

# Multicolinearidade

Gilberto A. Paula

Departamento de Estatística  
IME-USP, Brasil  
giapaula@ime.usp.br

1<sup>o</sup> Semestre 2023

- 1 Introdução
- 2 Ortogonalidade
- 3 Fontes de Multicolinearidade
- 4 Exemplo Ilustrativo
- 5 Efeitos da Multicolinearidade
- 6 Como Detectar Multicolinearidade
- 7 Tratamentos da Multicolinearidade
- 8 Referências

## Objetivos

Neste material serão apresentados os seguintes tópicos relacionados à multicolinearidade em **Regressão Linear Múltipla**:

- Ortogonalidade
- Fontes de Multicolinearidade
- Efeitos da Multicolinearidade
- Como detectar Multicolinearidade
- Tratamentos da Multicolinearidade
- Referências

- 1 Introdução
- 2 Ortogonalidade**
- 3 Fontes de Multicolinearidade
- 4 Exemplo Ilustrativo
- 5 Efeitos da Multicolinearidade
- 6 Como Detectar Multicolinearidade
- 7 Tratamentos da Multicolinearidade
- 8 Referências

## Regressão Linear Múltipla

Supor o seguinte modelo de regressão linear múltipla:

$$y_i = \beta_1 x_{i1} + \beta_2 x_{i2} + \cdots + \beta_p x_{ip} + \epsilon_i,$$

em que  $y_1, \dots, y_n$  são valores observados da variável resposta,  $x_{i1}, x_{i2}, \dots, x_{ip}$  são valores observados de variáveis explicativas e  $\epsilon_i \stackrel{\text{iid}}{\sim} N(0, \sigma^2)$ .

## Regressão Linear Múltipla

Tem-se ortogonalidade entre as colunas da matriz modelo  $\mathbf{X}$  se

$$\sum_{i=1}^n x_{ij}x_{i\ell} = 0, \quad \forall j \neq \ell = 1, \dots, p.$$

Quando a matriz modelo  $\mathbf{X}$  tem posto coluna completo tem-se sob ortogonalidade que

$$\mathbf{X}^T \mathbf{X} = \text{diag} \left\{ \sum_{i=1}^n x_{i1}^2, \dots, \sum_{i=1}^n x_{ip}^2 \right\} \text{ e } \mathbf{X}^T \mathbf{y} = \left( \sum_{i=1}^n x_{i1}y_i, \dots, \sum_{i=1}^n x_{ip}y_i \right)^T,$$

em que  $\mathbf{y} = (y_1, \dots, y_n)^T$ .

## Regressão Linear Múltipla

Portanto, sob ortogonalidade, segue que

$$\hat{\boldsymbol{\beta}} = \begin{bmatrix} \hat{\beta}_1 \\ \vdots \\ \hat{\beta}_p \end{bmatrix} = (\mathbf{X}^T \mathbf{X})^{-1} \mathbf{X}^T \mathbf{y} = \begin{bmatrix} \frac{\sum_{i=1}^n x_{i1} y_i}{\sum_{i=1}^n x_{i1}^2} \\ \vdots \\ \frac{\sum_{i=1}^n x_{ip} y_i}{\sum_{i=1}^n x_{ip}^2} \end{bmatrix}.$$

Portanto,  $\hat{\beta}_j = \frac{\sum_{i=1}^n x_{ij} y_i}{\sum_{i=1}^n x_{ij}^2}$  depende apenas dos valores  $y_1, \dots, y_n$  e de  $x_{1j}, \dots, x_{nj}$ , para  $j = 1, \dots, p$ .

## Regressão Linear Múltipla

Além disso, a matriz de variância-covariância para  $\hat{\beta}$  fica dada por

$$\text{Var}(\hat{\beta}) = \sigma^2(\mathbf{X}^T \mathbf{X})^{-1} = \begin{bmatrix} \frac{\sigma^2}{\sum_{i=1}^n x_{i1}^2} & \cdots & 0 \\ \vdots & \vdots & \vdots \\ 0 & \cdots & \frac{\sigma^2}{\sum_{i=1}^n x_{ip}^2} \end{bmatrix}.$$

Portanto,  $\text{Var}(\hat{\beta}_j) = \frac{\sigma^2}{\sum_{i=1}^n x_{ij}^2}$  e  $\text{Cov}(\hat{\beta}_j, \hat{\beta}_\ell) = 0$ , para  $j \neq \ell$  e  $j, \ell = 1, \dots, p$ . Tem-se independência mútua entre os estimadores dos coeficientes.

## Regressão Linear Múltipla

Em particular, quando tem-se um intercepto na regressão linear múltipla segue que  $\hat{\beta}_1 = \bar{y}$  e  $\text{Var}(\hat{\beta}_1) = \frac{\sigma^2}{n}$ .

## Multicolinearidade

Multicolinearidade é o oposto da ortogonalidade. Ocorre quando há uma alta correlação linear entre variáveis explicativas e conseqüentemente entre os estimadores dos coeficientes da regressão linear múltipla. Uma consequência prática é que  $\det(\mathbf{X}^T \mathbf{X}) \cong 0$ .

- 1 Introdução
- 2 Ortogonalidade
- 3 Fontes de Multicolinearidade**
- 4 Exemplo Ilustrativo
- 5 Efeitos da Multicolinearidade
- 6 Como Detectar Multicolinearidade
- 7 Tratamentos da Multicolinearidade
- 8 Referências

## Regressão Linear Múltipla

Algumas fontes de multicolinearidade:

- **Método empregado na coleta de dados**

Os dados são coletados de um estrato da população onde há uma alta correlação linear entre duas variáveis explicativas. Por exemplo, num estudo de regressão em que tem-se como variáveis explicativas o consumo de um produto alimentício e o preço do produto alimentício. É razoável esperar nos estratos de renda mais baixa uma correlação mais alta entre as duas variáveis explicativas.

- **Restrições no modelo ou na população**

Duas variáveis explicativas que têm uma correlação linear alta são incluídas no modelo. Por exemplo, consumo de energia elétrica e renda percapita. Notas referentes às avaliações sobre qualidade e clareza das aulas de um instrutor.

## Regressão Linear Múltipla

- **Especificação do modelo**

No modelo são incluídos vários termos que estão em função de uma mesma variável explicativa. Por exemplo, numa regressão polinomial em que são incluídos termos  $x + x^2 + x^3 + \dots$ .

- **Modelo superdimensionado**

Estudos com amostras pequenas e uma grande quantidade de variáveis explicativas. Por exemplo, na área médica em geral tem-se amostras pequenas com uma grande quantidade de informações por paciente.

- 1 Introdução
- 2 Ortogonalidade
- 3 Fontes de Multicolinearidade
- 4 Exemplo Ilustrativo**
- 5 Efeitos da Multicolinearidade
- 6 Como Detectar Multicolinearidade
- 7 Tratamentos da Multicolinearidade
- 8 Referências

### Avaliação de Docentes

Como motivação serão considerados os dados apresentados no livro de Weisberg (2014) e também na biblioteca `alr4` do R, referentes a notas médias recebidas por 364 instrutores de uma universidade norte americana durante um período de 10 anos. O objetivo do estudo é relacionar o interesse do avaliador (`RaterInterest`) (escore de 1 a 5) com as seguintes avaliações feitas pelo avaliador:

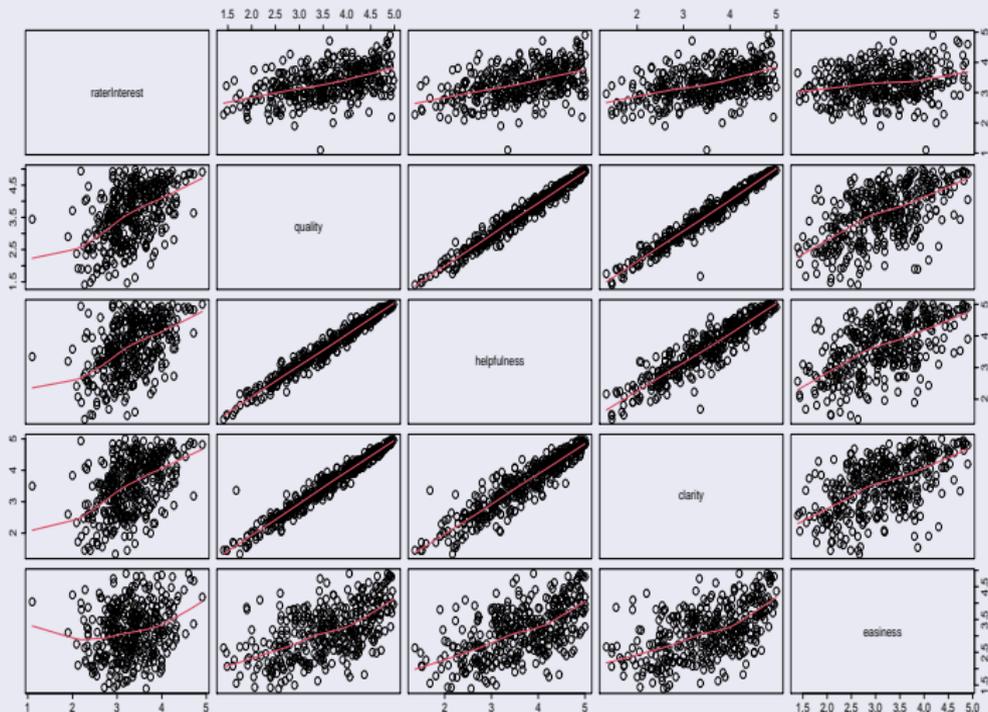
- *Quality*: qualidade das aulas do instrutor (escore de 1 a 5)
- *Helpfulness*: prestatividade do instrutor (escore de 1 a 5)
- *Clarity*: clareza das aulas do instrutor (escore de 1 a 5)
- *Easiness*: facilidade que o instrutor tem com a matéria (escore de 1 a 5).

## Matriz de Correlações Lineares

	RInterest	Quality	Helpfulness	Clarity	Easiness
RInterest	1,0000	0,4707	0,4630	0,4611	0,2052
Quality		1,0000	<b>0,9810</b>	<b>0,9760</b>	0,5651
Helpfulness			1,0000	0,9208	0,5635
Clarity				1,0000	0,5359
Easiness					1,0000

Notas-se altas correlações lineares entre Quality e Helpfulness e entre Quality e Clarity.

## Diagramas de Dispersão



- 1 Introdução
- 2 Ortogonalidade
- 3 Fontes de Multicolinearidade
- 4 Exemplo Ilustrativo
- 5 Efeitos da Multicolinearidade**
- 6 Como Detectar Multicolinearidade
- 7 Tratamentos da Multicolinearidade
- 8 Referências

## Exemplo

Para ilustrar considere o seguinte modelo de regressão linear múltipla:

$$y_i = \beta_1 x_{i1} + \beta_2 x_{i2} + \epsilon_i,$$

em que  $y_1, \dots, y_n$  são valores observados da variável resposta com comprimento unitário,  $x_{i1}$  e  $x_{i2}$  são valores observados de variáveis explicativas com comprimento unitário<sup>a</sup> e  $\epsilon_i \stackrel{\text{iid}}{\sim} N(0, \sigma^2)$ , para  $i = 1, \dots, n$ .

---

<sup>a</sup> $\sum_{i=1}^n x_{ij} = 0$  e  $\sum_{i=1}^n x_{ij}^2 = 1$  para  $j = 1, 2$

## Exemplo

Para esse exemplo tem-se que

$$\mathbf{X}^T \mathbf{X} = \begin{bmatrix} \sum_{i=1}^n x_{i1}^2 & \sum_{i=1}^n x_{i1} x_{i2} \\ \sum_{i=1}^n x_{i2} x_{i1} & \sum_{i=1}^n x_{i2}^2 \end{bmatrix} = \begin{bmatrix} 1 & r_{12} \\ r_{12} & 1 \end{bmatrix},$$

em que  $r_{12}$  denota a correlação linear amostral entre  $X_1$  e  $X_2$ . Além disso

$$\mathbf{X}^T \mathbf{y} = \begin{bmatrix} \sum_{i=1}^n x_{i1} y_i \\ \sum_{i=1}^n x_{i2} y_i \end{bmatrix} = \begin{bmatrix} r_{1y} \\ r_{2y} \end{bmatrix},$$

em que  $r_{1y}$  e  $r_{2y}$  denotam, respectivamente, as correlações lineares amostrais entre  $X_1$  e  $Y$  e  $X_2$  e  $Y$ .

## Exemplo

Portanto, as estimativas de mínimos quadrados ficam dadas por

$$\hat{\beta} = \begin{bmatrix} \hat{\beta}_1 \\ \hat{\beta}_2 \end{bmatrix} = (\mathbf{X}^T \mathbf{X})^{-1} \mathbf{X}^T \mathbf{y} = \begin{bmatrix} \frac{r_{1y} - r_{12}r_{2y}}{(1 - r_{12}^2)} \\ \frac{r_{2y} - r_{12}r_{1y}}{(1 - r_{12}^2)} \end{bmatrix}.$$

Portanto, as estimativas de mínimos quadrados  $\hat{\beta}_1$  e  $\hat{\beta}_2$  dependem das correlações lineares  $r_{12}$ ,  $r_{1y}$  e  $r_{2y}$ .

## Exemplos

Além disso, a matriz de variância-covariância para  $\hat{\beta}$  assume a forma

$$\text{Var}(\hat{\beta}) = \sigma^2(\mathbf{X}^T \mathbf{X})^{-1} = \begin{bmatrix} \frac{\sigma^2}{(1-r_{12}^2)} & -\frac{\sigma^2 r_{12}}{(1-r_{12}^2)} \\ -\frac{\sigma^2 r_{12}}{(1-r_{12}^2)} & \frac{\sigma^2}{(1-r_{12}^2)} \end{bmatrix}.$$

Ou seja,  $\text{Var}(\hat{\beta}_1) = \text{Var}(\hat{\beta}_2) = \frac{\sigma^2}{(1-r_{12}^2)}$  e  $\text{Cov}(\hat{\beta}_1, \hat{\beta}_2) = -\frac{\sigma^2 r_{12}}{(1-r_{12}^2)}$ .

## Consequências

- Se  $|r_{12}| \rightarrow 1$  então  $\text{Var}(\hat{\beta}_1)$  e  $\text{Var}(\hat{\beta}_2)$  ficam grandes.
- Se  $r_{12} \rightarrow 1$  então  $\text{Cov}(\hat{\beta}_1, \hat{\beta}_2) \rightarrow -\infty$ .
- Se  $r_{12} \rightarrow -1$  então  $\text{Cov}(\hat{\beta}_1, \hat{\beta}_2) \rightarrow \infty$ .

- 1 Introdução
- 2 Ortogonalidade
- 3 Fontes de Multicolinearidade
- 4 Exemplo Ilustrativo
- 5 Efeitos da Multicolinearidade
- 6 Como Detectar Multicolinearidade**
- 7 Tratamentos da Multicolinearidade
- 8 Referências

## Fator de Inflação da Variância

Supor o seguinte modelo de regressão linear múltipla:

$$y_i = \beta_1 x_{i1} + \beta_2 x_{i2} + \cdots + \beta_p x_{ip} + \epsilon_i,$$

em que  $y_1, \dots, y_n$  são valores observados da variável resposta,  $x_{i1}, x_{i2}, \dots, x_{ip}$  são valores observados de variáveis explicativas com comprimento unitário<sup>a</sup> e  $\epsilon_j \stackrel{\text{iid}}{\sim} N(0, \sigma^2)$ .

---

<sup>a</sup> $(\mathbf{X}^T \mathbf{X})$  é a matriz de correlações.

### Fator de Inflação da Variância

Seja  $\mathbf{C} = (\mathbf{X}^T \mathbf{X})^{-1} = \{C_{j\ell}\}$ , em que  $C_{j\ell}$  denota o  $(j, \ell)$ -ésimo elemento da matriz  $\mathbf{C}$ , para  $j, \ell = 1, \dots, p$ . É possível mostrar que

$$\text{Var}(\hat{\beta}_j) = \sigma^2 C_{jj} = \sigma^2 (1 - R_j^2)^{-1},$$

em que  $R_j^2$  denota o coeficiente de determinação da regressão linear da variável explicativa  $X_j$  contra as demais variáveis explicativas  $X_\ell$ , em que  $j \neq \ell$ , para  $j, \ell = 1, \dots, p$ .

### Fator de Inflação da Variância

O fator de inflação de variância da  $j$ -ésima variável explicativa é definido por

$$\text{VIF}_j = (1 - R_j^2)^{-1}.$$

Assim, se  $R_j^2 \rightarrow 1$  então  $\text{VIF}_j \rightarrow \infty$ , para  $j = 1, \dots, p$ .

### Fator de Inflação da Variância

Supor três variáveis explicativas  $X_1$ ,  $X_2$  e  $X_3$  cujos valores amostrais têm comprimento unitário. Os VIFs saem das seguintes regressões:

- $VIF_1$ : da regressão  $x_{i1} = \beta_2 x_{i2} + \beta_3 x_{i3} + \epsilon_i$
- $VIF_2$ : da regressão  $x_{i2} = \beta_1 x_{i1} + \beta_3 x_{i3} + \epsilon_i$
- $VIF_3$ : da regressão  $x_{i3} = \beta_1 x_{i1} + \beta_2 x_{i2} + \epsilon_i$ , para  $i = 1, \dots, n$ .

Critério: se  $VIF_j \geq 10$  indica que  $\hat{\beta}_j$  está com variância inflacionada.

### Análise de Autovalores de $(\mathbf{X}^T \mathbf{X})$

Sejam  $\lambda_1, \lambda_2, \dots, \lambda_p$  os autovalores da matriz  $(\mathbf{X}^T \mathbf{X})$ . Autovalores próximos de zero é indício de multicolinearidade.

### Número da Condição

Uma medida resumo de multicolinearidade entre as colunas da matriz  $\mathbf{X}$  é o **número da condição** definido por

$$k = \frac{\lambda_{\max}}{\lambda_{\min}}.$$

Critério: (i) se  $k \leq 100$  não há indícios de multicolinearidade, (ii) se  $100 < k \leq 1000$  há indícios moderados de multicolinearidade e (iii) se  $k > 1000$  há indícios fortes de multicolinearidade.

## Índice da Condição

Quando há indícios de multicolinearidade através do número da condição, pode-se avaliar a contribuição de cada variável explicativa através do **índice da condição** definido por

$$k_j = \frac{\lambda_{\max}}{\lambda_j},$$

para  $j = 1, \dots, p$ . Os mesmos critérios usados para o número da condição são usados para o índice da condição.

## Determinante da Matrix $(\mathbf{X}^T \mathbf{X})$

Se as variáveis explicativas têm comprimento unitário então

$$0 \leq \det(\mathbf{X}^T \mathbf{X}) \leq 1.$$

Tem-se que  $\det(\mathbf{X}^T \mathbf{X}) = 1$  indica ortogonalidade entre as colunas da matriz  $\mathbf{X}$ , enquanto  $\det(\mathbf{X}^T \mathbf{X}) = 0$  indica dependência linear entre as colunas da matrix  $\mathbf{X}$ . Então, valores próximos de zero são indícios de multicolinearidade.

- 1 Introdução
- 2 Ortogonalidade
- 3 Fontes de Multicolinearidade
- 4 Exemplo Ilustrativo
- 5 Efeitos da Multicolinearidade
- 6 Como Detectar Multicolinearidade
- 7 Tratamentos da Multicolinearidade**
- 8 Referências

## Regressão Linear Múltipla

Alguns tratamentos para a multicolinearidade

- Coletar mais dados.
- Eliminação de variáveis explicativas.
- Transformação de variáveis explicativas.
- Regressão Ridge.
- Regressão através de componentes principais.

## Regressão Ridge

O objetivo da **regressão ridge** é utilizar um estimador tendencioso que produza variâncias mais estáveis para os estimadores dos coeficientes da regressão.

## Erro Quadrático Médio

Seja  $\hat{\beta}^*$  um estimador tendencioso de  $\beta$ . O erro quadrático médio de  $\hat{\beta}^*$  pode ser expresso na forma

$$\text{EQM}(\hat{\beta}^*) = \text{Var}(\hat{\beta}^*) + [\text{Viés}][\text{Viés}]^T,$$

em que  $\text{Viés} = E(\hat{\beta}^*) - \beta$ .

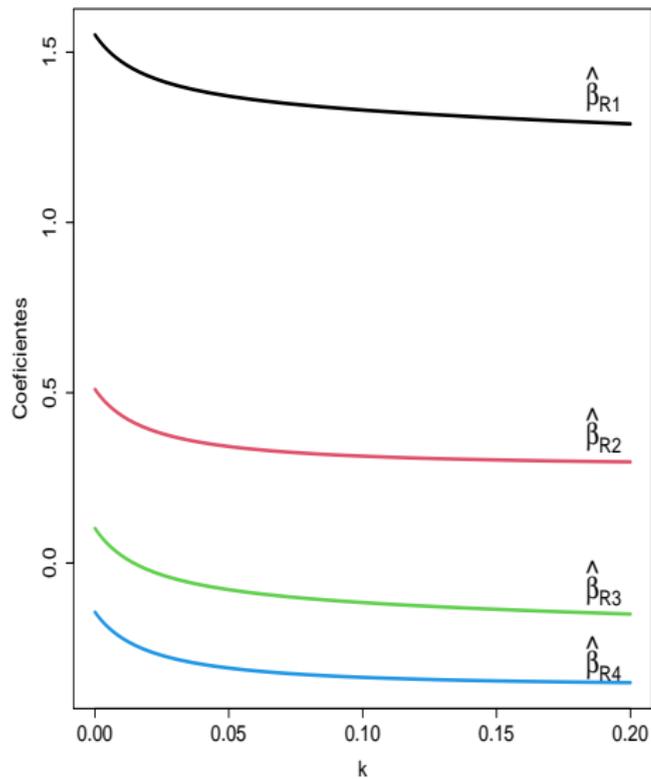
## Estimador Ridge

A fim de estabilizar as estimativas dos coeficientes da regressão linear múltipla bem com as respectivas variâncias é proposto o seguinte estimador:

$$\hat{\beta}_R = (\mathbf{X}^T \mathbf{X} + k\mathbf{I}_p)^{-1} \mathbf{X}^T \mathbf{y},$$

em que  $k > 0$  é uma constante desconhecida que é estimada separadamente. Em particular quando  $k = 0$  recupera-se o estimador de mínimos quadrados. Estima-se  $k$  até estabilizar as estimativas dos coeficientes.

# Ilustração Regressão Ridge



## Propriedades

Denote  $\hat{\beta}_R = \mathbf{Z}_k \hat{\beta}$ , em que  $\mathbf{Z}_k = (\mathbf{X}^\top \mathbf{X} + k\mathbf{I}_p)^{-1} (\mathbf{X}^\top \mathbf{X})$ . Tem-se as seguintes propriedades:

- $E(\hat{\beta}_R) = E(\mathbf{Z}_k \hat{\beta}) = \mathbf{Z}_k E(\hat{\beta}) = \mathbf{Z}_k \beta$ .
- $\text{Var}(\hat{\beta}_R) = \text{Var}(\mathbf{Z}_k \hat{\beta}) = \mathbf{Z}_k \text{Var}(\hat{\beta}) \mathbf{Z}_k^\top = \sigma^2 (\mathbf{X}^\top \mathbf{X} + k\mathbf{I}_p)^{-1} (\mathbf{X}^\top \mathbf{X}) (\mathbf{X}^\top \mathbf{X} + k\mathbf{I}_p)^{-1}$ .

Em particular, se  $(\mathbf{X}^\top \mathbf{X}) = \mathbf{I}_p$  tem-se que  $\mathbf{Z}_k = (1 + k)^{-1} \mathbf{I}_p$ . Portanto,  $E(\hat{\beta}_R) = (1 + k)^{-1} \beta$  e  $\text{Var}(\hat{\beta}_R) = \sigma^2 (1 + k)^{-2} \mathbf{I}_p$ . Ou seja, à medida que  $k$  cresce o estimador ridge fica mais tendencioso havendo um encolhimento com relação ao estimador de mínimos quadrados. A variância diminui com o aumento de  $k$ .

## Propriedades

- Tem-se ainda que  $\hat{\beta}_R \sim N_p(E(\hat{\beta}_R), \text{Var}(\hat{\beta}_R))$ .  
Daí segue que  $\hat{\beta}_{R_j}$  são normais de média  $E(\hat{\beta}_{R_j})$  e variância  $\text{Var}(\hat{\beta}_{R_j})$ , para  $j = 1, \dots, p$ .
- É possível mostrar que  $\text{SQRes}(k) = (\mathbf{y} - \mathbf{X}\hat{\beta}_R)^\top (\mathbf{y} - \mathbf{X}\hat{\beta}_R) = \text{SQRes} + (\hat{\beta}_R - \hat{\beta})^\top (\mathbf{X}^\top \mathbf{X})(\hat{\beta}_R - \hat{\beta})$ .

Portanto, com a regressão ridge há um aumento na soma de quadrados de resíduos, logo uma redução no valor de  $R^2$ .

### Estimação de $k$

A constante  $k$  pode ser estimada através do processo iterativo

$$k^{(m+1)} = \frac{p\hat{\sigma}^2}{\hat{\beta}_R(k^{(m)})^\top \hat{\beta}_R(k^{(m)})},$$

para  $m = 0, 1, \dots$ , em que  $\hat{\sigma}^2$  é obtido através do estimador de mínimos quadrados  $\hat{\beta}$ . Para valor inicial utiliza-se o estimador de HKB (Hoerl, Kennard e Baldwin, 1975) dado por  $k^{(0)} = p\hat{\sigma}^2 / \hat{\beta}^\top \hat{\beta}$ .

### Procedimentos de Diagnóstico

Métodos de diagnóstico para a regressão ridge podem ser obtidos dos métodos de diagnóstico para regressão não paramétrica.

## Forma Canônica

A **forma canônica** da regressão linear múltipla  $\mathbf{y} = \mathbf{X}\boldsymbol{\beta} + \boldsymbol{\epsilon}$  é definida por

$$\mathbf{y} = \mathbf{Z}\boldsymbol{\alpha} + \boldsymbol{\epsilon},$$

em que  $\boldsymbol{\epsilon} \sim N_n(\mathbf{0}, \sigma^2 \mathbf{I}_n)$ ,  $\mathbf{Z} = \mathbf{X}\mathbf{T}$ ,  $\boldsymbol{\alpha} = \mathbf{T}^\top \boldsymbol{\beta}$  e  $\mathbf{Z}^\top \mathbf{Z} = \mathbf{T}^\top \mathbf{X}^\top \mathbf{X} \mathbf{T} = \boldsymbol{\Lambda}$ , com  $\boldsymbol{\Lambda} = \text{diag}\{\lambda_1, \dots, \lambda_p\}$  sendo a matriz diagonal  $p \times p$  com os autovalores da matriz  $\mathbf{X}^\top \mathbf{X}$  e  $\mathbf{T}$  a matriz  $p \times p$  cujas colunas são os autovetores ortogonais correspondentes aos autovalores  $\lambda_1, \dots, \lambda_p$ . Como  $\mathbf{X}^\top \mathbf{X}$  é positiva definida todos os seus autovalores são positivos. Sugere-se que  $\mathbf{y}$  e a matriz  $\mathbf{X}$  **sejam centralizadas**, assim não precisa de intercepto.

## Efeito na Variância de $\hat{\alpha}_j$

Portanto, tem-se que

$$\begin{aligned}\hat{\alpha} &= (\mathbf{Z}^T \mathbf{Z})^{-1} \mathbf{Z}^T \mathbf{y} \\ &= \mathbf{\Lambda}^{-1} \mathbf{Z}^T \mathbf{y} \text{ e} \\ \text{Var}(\hat{\alpha}) &= \sigma^2 (\mathbf{Z}^T \mathbf{Z})^{-1} \\ &= \sigma^2 \mathbf{\Lambda}^{-1}.\end{aligned}$$

Pode-se mostrar que  $\text{Var}(\hat{\alpha}_j) = \sigma^2 \lambda_j^{-1}$ . Assim,  $\lambda_j$  próximo de zero inflaciona a variância de  $\hat{\alpha}_j$ .

## Efeito na Variância de $\hat{\beta}_j$

Similarmente, segue que

$$\begin{aligned}\text{Var}(\hat{\beta}) &= \text{Var}(\mathbf{T}\hat{\alpha}) \\ &= \mathbf{T}\text{Var}(\hat{\alpha})\mathbf{T}^\top \\ &= \sigma^2\mathbf{T}\mathbf{\Lambda}^{-1}\mathbf{T}^\top.\end{aligned}$$

E daí pode-se mostrar que  $\text{Var}(\hat{\beta}_j) = \sigma^2 \sum_{\ell=1}^p t_{j\ell}^2 / \lambda_\ell$ , em que  $t_{j\ell}$  denota o  $(j, \ell)$ -ésimo elemento da matriz  $\mathbf{T}$ . Verifica-se aqui também o efeito de autovalores próximos de zero na variância de  $\hat{\beta}_j$ .

## Seleção dos Coeficientes

A proposta é considerar os coeficientes estimados

$$\hat{\alpha}_1^{CP}, \dots, \hat{\alpha}_{p-s}^{CP}$$

com os  $p - s$  maiores autovalores e os demais  $s$  coeficientes como sendo iguais a zero. Assim, da relação  $\hat{\beta} = \mathbf{T}\hat{\alpha}$  obtém-se os coeficientes estimados

$$\hat{\beta}_1^{CP}, \dots, \hat{\beta}_p^{CP}$$

que serão considerados na regressão linear múltipla. Ou seja, os coeficientes estimados segundo o critério de componentes principais serão dados por  $\hat{\beta}^{CP} = \mathbf{T}\hat{\alpha}^{CP}$ . Porém, os erros padrão desses coeficientes estimados devem ser extraídos da relação

$$\text{Var}(\hat{\beta}) = \sigma^2 \mathbf{T}\mathbf{\Lambda}^{-1}\mathbf{T}^T.$$

## Interpretação dos Componentes Principais

Da relação  $\mathbf{Z} = \mathbf{X}\mathbf{T}$  segue que

$$\mathbf{z}_j = \sum_{\ell=1}^p \mathbf{x}_\ell t_{\ell j},$$

em que  $\mathbf{z}_1, \dots, \mathbf{z}_p$  e  $\mathbf{x}_1, \dots, \mathbf{x}_p$  denotam, respectivamente, as colunas de  $\mathbf{Z}$  e  $\mathbf{X}$ , enquanto  $t_{1j}, \dots, t_{pj}$  denotam os componentes do autovetor correspondente ao autovalor  $\lambda_j$ . Assim, se  $\lambda_j$  for próximo de zero os componentes de  $\mathbf{z}_j$  devem ser aproximadamente constantes. Deve-se portanto escolher os  $p - s$  componentes principais  $\mathbf{z}_1, \dots, \mathbf{z}_{(p-s)}$  que correspondem aos  $p - s$  maiores autovalores.

- 1 Introdução
- 2 Ortogonalidade
- 3 Fontes de Multicolinearidade
- 4 Exemplo Ilustrativo
- 5 Efeitos da Multicolinearidade
- 6 Como Detectar Multicolinearidade
- 7 Tratamentos da Multicolinearidade
- 8 Referências**

## Referências

- Montgomery, D. C.; Peck, E. A. e Vining, G. G. (2021). *Introduction to Linear Regression Analysis, 6th Edition*.
- Weisberg, S. (2014) *Applied Linear Regression, 5th Edition*. Wiley. Hoboken: Wiley.