

# Seleção de Modelos

Gilberto A. Paula

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

1<sup>o</sup> Semestre 2023

- 1 Introdução
- 2 Todas Regressões Possíveis
- 3 Métodos Sequenciais
- 4 Estratégias para Seleção de Modelos
- 5 Referências

## Objetivos

Neste material serão apresentados os seguintes tópicos relacionados à seleção de modelos em **Regressão Linear Múltipla**:

- Todas Regressões Possíveis
- Métodos Sequenciais
- Estratégias para Seleção de Modelos
- Referências

## Regressão Linear Múltipla

Supor o seguinte modelo de regressão linear múltipla:

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

em que  $y_1, \dots, y_n$  são valores observados da variável resposta,  $x_{i2}, \dots, x_{ip}$  são valores observados de  $(p - 1)$  variáveis explicativas e  $\epsilon_i \stackrel{\text{iid}}{\sim} N(0, \sigma^2)$ .

## Regressão Linear Múltipla

Supor que  $p = p_1 + p_2$  e que  $p_2$  coeficientes são removidos no modelo de regressão linear múltipla. A remoção desses coeficientes diferentes de zero:

- Introduz viés nas estimativas do submodelo.
- Não aumenta as variâncias das estimativas do submodelo, nem do erro quadrático médio.

- 1 Introdução
- 2 Todas Regressões Possíveis**
- 3 Métodos Sequenciais
- 4 Estratégias para Seleção de Modelos
- 5 Referências

## Definição

Supor um total de  $(p - 1)$  variáveis explicativas a serem selecionadas num modelo de regressão e seja  $T$  o total de regressões possíveis. Tem-se que

$$T = 1 + \binom{p-1}{1} + \binom{p-1}{2} + \cdots + \binom{p-1}{p-1} = 2^{(p-1)}.$$

Por exemplo, se  $p = 4$  (3 variáveis explicativas), haverá um total de  $T = 1 + 3 + 3 + 1 = 8$  regressões possíveis.

## Maior $R_k^2$


Seja  $R_k^2$  o coeficiente de determinação de um submodelo com  $k$  coeficientes (( $k - 1$ ) variáveis explicativas + o intercepto). Tem-se que

$$R_k^2 = \frac{\text{SQReg}(k)}{\text{SQT}} = 1 - \frac{\text{SQRes}(k)}{\text{SQT}}.$$

Esse critério procura um submodelo com  $R_k^2$  alto e  $k$  pequeno.



# Gráfico de $R^2_k$ contra $k$



## Maior $R_k^2$ ajustado

Denote  $\bar{R}_k^2$ :  $R_{\text{ajustado}}^2$  do submodelo com  $k$  coeficientes ( $(k - 1)$  variáveis explicativas + intercepto)

$$\bar{R}_k^2 = 1 - (1 - R_k^2) \frac{(n - 1)}{(n - k)}.$$

Alternativamente, pode-se adotar como critério selecionar um submodelo com  $\bar{R}_k^2$  alto e  $k$  pequeno. Contudo,  $\bar{R}_k^2$  não necessariamente cresce com  $k$ .


## Menor $s_k^2$

Seja  $s_k^2$  o erro quadrático médio de um submodelo com  $k$  coeficientes ( $(k - 1)$  variáveis explicativas + o intercepto). Tem-se que

$$s_k^2 = \frac{\text{SQRes}(k)}{n - k}.$$

Esse critério procura um submodelo com  $s_k^2$  pequeno e  $k$  pequeno.

# Gráfico de $s_k^2$ contra $k$



## Relação entre $\bar{R}_k^2$ e $s_k^2$

Tem-se que

$$\begin{aligned}\bar{R}_k^2 &= 1 - \frac{(n-1)}{(n-k)}(1 - R_k^2) \\ &= 1 - \frac{(n-1)}{(n-k)} \left\{ 1 - \frac{\text{SQReg}(k)}{\text{SQT}} \right\} \\ &= 1 - \frac{(n-1)}{(n-k)} \frac{\text{SQRes}(k)}{\text{SQT}} \\ &= 1 - \frac{(n-1)}{\text{SQT}} \frac{\text{SQRes}(k)}{n-k} \\ &= 1 - \frac{(n-1)}{\text{SQT}} s_k^2.\end{aligned}$$

## Relação entre $\bar{R}_k^2$ e $s_k^2$

Portanto, tem-se que

$$\bar{R}_k^2 = 1 - \frac{(n-1)}{SQT} s_k^2.$$

Assim, minimizar  $s_k^2$  é equivalente a maximizar  $\bar{R}_k^2$ .

## Critério $C_k$ de Mallows

O **critério de Mallows** está relacionado com o erro quadrático médio do  $i$ -ésimo valor ajustado  $\hat{Y}_i$  do submodelo com  $k$  coeficientes

$$E\{\hat{Y}_i - E(Y_i)\}^2 = \text{Var}(\hat{Y}_i) + \{E(\hat{Y}_i) - E(Y_i)\}^2.$$

A soma dos vieses ao quadrado do submodelo com  $k$  coeficientes fica dada por

$$\{\text{Viés}(k)\}^2 = \sum_{i=1}^n \{E(\hat{Y}_i) - E(Y_i)\}^2,$$

em que  $E(Y_i)$  denota o valor esperado do modelo correto.

## Critério $C_k$ de Mallows

O erro quadrático médio padronizado do submodelo com  $k$  coeficientes fica dado por

$$\text{EQM}(k) = \frac{1}{\sigma^2} \left[ \sum_{i=1}^n \{E(\hat{Y}_i) - E(Y_i)\}^2 + \sum_{i=1}^n \text{Var}(\hat{Y}_i) \right].$$

Usando o resultado que  $\sum_{i=1}^n \text{Var}(\hat{Y}_i) = k\sigma^2$  obtém-se

$$\text{EQM}(k) = \frac{\{\text{Viés}(k)\}^2}{\sigma^2} + k.$$



## Critério $C_k$ de Mallows

Por outro lado

$$E\{\text{SQRes}(k)\} = \{\text{Viés}(k)\}^2 + (n - k)\sigma^2.$$

Portanto, o erro quadrático médio padronizado assume a forma

$$\text{EQM}(k) = \frac{E\{\text{SQRes}(k)\}}{\sigma^2} - n + 2k.$$

Deve-se escolher submodelos com EQM(k)'s pequenos.

## CrITÉrio $C_k$ de Mallows

A estatística  $C_k$  é definida por

$$C_k = \frac{\text{SQRes}(k)}{\hat{\sigma}^2} - n + 2k.$$

em que  $\hat{\sigma}^2$  deve ser obtido de um modelo bem ajustado. Sob viés zero tem-se que

$$E(C_k | \text{Viés} = 0) = \frac{(n - k)\sigma^2}{\sigma^2} - n + 2k = k.$$


## Critério $C_k$ de Mallows

Portanto, deve-se escolher submodelos com  $C_k$  pequenos tais que

$$C_k \cong k.$$

Para um mesmo  $k$ , submodelos com  $C_k < k$  têm uma SQRes menor enquanto submodelos com  $C_k > k$  têm uma SQRes maior.

## Descrição da Retra $C_k = k$ e Modelos A, B e C



## Critério $C_k$ de Mallows

Na figura anterior o **modelo A** é o pior modelo, tem  $C_k$  alto e viés alto. O **modelo B** tem um  $C_k$  menor e viés pequeno. Já o **modelo C** tem um viés um pouco maior do que o modelo B, porém um  $C_k$  bem menor, assim poderia ser o modelo escolhido.

## Estatística Press

O **critério Press** consiste em escolher o submodelo com o menor valor para a estatística

$$\text{Press}_k = \sum_{i=1}^n \{y_i - \hat{y}_{(i)}\}^2,$$

em que  $\hat{y}_{(i)}$  denota o valor predito para  $y_i$  do ajuste do submodelo com  $k$  coeficientes sem a  $i$ -ésimo observação.

## Estatística Press

Desde que  $\hat{y}_{(i)} = \mathbf{x}_i^\top \hat{\boldsymbol{\beta}}_{(i)}$ , em que

$$\hat{\boldsymbol{\beta}}_{(i)} = \hat{\boldsymbol{\beta}} - \frac{r_i}{(1 - h_{ii})} (\mathbf{X}^\top \mathbf{X})^{-1} \mathbf{x}_i.$$

obtem-se após algumas manipulações algébricas o seguinte resultado:

$$\text{Press}_k = \sum_{i=1}^n \left( \frac{r_i}{1 - h_{ii}} \right)^2,$$

em que  $r_i$  e  $h_{ii}$  denotam, respectivamente, o  $i$ -ésimo resíduo ordinário e  $i$ -ésima medida de alavanca do submodelo com  $k$  coeficientes.

## Todas as Regressões Possíveis

A fim de selecionar um submodelo usando os critérios:  $R_k^2$  maior,  $s_k^2$  menor,  $C_k \cong k$  e pequeno e menor  $\text{Press}_k$ , deve-se ajustar todas as  $T = 2^{(p-1)}$  regressões possíveis e selecionar um submodelo seguindo os 4 critérios descritos.



- 1 Introdução
- 2 Todas Regressões Possíveis
- 3 Métodos Sequenciais**
- 4 Estratégias para Seleção de Modelos
- 5 Referências

## Método de Akaike

Seja  $L(\theta)$  o logaritmo da função de verossimilhança de um modelo de regressão com  $p$  coeficientes a serem estimados. O **método de Akaike** consiste em maximizar  $L(\theta)$  com o menor número  $p$  de coeficientes da regressão. Isso é equivalente a minimizar a função penalizada abaixo

$$AIC = -2L(\hat{\theta}) + 2p.$$

No caso de regressão linear múltipla tem-se que

$$AIC = n \log \left( \frac{SQRes}{n} \right) + 2p.$$

## Método de Schwartz

Similarmente ao método de Akaike o **método de Schwartz** consiste em maximizar  $L(\theta)$  com o menor número  $p$  de coeficientes da regressão, porém com uma penalização diferente. O método é equivalente a minimizar a função abaixo

$$\text{BIC} = -2L(\hat{\theta}) + p \log(n).$$

No caso de regressão linear múltipla tem-se que

$$\text{BIC} = n \log \left( \frac{\text{SQRes}}{n} \right) + p \log(n).$$

## Método LASSO

O método LASSO é utilizado para a seleção de variáveis explicativas (na forma padronizada) eliminando coeficientes da regressão cujas estimativas estejam próximas de zero. No contexto de mínimos quadrados o método é equivalente a minimizar a função abaixo

$$S(\beta, \lambda) = \sum_{i=1}^n (y_i - \mathbf{x}_i^T \beta)^2 + \lambda \sum_{j=1}^p |\beta_j|,$$

em que  $\beta = (\beta_1, \beta_2, \dots, \beta_p)^T$  e  $\lambda \geq 0$  é o parâmetro de penalização. Quando  $\lambda = 0$  tem-se o método de mínimos quadrados e quando  $\lambda \rightarrow \infty$  todos os coeficientes tendem a zero.

## Passo 1

Ajustar todas as regressões possíveis com apenas 1 variável explicativa. Isto é ajustar as regressões

$$y_i = \beta_1 + \beta_j x_{ij} + \epsilon_i,$$

em que  $\epsilon_i \stackrel{\text{iid}}{\sim} N(0, \sigma^2)$ , para  $i = 1, \dots, n$  e  $j = 2, \dots, p$ .

## Passo 1

Testar  $H_0 : \beta_j = 0$  contra  $H_1 : \beta_j \neq 0$  e obter a estatística

$$F_j = \frac{\text{SQReg}(x_j)}{s^2(x_j)} \stackrel{H_0}{\sim} F_{1, (n-2)}.$$

Denote  $P_j$ : valor-P do teste.

## Passo 1

Seja

$$P_{\min} = \min\{P_2, \dots, P_p\}.$$

Se  $P_{\min} \leq P_E$  então a variável explicativa correspondente entra no modelo. Supor que  $X_2$  entra no modelo.

## Passo 2

Ajustar todas as regressões possíveis com apenas  $X_2$  mais uma variável explicativa. Isto é ajustar as regressões

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

em que  $\epsilon_i \stackrel{\text{iid}}{\sim} N(0, \sigma^2)$ , para  $i = 1, \dots, n$  e  $j = 3, \dots, p$ .

## Passo 2

Testar  $H_0 : \beta_j = 0$  contra  $H_1 : \beta_j \neq 0$  e obter a estatística

$$F_j = \frac{\text{SQReg}(x_j|x_2)}{s^2(x_2, x_j)} \stackrel{H_0}{\sim} F_{1, (n-3)}.$$

Denote  $P_j$ : valor-P do teste.

## Passo 2

Seja

$$P_{\min} = \min\{P_3, \dots, P_p\}.$$

Se  $P_{\min} \leq P_E$  então a variável explicativa correspondente entra no modelo. Supor que  $X_3$  entra no modelo.



## Passo 3

Ajustar todas as regressões possíveis com apenas  $X_2$  e  $X_3$  mais uma variável explicativa. Isto é ajustar as regressões

$$y_i = \beta_1 + \beta_2 x_{i2} + \beta_3 x_{i3} + \beta_j x_{ij} + \epsilon_i,$$

em que  $\epsilon_i \stackrel{\text{iid}}{\sim} N(0, \sigma^2)$ , para  $i = 1, \dots, n$  e  $j = 4, \dots, p$ .

## Passo 2

Testar  $H_0 : \beta_j = 0$  contra  $H_1 : \beta_j \neq 0$  e obter a estatística

$$F_j = \frac{\text{SQReg}(x_j | x_2, x_3)}{s^2(x_2, x_3, x_j)} \stackrel{H_0}{\sim} F_{1, (n-4)}.$$

Denote  $P_j$ : valor-P do teste.

## Passo 3

Seja

$$P_{\min} = \min\{P_4, \dots, P_p\}.$$

Se  $P_{\min} \leq P_E$  então a variável explicativa correspondente entra no modelo. Se  $P_{\min} > P_E$  parar o processo, nenhuma variável entra no modelo.

## Passo 1

Ajustar a regressão com todas as variáveis explicativas. Isto é ajustar o seguinte modelo:

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

em que  $\epsilon_i \stackrel{\text{iid}}{\sim} N(0, \sigma^2)$ , para  $i = 1, \dots, n$ .

## Passo 1

Testar  $H_0 : \beta_j = 0$  contra  $H_1 : \beta_j \neq 0$  e obter a estatística

$$F_j = \frac{\text{SQReg}(x_j | \text{demais})}{s^2(x_2, \dots, x_p)} \stackrel{H_0}{\sim} F_{1, (n-p)}.$$

Denote  $P_j$ : valor-P do teste, para  $j = 2, \dots, p$ .

## Passo 1

Seja

$$P_{\max} = \max\{P_2, \dots, P_p\}.$$

Se  $P_{\max} \geq P_S$  então a variável explicativa correspondente sai do modelo. Supor que  $X_2$  sai do modelo.

## Passo 2

Ajustar a regressão sem a variável explicativa  $X_2$ . Isto é ajustar o seguinte modelo:

$$y_i = \beta_1 + \beta_3 X_{i3} + \cdots + \beta_p X_{ip} + \epsilon_i,$$

em que  $\epsilon_i \stackrel{\text{iid}}{\sim} N(0, \sigma^2)$ , para  $i = 1, \dots, n$ .

## Passo 2

Testar  $H_0 : \beta_j = 0$  contra  $H_1 : \beta_j \neq 0$  e obter a estatística

$$F_j = \frac{\text{SQReg}(x_j|\text{demais})}{s^2(x_3, \dots, x_p)} \stackrel{H_0}{\sim} F_{1, (n-p-1)}.$$

Denote  $P_j$ : valor-P do teste, para  $j = 3, \dots, p$ .

## Passo 2

Seja

$$P_{\max} = \max\{P_3, \dots, P_p\}.$$

Se  $P_{\max} < P_S$  o processo é terminado, nenhuma variável sai do modelo.

## Descrição

O **método stepwise** é uma combinação dos métodos forward e backward.

## Passo 1

Ajustar todas as regressões com apenas uma variável explicativa, além do intercepto. Verificar se alguma variável explicativa entra no modelo. **Supor que  $X_2$  entrou no modelo.**

## Passo 2

Ajustar todas as regressões com  $X_2$  mais uma variável explicativa, além do intercepto. Verificar se alguma variável explicativa entra no modelo. **Supor que  $X_3$  entrou no modelo.** Verificar se  $X_2$  sai do modelo dado que  $X_3$  está no modelo.

## Passo 3

O processo stepwise deve continuar até que não seja possível incluir nenhuma variável no modelo, nem retirar nenhuma variável do modelo.



## Critérios de Parada

Não há um consenso na área de regressão a respeito de critérios de parada para os processos sequenciais forward, backward e stepwise. Alguns critérios mais utilizados:

- Usar  $F_E = F_S = 4$  que equivale aproximadamente a usar  $P_E = P_S = 0,05$ .
- Considerar  $P_E = 0,25$  e  $P_S = 0,10$ , ou mesmo ainda ser mais flexível com  $P_E = P_S = 0,15$ .

- 1 Introdução
- 2 Todas Regressões Possíveis
- 3 Métodos Sequenciais
- 4 Estratégias para Seleção de Modelos**
- 5 Referências

## Considerações

A seleção de modelos é uma **combinação de técnicas e bom senso** e não há uma receita pronta para seleção de modelos a partir de um conjunto de variáveis explicativas. Em Montgomery, Peck e Vining (2021, Seção 10.3) há uma longa discussão a respeito de possíveis estratégias para seleção de modelos através dos critérios propostos. A seguir sintetizamos algumas dessas estratégias.

## Todas as Regressões Possíveis

Quando o número de variáveis explicativas é relativamente pequeno pode ser factível ajustar todas as regressões possíveis e selecionar algumas candidatas segundo os critérios  $R_k^2$  maior,  $s_k^2$  menor,  $C_k \cong k$  e pequeno e menor  $Press_k$ . Para as regressões selecionadas sugere-se fazer uma análise de diagnóstico e levar em conta aspectos como a importância, custo e facilidade de interpretação das variáveis explicativas bem como da capacidade de predição do modelo.

## Métodos Sequencias

Os métodos sequenciais **forward**, **backward** e **stepwise** são recomendados quando há um número médio ou alto de variáveis explicativas, contudo exigem os níveis de significância de entrada e saída das variáveis explicativas. Já os métodos **AIC**, **BIC** e **LASSO** são mais recomendados quando há um grande número de variáveis explicativas no sentido de se fazer uma pré-seleção de variáveis explicativas sem a necessidade de estabelecer níveis de significância. Todos os métodos sequencias podem ser combinados com o ajuste de todas as regressões possíveis. Recomenda-se análise de diagnóstico antes de escolher o modelo final.

- 1 Introdução
- 2 Todas Regressões Possíveis
- 3 Métodos Sequenciais
- 4 Estratégias para Seleção de Modelos
- 5 Referências**

## Referências

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