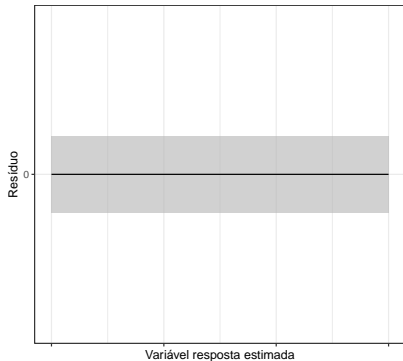



Figura 1: Gráfico de probabilidade normal dos resíduos.



(a) Variância constante.



(b) Variância não constante.

Figura 2: Gráficos de resíduos.

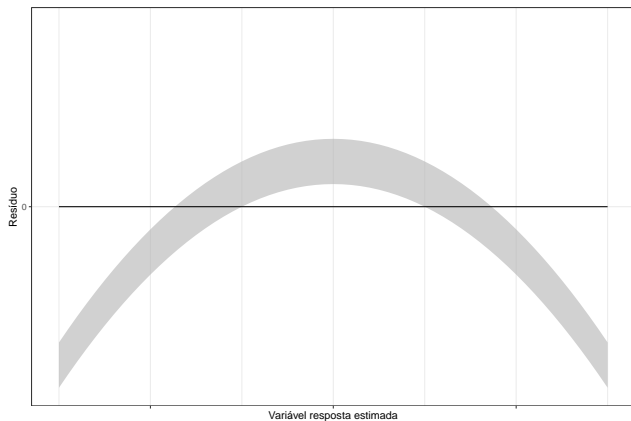


Figura 3: Não linearidade.

Gráfico de resíduos

- Resíduos contra as variáveis regressoras do modelo;

Gráfico de resíduos

- Resíduos contra as variáveis regressoras do modelo;
 - Verifica variância não constante;

Gráfico de resíduos

- Resíduos contra as variáveis regressoras do modelo;
 - Verifica variância não constante;
 - Verifica não linearidade.

Gráfico de resíduos

- Resíduos contra as variáveis regressoras do modelo;
 - Verifica variância não constante;
 - Verifica não linearidade.
- Resíduos contra as variáveis regressoras que não estão modelo;



Gráfico de resíduos

- Resíduos contra as variáveis regressoras do modelo;
 - Verifica variância não constante;
 - Verifica não linearidade.
- Resíduos contra as variáveis regressoras que não estão modelo;
 - Se um padrão aparecer, pode indicar que adicionar esse regressor pode melhorar o ajuste do modelo.



Gráfico de resíduos

- Resíduos contra as variáveis regressoras do modelo;
 - Verifica variância não constante;
 - Verifica não linearidade.
- Resíduos contra as variáveis regressoras que não estão modelo;
 - Se um padrão aparecer, pode indicar que adicionar esse regressor pode melhorar o ajuste do modelo.
- Resíduos contra a ordem das observações.



Gráfico de resíduos

- Resíduos contra as variáveis regressoras do modelo;
 - Verifica variância não constante;
 - Verifica não linearidade.
- Resíduos contra as variáveis regressoras que não estão modelo;
 - Se um padrão aparecer, pode indicar que adicionar esse regressor pode melhorar o ajuste do modelo.
- Resíduos contra a ordem das observações.
 - Verifica erros correlacionados.



Gráfico de resíduos

- Resíduos contra as variáveis regressoras do modelo;
 - Verifica variância não constante;
 - Verifica não linearidade.
- Resíduos contra as variáveis regressoras que não estão modelo;
 - Se um padrão aparecer, pode indicar que adicionar esse regressor pode melhorar o ajuste do modelo.
- Resíduos contra a ordem das observações.
 - Verifica erros correlacionados.






Figura 4: Não independência dos erros.

Gráficos de regressão parcial

Uma alternativa para nós verificarmos a contribuição marginal da variável independente x_m , $m = 1, 2, \dots, p$, no modelo ajustado com as demais variáveis, é através dos gráficos de regressão parcial. Além disso, esse método também pode ser utilizado para verificar a relação correta entre Y e x_m .



Gráficos de regressão parcial

O método consiste em ajustar um modelo de regressão sem a covariável x_m e calcular os resíduos. Em seguida, ajustar um modelo de regressão com x_m como variável resposta e a demais covariáveis como regressoras e calcular os resíduos dessa análise. E, finalmente, construir um gráfico de dispersão com estes dois conjuntos de resíduos.



Gráficos de regressão parcial

Se

- o gráfico parece ser linear, então uma relação linear entre Y e x_m parece ser razoável;

Gráficos de regressão parcial

Se

- o gráfico parece ser linear, então uma relação linear entre Y e x_m parece ser razoável;
- o gráfico for curvilíneo, pode ser necessário trabalhar com x_m^2 ou $1/x_m$;



Gráficos de regressão parcial

Se

- o gráfico parece ser linear, então uma relação linear entre Y e x_m parece ser razoável;
- o gráfico for curvilíneo, pode ser necessário trabalhar com x_m^2 ou $1/x_m$;
- x_m for uma variável candidata e uma “banda” horizontal aparecer, essa variável não adiciona nenhuma informação nova.



Gráficos de regressão parcial

Se

- o gráfico parece ser linear, então uma relação linear entre Y e x_m parece ser razoável;
- o gráfico for curvilíneo, pode ser necessário trabalhar com x_m^2 ou $1/x_m$;
- x_m for uma variável candidata e uma “banda” horizontal aparecer, essa variável não adiciona nenhuma informação nova.



Gráficos de regressão parcial

Considerações:

- Use com cautela, eles apenas sugerem possíveis relações;



Gráficos de regressão parcial

Considerações:

- Use com cautela, eles apenas sugerem possíveis relações;
- Geralmente não detectam efeitos de interação;



Gráficos de regressão parcial

Considerações:

- Use com cautela, eles apenas sugerem possíveis relações;
- Geralmente não detectam efeitos de interação;
- Se houver multicolinearidade, os gráficos de regressão podem fornecer informações incorretas.

Gráficos de regressão parcial

Considerações:

- Use com cautela, eles apenas sugerem possíveis relações;
- Geralmente não detectam efeitos de interação;
- Se houver multicolinearidade, os gráficos de regressão podem fornecer informações incorretas.



Outros gráficos

Construir um gráfico de dispersão para todos os pares de covariáveis, isto pode dar informações sobre a relação entre elas, como:

- uma possível correlação;



Outros gráficos

Construir um gráfico de dispersão para todos os pares de covariáveis, isto pode dar informações sobre a relação entre elas, como:

- uma possível correlação;
- a existência de “pontos remotos”.



Outros gráficos

Construir um gráfico de dispersão para todos os pares de covariáveis, isto pode dar informações sobre a relação entre elas, como:

- uma possível correlação;
- a existência de “pontos remotos”.



Roteiro

- 1 Introdução
- 2 Resíduos
- 3 Padronização de resíduos
- 4 Gráfico de resíduos
- 5 Estatística PRESS**
- 6 Aplicação
- 7 Referências bibliográficas



Estatística PRESS

Uma valiosa maneira para comparação de modelos é a estatística PRESS (Montgomery et al., 2021), ela é definida da seguinte forma

$$\text{PRESS} = \sum_{\ell=1}^n e_{(\ell)}^2 = \sum_{\ell=1}^n \{Y_{\ell} - \hat{Y}_{(\ell)}\}^2 = \sum_{\ell=1}^n \left\{ \frac{e_{\ell}}{1 - h_{\ell\ell}} \right\}^2.$$



Estatística PRESS

Uma valiosa maneira para comparação de modelos é a estatística PRESS (Montgomery et al., 2021), ela é definida da seguinte forma

$$\text{PRESS} = \sum_{\ell=1}^n e_{(\ell)}^2 = \sum_{\ell=1}^n \{Y_{\ell} - \hat{Y}_{(\ell)}\}^2 = \sum_{\ell=1}^n \left\{ \frac{e_{\ell}}{1 - h_{\ell\ell}} \right\}^2.$$

Observação: valores pequenos da estatística PRESS são desejados.



Estatística PRESS

Uma valiosa maneira para comparação de modelos é a estatística PRESS (Montgomery et al., 2021), ela é definida da seguinte forma

$$\text{PRESS} = \sum_{\ell=1}^n e_{(\ell)}^2 = \sum_{\ell=1}^n \{Y_{\ell} - \hat{Y}_{(\ell)}\}^2 = \sum_{\ell=1}^n \left\{ \frac{e_{\ell}}{1 - h_{\ell\ell}} \right\}^2.$$

Observação: valores pequenos da estatística PRESS são desejados.



Estatística PRESS

Também é possível definir um coeficiente de determinação da estatística PRESS da seguinte forma,

$$R^2 = 1 - \frac{\text{PRESS}}{\text{SQT}}.$$



Estatística PRESS

Também é possível definir um coeficiente de determinação da estatística PRESS da seguinte forma,

$$R^2 = 1 - \frac{\text{PRESS}}{\text{SQT}}.$$

Interpretação: nós esperamos que o modelo explique cerca de $R^2\%$ da variabilidade na previsão de uma nova observação.



Estatística PRESS

Também é possível definir um coeficiente de determinação da estatística PRESS da seguinte forma,

$$R^2 = 1 - \frac{\text{PRESS}}{\text{SQT}}.$$

Interpretação: nós esperamos que o modelo explique cerca de $R^2\%$ da variabilidade na previsão de uma nova observação.



Roteiro

- 1 Introdução
- 2 Resíduos
- 3 Padronização de resíduos
- 4 Gráfico de resíduos
- 5 Estatística PRESS
- 6 Aplicação**
- 7 Referências bibliográficas



Aplicação

(Montgomery et al., 2021, p. 76) Um conjunto de dados que relaciona o tempo de entrega de máquinas de venda automática (Y , em minutos) com o número de máquinas em estoque (x_2) e o comprimento da rota (x_3 , em pés). Após o ajuste, nós temos o seguinte modelo estimado,

$$\hat{Y}_\ell = 2,341 + 1,661x_{\ell 2} + 0,014x_{\ell 3},$$

$$\ell = 1, 2, \dots, 25.$$



Aplicação

(Montgomery et al., 2021, p. 76) Um conjunto de dados que relaciona o tempo de entrega de máquinas de venda automática (Y , em minutos) com o número de máquinas em estoque (x_2) e o comprimento da rota (x_3 , em pés). Após o ajuste, nós temos o seguinte modelo estimado,

$$\hat{Y}_\ell = 2,341 + 1,661x_{\ell 2} + 0,014x_{\ell 3},$$

$$\ell = 1, 2, \dots, 25.$$



Exemplo

Nós temos também que:

Tabela 1: Estimativas do parâmetros.

Parâmetro	Estimativa	EP	t_c
β_1	2,341	1,097	2,135
β_2	1,616	0,171	9,464
β_3	0,014	0,004	3,981

Região crítica, para $\alpha = 5\%$: $|t_c| > 2,074$ com $QMRes = 10,164$.



Exemplo


Nós temos também que:

Tabela 1: Estimativas do parâmetros.


Parâmetro	Estimativa	EP	t_c
β_1	2,341	1,097	2,135
β_2	1,616	0,171	9,464
β_3	0,014	0,004	3,981

Região crítica, para $\alpha = 5\%$: $|t_c| > 2,074$ com $QMRes = 10,164$.






(a) Resíduos ordinários.

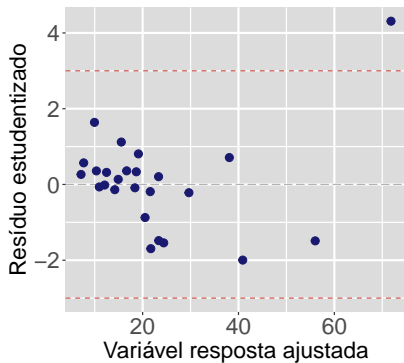


(b) Resíduos PRESS.

Figura 5: Gráficos QQ.



(a) Resíduos ordinários.



(b) Resíduos estudentizados.

Figura 6: Gráficos de resíduos.




Figura 7: Gráfico de dispersão entre as covariáveis

Roteiro

- 1 Introdução
- 2 Resíduos
- 3 Padronização de resíduos
- 4 Gráfico de resíduos
- 5 Estatística PRESS
- 6 Aplicação
- 7 Referências bibliográficas



Referências bibliográficas I

Montgomery, D. C., Peck, E. A. e Vining, G. G. (2021), *Introduction to linear regression analysis*, 6th edn, Wiley, New York.



Obrigado!

✉ tiago.magalhaes@ufjf.br

📄 ufjf.br/tiago_magalhaes

🌐 Departamento de Estatística, Sala 319

