



ME613 - Análise de Regressão

Parte 11

Benilton S Carvalho - 1S2020

Critérios para Seleção de Modelos

Introdução

Fases na construção de um modelo:

- Coleta e preparação dos dados.
- Redução do número de variáveis preditoras.
- Refinamento e seleção de modelo.
- Validação do modelo.

Introdução

Se tivermos $p - 1$ variáveis preditoras, podemos construir 2^{p-1} modelos diferentes.

Mesmo se considerarmos todos esses modelos (computacionalmente intenso), precisaríamos de algum critério para selecionar entre eles.

Métodos para seleção de modelos/variáveis foram desenvolvidos para identificar um subgrupo de variáveis que são “boas” para o modelo, segundo algum critério.

Há vários critérios desenvolvidos na literatura. Neste curso, focaremos em seis.

R_p^2

Para o critério R_p^2 , a idéia é utilizar o coeficiente de determinação, R^2 para identificar subgrupos das variáveis preditoras que, quando incluídas no modelo, produzem um alto valor para R^2 .

R_p^2 indica que temos p parâmetros no modelo, isto é, $p - 1$ variáveis preditoras incluídas no modelo.

$$R_p^2 = 1 - \frac{SQE_p}{SQT}$$

O objetivo deste critério não é maximização: R_p^2 sempre irá aumentar conforme mais variáveis preditoras são incluídas no modelo. A idéia é comparar os diversos R_p^2 's e verificar se adicionar mais variáveis ainda traz um aumento.

Exemplo: Cirurgias

Y : tempo de sobrevivência

X_1 : blood clotting score

X_2 : índice de prognóstico

X_3 : teste de função enzimática

X_4 : teste de função do fígado

X_5 : idade (anos)

X_6 : gênero (0=masculino, 1=feminino)

X_7 : uso de álcool (1 = moderado, 0 = nenhum ou severo)

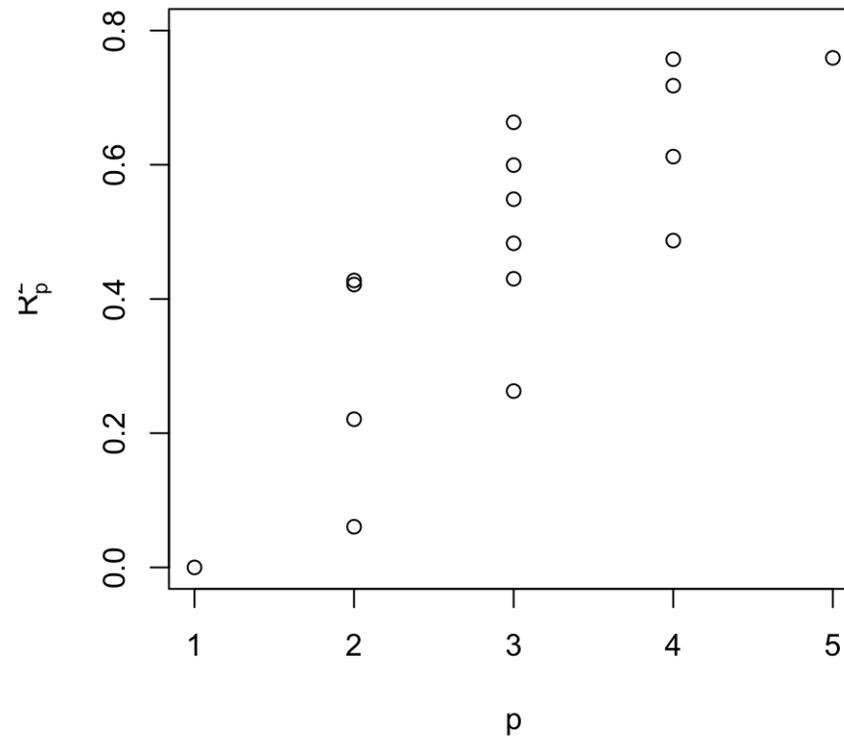
X_8 : uso de álcool (1 = severo, 0 = nenhum ou moderado)

Exemplo

Considerando X_1, X_2, X_3 e X_4 , temos $2^4 = 16$ modelos possíveis.

Variáveis no modelo	p	R_p^2	Variáveis no modelo	p	R_p^2
nenhuma	1	0	$X_2 X_3$	3	0.663
X_1	2	0.061	$X_2 X_4$	3	0.483
X_2	2	0.221	$X_3 X_4$	3	0.599
X_3	2	0.428	$X_1 X_2 X_3$	4	0.757
X_4	2	0.422	$X_1 X_2 X_4$	4	0.487
$X_1 X_2$	3	0.263	$X_1 X_3 X_4$	4	0.612
$X_1 X_3$	3	0.549	$X_2 X_3 X_4$	4	0.718
$X_1 X_4$	3	0.43	$X_1 X_2 X_3 X_4$	5	0.759

Exemplo



$$R_{a,p}^2$$

Como R_p^2 não leva em conta o número de parâmetros no modelo e sempre aumenta conforme temos mais variáveis incluídas, uma alternativa é usar:

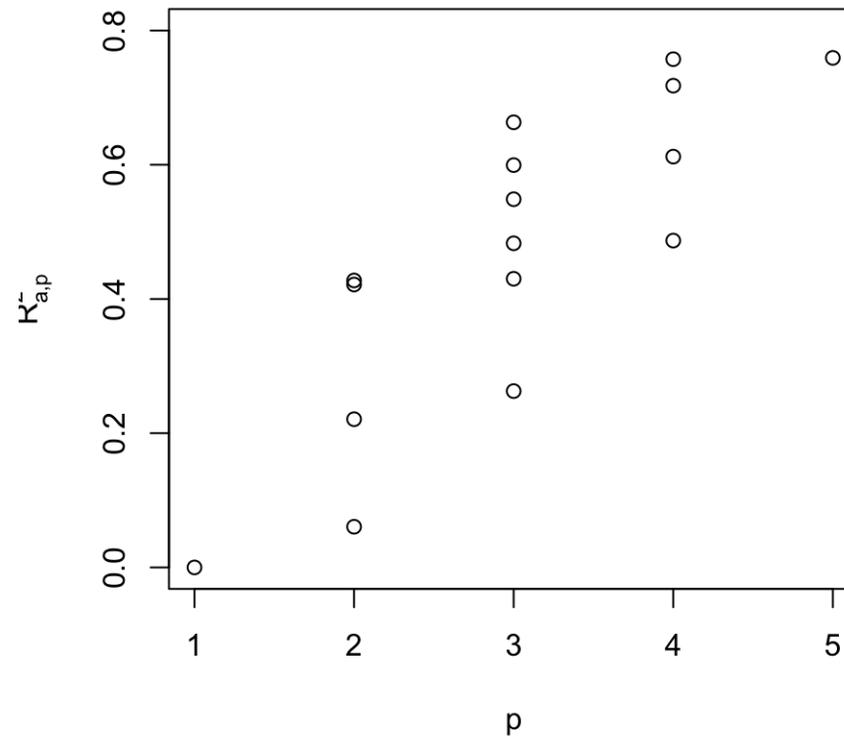
$$R_{a,p}^2 = 1 - \left(\frac{n-1}{n-p} \right) \frac{SQE_p}{SQT} = 1 - \frac{QME_p}{SQT/(n-1)}$$

$R_{a,p}^2$ aumenta se e somente se QME_p diminui.

Exemplo

Variáveis no modelo	p	$R_{a,p}^2$	Variáveis no modelo	p	$R_{a,p}^2$
nenhuma	1	0	$X_2 X_3$	3	0.65
X_1	2	0.043	$X_2 X_4$	3	0.463
X_2	2	0.206	$X_3 X_4$	3	0.584
X_3	2	0.417	$X_1 X_2 X_3$	4	0.743
X_4	2	0.41	$X_1 X_2 X_4$	4	0.456
$X_1 X_2$	3	0.234	$X_1 X_3 X_4$	4	0.589
$X_1 X_3$	3	0.531	$X_2 X_3 X_4$	4	0.701
$X_1 X_4$	3	0.408	$X_1 X_2 X_3 X_4$	5	0.74

Exemplo



C_p de Mallow

Este critério avalia o erro quadrático médio dos n valores ajustados segundo um modelo a ser considerado.

Erro de cada valor ajustado é dado por:

$$\hat{Y}_i - \mu_i$$

em que μ_i é o valor verdadeiro da função resposta.

Temos o viés:

$$E(\hat{Y}_i) - \mu_i$$

E um componente aleatório de erro:

$$\hat{Y}_i - E(\hat{Y}_i)$$

C_p de Mallow

$$(\hat{Y}_i - \mu_i)^2 = [(E(\hat{Y}_i) - \mu_i) + (\hat{Y}_i - E(\hat{Y}_i))]^2$$

$$E(\hat{Y}_i - \mu_i)^2 = [E(\hat{Y}_i) - \mu_i]^2 + Var(\hat{Y}_i)$$

Erro quadrático médio total:

$$\sum_{i=1}^n [E(\hat{Y}_i) - \mu_i]^2 + \sum_{i=1}^n Var(\hat{Y}_i)$$

Medida para o critério:

$$\Gamma_p = \frac{1}{\sigma^2} \left[\sum_{i=1}^n [E(\hat{Y}_i) - \mu_i]^2 + \sum_{i=1}^n Var(\hat{Y}_i) \right]$$

(erro quadrático médio total dividido pela verdadeira variância do erro)

C_p de Mallow

Estamos considerando incluir $p - 1$ variáveis, mas assumamos que o número ideal de variáveis a serem incluídas no modelo seja $P - 1 > p - 1$.

Se assumirmos que o modelo incluindo as $P - 1$ variáveis é correto, temos que $QME(X_1, \dots, X_{P-1})$ é um estimador não viesado para σ^2 .

Estimador para Γ_p é dado por:

$$C_p = \frac{SQE_p}{QME(X_1, \dots, X_{P-1})} - (n - 2p)$$

C_p de Mallow

Se o modelo com $p - 1$ variáveis é adequado, então $E \left[\frac{SQE_p}{(n-p)} \right] = \sigma^2$, de maneira que $E \left[\frac{SQE_p}{QME(X_1, \dots, X_{p-1})} \right] = n - p$.

Portanto, se o modelo com $p - 1$ variáveis é aproximadamente adequado, esperamos que $C_p \approx p$.

Procuramos o menor C_p tal que $C_p \approx p$.

Exemplo

Modelo considerando as variáveis X_1, X_2, X_3 e X_4 ($P - 1 = 4$)

Incluindo apenas X_4 ($p = 2$):

$$C_p = \frac{SQE(X_4)}{QME(X_1, \dots, X_4)} - (n - 2p)$$

Exemplo

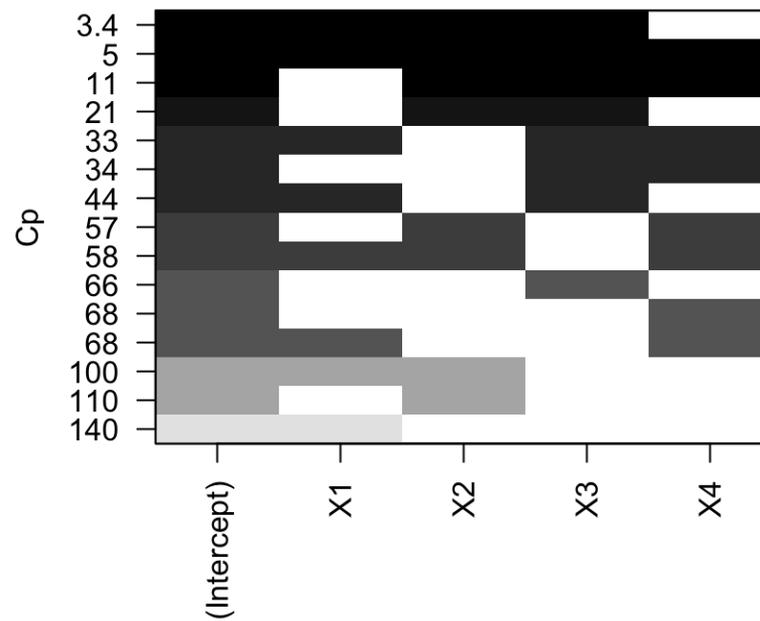
```
## Analysis of Variance Table
##
## Response: lnY
##           Df Sum Sq Mean Sq F value    Pr(>F)
## X4           1  5.3990   5.3990  37.894 1.092e-07 ***
## Residuals  52  7.4087   0.1425
## ---
## Signif. codes:  0 '***' 0.001 '**' 0.01 '*' 0.05 '.' 0.1 ' ' 1
```

```
## Analysis of Variance Table
##
## Response: lnY
##           Df Sum Sq Mean Sq  F value    Pr(>F)
## X1           1  0.7763   0.7763  12.3337 0.0009661 ***
## X2           1  2.5888   2.5888  41.1325 5.377e-08 ***
## X3           1  6.3341   6.3341 100.6408 1.810e-13 ***
## X4           1  0.0246   0.0246   0.3905 0.5349320
## Residuals  49  3.0840   0.0629
## ---
## Signif. codes:  0 '***' 0.001 '**' 0.01 '*' 0.05 '.' 0.1 ' ' 1
```

$$C_p = \frac{SQE(X_4)}{QME(X_1, \dots, X_4)} - (n - 2p) = \frac{7.4087314}{0.062938} - (54 - 2 \times 2) = 67.7147725$$

Exemplo

```
library(leaps)
leaps<-regsubsets(lnY~X1+X2+X3+X4,data=dados,nbest=10)
plot(leaps,scale="Cp")
```



AIC e BIC

Procuramos modelos com valores pequenos de *AIC*, *BIC*.

AIC: Akaike's information criterion

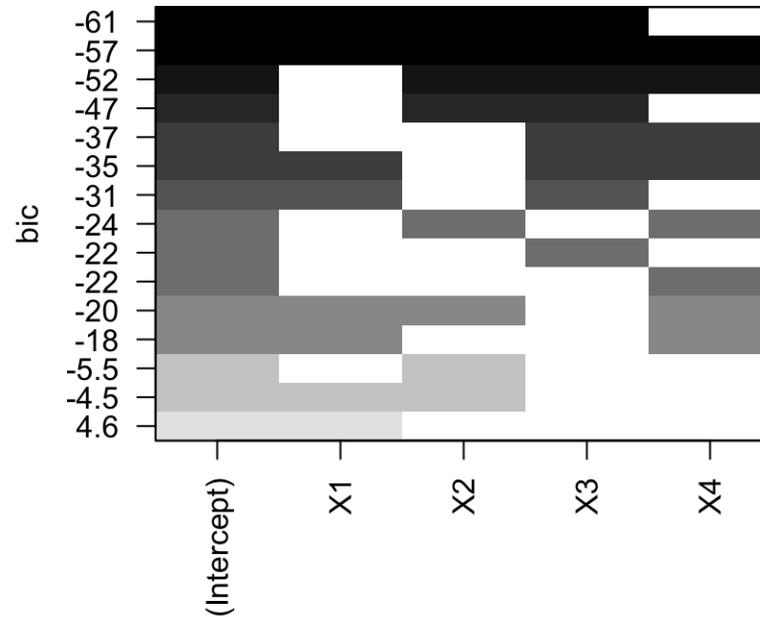
$$AIC_p = n \ln(SQE_p) - n \ln n + 2p$$

BIC: Bayesian information criterion

$$BIC_p = n \ln(SQE_p) - n \ln n + \ln(n)p$$

Exemplo

```
plot(leaps, scale="bic")
```



PRESS_p

PRESS_p (*prediction sum of squares*): critério para medir quão adequado é o uso dos valores ajustados obtidos a partir de um modelo com menos variáveis para prever os valores observados de Y .

$SQE = \sum (Y_i - \hat{Y}_i)^2$ também serve para este propósito.

A diferença é que a medida *PRESS* é obtida após a exclusão da i -ésima observação e estimação do modelo com as $n - 1$ observações restantes, e então usar este modelo para prever o valor de Y para a i -ésima observação.

Notação: $\hat{Y}_{i(i)}$ indica o valor predito para a i -ésima observação quando esta foi excluída na obtenção do modelo.

PRESS_p

$$PRESS_p = \sum_{i=1}^n (Y_i - \hat{Y}_{i(i)})^2$$

Modelos com *PRESS_p* pequenos são considerados bons candidatos (com erro de predição pequeno).

Não é preciso ajustar $n - 1$ vezes o modelo para calcular o *PRESS_p*.

Seja $d_i = Y_i - \hat{Y}_{i(i)}$, reescrevemos: $d_i = \frac{e_i}{1-h_{ii}}$

em que e_i é o resíduo para a i -ésima observação e h_{ii} é o i -ésimo elemento da diagonal de $\mathbf{H} = \mathbf{X}^T (\mathbf{X}^T \mathbf{X})^{-1} \mathbf{X}$, obtidos a partir do modelo de regressão com todas as observações incluídas.

Exemplo

```
library(qpcR)
modelo1 <- lm(lnY ~ 1,data=dados)
modelo2 <- lm(lnY ~ X1,data=dados)
modelo3 <- lm(lnY ~ X2,data=dados)
modelo4 <- lm(lnY ~ X3,data=dados)
modelo5 <- lm(lnY ~ X4,data=dados)
modelo6 <- lm(lnY ~ X1+X2,data=dados)
modelo7 <- lm(lnY ~ X1+X3,data=dados)
modelo8 <- lm(lnY ~ X1+X4,data=dados)
modelo9 <- lm(lnY ~ X2+X3,data=dados)
modelo10 <- lm(lnY ~ X2+X4,data=dados)
modelo11 <- lm(lnY ~ X3+X4,data=dados)
modelo12 <- lm(lnY ~ X1+X2+X3,data=dados)
modelo13 <- lm(lnY ~ X1+X2+X4,data=dados)
modelo14 <- lm(lnY ~ X1+X3+X4,data=dados)
modelo15 <- lm(lnY ~ X2+X3+X4,data=dados)
modelo16 <- lm(lnY ~ X1+X2+X3+X4,data=dados)
PRESS(modelo1,verbose=FALSE)$stat
```

```
## [1] 13.2956
```

Exemplo

Variáveis no modelo	p	$PRESS_p$	Variáveis no modelo	p	$PRESS_p$
nenhuma	1	13.296	$X_2 X_3$	3	5.065
X_1	2	13.512	$X_2 X_4$	3	7.476
X_2	2	10.744	$X_3 X_4$	3	6.121
X_3	2	8.327	$X_1 X_2 X_3$	4	3.914
X_4	2	8.025	$X_1 X_2 X_4$	4	7.903
$X_1 X_2$	3	11.062	$X_1 X_3 X_4$	4	6.207
$X_1 X_3$	3	6.988	$X_2 X_3 X_4$	4	4.597
$X_1 X_4$	3	8.472	$X_1 X_2 X_3 X_4$	5	4.069

Procedimentos Automáticos para Seleção de Modelos

“Best” Subsets Algorithms

Para o exemplo visto anteriormente, se considerarmos todas as variáveis, temos $2^8 = 256$ modelos possíveis.

Exemplo - Usando AIC_p

```
library(bestglm)
Xy = dados[, -9] # excluindo coluna do Y original, usamos ln(Y) como variável resposta
names(Xy) <- c(names(Xy)[1:8], "y")
modelos <- bestglm(Xy, IC="AIC", TopModels = 2)
modelos$Subsets
```

```
##      (Intercept)   X1    X2    X3    X4    X5    X6    X7    X8 logLikelihood
## 0             TRUE FALSE FALSE FALSE FALSE FALSE FALSE FALSE FALSE      38.85126
## 1             TRUE FALSE FALSE  TRUE FALSE FALSE FALSE FALSE FALSE      53.91343
## 2             TRUE FALSE  TRUE  TRUE FALSE FALSE FALSE FALSE FALSE      68.24165
## 3             TRUE FALSE  TRUE  TRUE FALSE FALSE FALSE FALSE  TRUE      79.49246
## 4             TRUE  TRUE  TRUE  TRUE FALSE FALSE FALSE FALSE  TRUE      86.67568
## 5             TRUE  TRUE  TRUE  TRUE FALSE FALSE  TRUE FALSE  TRUE      87.90259
## 6*            TRUE  TRUE  TRUE  TRUE FALSE  TRUE  TRUE FALSE  TRUE      88.91714
## 7             TRUE  TRUE  TRUE  TRUE FALSE  TRUE  TRUE  TRUE  TRUE      89.36782
## 8             TRUE  TRUE  TRUE  TRUE  TRUE  TRUE  TRUE  TRUE  TRUE      89.38549
##              AIC
## 0      -77.70252
## 1     -105.82686
## 2     -132.48329
## 3     -152.98493
## 4     -165.35135
## 5     -165.80517
## 6*    -165.83429
## 7     -164.73565
## 8     -162.77098
```

Exemplo - Usando AIC_p

```
melhor <- which(modelos$Subsets$AIC==min(modelos$Subsets$AIC))
numvar <- dim(Xy)[2]-1 # total de variáveis consideradas inicialmente
varincludidas <- modelos$Subsets[melhor,2:(numvar+1)] # variaveis escolhidas segundo criterio
varincludidas
```

```
##      X1  X2  X3  X4  X5  X6  X7  X8
## 6* TRUE TRUE TRUE FALSE TRUE TRUE FALSE TRUE
```

```
modeloescolhidoAIC <- lm(y ~ .,data=Xy[,c(which(varincludidas==TRUE),which(names(Xy)=="y"))])
summary(modeloescolhidoAIC)$coef
```

```
##           Estimate Std. Error  t value    Pr(>|t|)
## (Intercept)  4.053974209  0.234793506  17.266126  5.572016e-22
## X1           0.071517057  0.018637294   3.837309  3.701898e-04
## X2           0.013755482  0.001709437   8.046792  2.169036e-10
## X3           0.015116499  0.001385313  10.911972  1.777375e-14
## X5          -0.003450094  0.002571776  -1.341522  1.861972e-01
## X6           0.087316639  0.057701672   1.513243  1.369140e-01
## X8           0.350903932  0.076391406   4.593500  3.276184e-05
```

Exemplo - Usando BIC_p

```
modelos <- bestglm(Xy,IC="BIC")  
modelos$Subsets
```

```
##      (Intercept)    X1    X2    X3    X4    X5    X6    X7    X8 logLikelihood  
## 0          TRUE FALSE FALSE FALSE FALSE FALSE FALSE FALSE FALSE      38.85126  
## 1          TRUE FALSE FALSE  TRUE FALSE FALSE FALSE FALSE FALSE      53.91343  
## 2          TRUE FALSE  TRUE  TRUE FALSE FALSE FALSE FALSE FALSE      68.24165  
## 3          TRUE FALSE  TRUE  TRUE FALSE FALSE FALSE FALSE  TRUE      79.49246  
## 4*         TRUE  TRUE  TRUE  TRUE FALSE FALSE FALSE FALSE  TRUE      86.67568  
## 5          TRUE  TRUE  TRUE  TRUE FALSE FALSE  TRUE FALSE  TRUE      87.90259  
## 6          TRUE  TRUE  TRUE  TRUE FALSE  TRUE  TRUE FALSE  TRUE      88.91714  
## 7          TRUE  TRUE  TRUE  TRUE FALSE  TRUE  TRUE  TRUE  TRUE      89.36782  
## 8          TRUE  TRUE  TRUE  TRUE  TRUE  TRUE  TRUE  TRUE  TRUE      89.38549  
##          BIC  
## 0      -77.70252  
## 1     -103.83788  
## 2     -128.50532  
## 3     -147.01798  
## 4*    -157.39542  
## 5     -155.86025  
## 6     -153.90039  
## 7     -150.81276  
## 8     -146.85911
```

Exemplo - Usando BIC_p

```
melhor <- which(modelos$Subsets$BIC==min(modelos$Subsets$BIC))
varincludidas <- modelos$Subsets[melhor,2:(numvar+1)] # variaveis escolhidas segundo criterio
varincludidas
```

```
##      X1  X2  X3  X4  X5  X6  X7  X8
## 4* TRUE TRUE TRUE FALSE FALSE FALSE TRUE
```

```
modeloescolhidoBIC <- lm(y ~ .,data=Xy[,c(which(varincludidas==TRUE),which(names(Xy)=="y"))])
summary(modeloescolhidoBIC)$coef
```

```
##           Estimate Std. Error  t value    Pr(>|t|)
## (Intercept) 3.85241856 0.192695224 19.992289 3.279284e-25
## X1           0.07332263 0.018973044  3.864569 3.273887e-04
## X2           0.01418507 0.001730632  8.196469 9.581863e-11
## X3           0.01545270 0.001395609 11.072371 6.145977e-15
## X8           0.35296762 0.077190626  4.572675 3.290701e-05
```

Exemplo - Usando $PRESS_p$

```
modelos <- bestglm(Xy,IC="LOOCV")  
modelos$Subsets
```

```
##      (Intercept)    X1    X2    X3    X4    X5    X6    X7    X8 logLikelihood  
## 0          TRUE FALSE FALSE FALSE FALSE FALSE FALSE FALSE FALSE      38.85126  
## 1          TRUE FALSE FALSE  TRUE FALSE FALSE FALSE FALSE FALSE      53.91343  
## 2          TRUE FALSE  TRUE  TRUE FALSE FALSE FALSE FALSE FALSE      68.24165  
## 3          TRUE FALSE  TRUE  TRUE FALSE FALSE FALSE FALSE  TRUE      79.49246  
## 4*         TRUE  TRUE  TRUE  TRUE FALSE FALSE FALSE FALSE  TRUE      86.67568  
## 5          TRUE  TRUE  TRUE  TRUE FALSE FALSE  TRUE FALSE  TRUE      87.90259  
## 6          TRUE  TRUE  TRUE  TRUE FALSE  TRUE  TRUE FALSE  TRUE      88.91714  
## 7          TRUE  TRUE  TRUE  TRUE FALSE  TRUE  TRUE  TRUE  TRUE      89.36782  
## 8          TRUE  TRUE  TRUE  TRUE  TRUE  TRUE  TRUE  TRUE  TRUE      89.38549  
##              LOOCV  
## 0  0.24621473  
## 1  0.15419845  
## 2  0.09380257  
## 3  0.06424821  
## 4* 0.05069947  
## 5  0.05153172  
## 6  0.05133936  
## 7  0.05201306  
## 8  0.05428207
```

Exemplo - Usando $PRESS_p$

```
melhor <- which(modelos$Subsets$LOOCV==min(modelos$Subsets$LOOCV))
varincludidas <- modelos$Subsets[melhor,2:(numvar+1)] # variaveis escolhidas segundo criterio
varincludidas
```

```
##      X1  X2  X3  X4  X5  X6  X7  X8
## 4* TRUE TRUE TRUE FALSE FALSE FALSE FALSE TRUE
```

```
modeloescolhidoPRESS <- lm(y ~ .,data=Xy[,c(which(varincludidas==TRUE),which(names(Xy)=="y"))])
summary(modeloescolhidoPRESS)$coef
```

```
##           Estimate Std. Error  t value    Pr(>|t|)
## (Intercept) 3.85241856 0.192695224 19.992289 3.279284e-25
## X1          0.07332263 0.018973044  3.864569 3.273887e-04
## X2          0.01418507 0.001730632  8.196469 9.581863e-11
## X3          0.01545270 0.001395609 11.072371 6.145977e-15
## X8          0.35296762 0.077190626  4.572675 3.290701e-05
```

Exemplo - C_p de Mallows, R_p^2 , $R_{a,p}^2$ e BIC_p

```
library(leaps)
modelos <- regsubsets(y ~ ., data=Xy, nbest=2)
resultados = data.frame(cbind("p"=rowSums(summary(modelos)$which), summary(modelos)$which,
                              "Cp"=round(summary(modelos)$cp, 2),
                              "R2"=round(summary(modelos)$rsq, 2),
                              "R2adj"=round(summary(modelos)$adjr2, 2), "BIC"=round(summary(modelos)$bic, 2)))
resultados
```

##	p	X.Intercept.	X1	X2	X3	X4	X5	X6	X7	X8	Cp	R2	R2adj	BIC
##	X1	2	1	0	0	1	0	0	0	0	117.41	0.43	0.42	-22.15
##	X1.1	2	1	0	0	0	1	0	0	0	119.17	0.42	0.41	-21.58
##	X2	3	1	0	1	1	0	0	0	0	50.47	0.66	0.65	-46.81
##	X2.1	3	1	0	0	1	1	0	0	0	69.13	0.60	0.58	-37.44
##	X3	4	1	0	1	1	0	0	0	1	18.91	0.78	0.76	-65.33
##	X3.1	4	1	1	1	1	0	0	0	0	24.98	0.76	0.74	-60.50
##	X4	5	1	1	1	1	0	0	0	1	5.75	0.83	0.82	-75.70
##	X4.1	5	1	0	1	1	1	0	0	1	10.27	0.81	0.80	-71.01
##	X5	6	1	1	1	1	0	0	1	0	5.54	0.84	0.82	-74.17
##	X5.1	6	1	1	1	1	0	1	0	0	6.02	0.84	0.82	-73.63
##	X6	7	1	1	1	1	0	1	1	0	5.79	0.84	0.82	-72.21
##	X6.1	7	1	1	1	1	0	0	1	1	7.03	0.84	0.82	-70.76
##	X7	8	1	1	1	1	0	1	1	1	7.03	0.85	0.82	-69.12
##	X7.1	8	1	1	1	1	1	1	0	1	7.74	0.84	0.82	-68.28
##	X8	9	1	1	1	1	1	1	1	1	9.00	0.85	0.82	-65.17

Método *Stepwise*

- Método menos intensivo computacionalmente.
- Ao final, obtém-se apenas 1 modelo candidato.
- *forward, backward, both*

Forward Selection

Início considerando $P - 1$ variáveis.

1- Ajuste uma regressão linear simples com cada uma das $P - 1$ variáveis. Para cada regressão, calcule a estatística t^* para testar se o coeficiente angular é 0.

$$t_k^* = \frac{\hat{\beta}_k}{\sqrt{\widehat{Var}(\hat{\beta}_k)}}$$

2- Considere a variável cujo $|t^*|$ é o maior. Inclua esta variável caso $|t^*|$ esteja acima de algum valor pré-determinado.

3 - Se alguma variável é incluída, por exemplo, X_7 ajustam-se regressões com pares de variáveis, sendo que sempre uma delas é X_7 . Calcula-se t^* para a nova variável incluída e repita o passo 2 para decidir qual a segunda variável a ser incluída no modelo.

4 - Repita até considerar todas as variáveis.

Backward Selection

1. Ajuste uma regressão linear múltipla com todas as $P - 1$ variáveis.
2. Teste iterativamente se uma das variáveis pode ser eliminada.

Exemplo: *Forward Regression*

```
completo = lm(y~.,data=Xy)
vazio = lm(y~1, data=Xy)
step(vazio, scope=list(upper=completo, lower=vazio), direction='forward', trace=TRUE)
Start: AIC=-75.7
y ~ 1
```

	Df	Sum of Sq	RSS	AIC
+ X3	1	5.4762	7.3316	-103.827
+ X4	1	5.3990	7.4087	-103.262
+ X2	1	2.8285	9.9792	-87.178
+ X8	1	1.7798	11.0279	-81.782
+ X1	1	0.7763	12.0315	-77.079
+ X6	1	0.6897	12.1180	-76.692
<none>			12.8077	-75.703
+ X5	1	0.2691	12.5386	-74.849
+ X7	1	0.2052	12.6025	-74.575

Exemplo: *Forward Regression*

Step: AIC=-103.83

y ~ X3

	Df	Sum of Sq	RSS	AIC
+ X2	1	3.01908	4.3125	-130.48
+ X4	1	2.20187	5.1297	-121.11
+ X1	1	1.55061	5.7810	-114.66
+ X8	1	1.13756	6.1940	-110.93
<none>			7.3316	-103.83
+ X6	1	0.25854	7.0730	-103.77
+ X5	1	0.23877	7.0928	-103.61
+ X7	1	0.06498	7.2666	-102.31

Exemplo: *Forward Regression*

Step: AIC=-130.48

$y \sim X3 + X2$

	Df	Sum of Sq	RSS	AIC
+ X8	1	1.46961	2.8429	-150.99
+ X1	1	1.20395	3.1085	-146.16
+ X4	1	0.69836	3.6141	-138.02
+ X7	1	0.22632	4.0862	-131.39
+ X5	1	0.16461	4.1479	-130.59
<none>			4.3125	-130.48
+ X6	1	0.08245	4.2300	-129.53

Exemplo: *Forward Regression*

Step: AIC=-150.98

$y \sim X3 + X2 + X8$

	Df	Sum of Sq	RSS	AIC
+ X1	1	0.66408	2.1788	-163.35
+ X4	1	0.46630	2.3766	-158.66
+ X6	1	0.13741	2.7055	-151.66
<none>			2.8429	-150.99
+ X5	1	0.07081	2.7721	-150.35
+ X7	1	0.02464	2.8182	-149.46

Exemplo: *Forward Regression*

Step: AIC=-163.35

$y \sim X3 + X2 + X8 + X1$

	Df	Sum of Sq	RSS	AIC
+ X6	1	0.096791	2.0820	-163.81
<none>			2.1788	-163.35
+ X5	1	0.075876	2.1029	-163.26
+ X4	1	0.041701	2.1371	-162.40
+ X7	1	0.022944	2.1559	-161.92

Exemplo: *Forward Regression*

Step: AIC=-163.81

$y \sim X3 + X2 + X8 + X1 + X6$

	Df	Sum of Sq	RSS	AIC
+ X5	1	0.076782	2.0052	-163.83
<none>			2.0820	-163.81
+ X7	1	0.022387	2.0596	-162.39
+ X4	1	0.016399	2.0656	-162.23

Exemplo: *Forward Regression*

Step: AIC=-163.83

$y \sim X3 + X2 + X8 + X1 + X6 + X5$

	Df	Sum of Sq	RSS	AIC
<none>			2.0052	-163.83
+ X7	1	0.033193	1.9720	-162.74
+ X4	1	0.002284	2.0029	-161.90

Call:

`lm(formula = y ~ X3 + X2 + X8 + X1 + X6 + X5, data = Xy)`

Coefficients:

(Intercept)	X3	X2	X8	X1	X6	X5
4.05397	0.01512	0.01376	0.35090	0.07152	0.08732	-0.00345

Exemplo: *Backward Regression*

```
completo = lm(y~.,data=Xy)
vazio = lm(y~1, data=Xy)
step(completo, scope=list(upper=completo, lower=vazio), direction='backward', trace=TRUE)
```

Start: AIC=-160.77

$y \sim X1 + X2 + X3 + X4 + X5 + X6 + X7 + X8$

	Df	Sum of Sq	RSS	AIC
- X4	1	0.00129	1.9720	-162.74
- X7	1	0.03220	2.0029	-161.90
- X5	1	0.07354	2.0443	-160.79
<none>			1.9707	-160.77
- X6	1	0.08415	2.0549	-160.51
- X1	1	0.31809	2.2888	-154.69
- X8	1	0.84573	2.8165	-143.49
- X2	1	2.09045	4.0612	-123.72
- X3	1	2.99085	4.9616	-112.91

Exemplo: *Backward Regression*

Step: AIC=-162.74

$y \sim X1 + X2 + X3 + X5 + X6 + X7 + X8$

	Df	Sum of Sq	RSS	AIC
- X7	1	0.0332	2.0052	-163.834
<none>			1.9720	-162.736
- X5	1	0.0876	2.0596	-162.389
- X6	1	0.0971	2.0691	-162.141
- X1	1	0.6267	2.5988	-149.833
- X8	1	0.8446	2.8166	-145.486
- X2	1	2.6731	4.6451	-118.471
- X3	1	5.0986	7.0706	-95.784

Exemplo: *Backward Regression*

Step: AIC=-163.83

$y \sim X1 + X2 + X3 + X5 + X6 + X8$

	Df	Sum of Sq	RSS	AIC
<none>			2.0052	-163.834
- X5	1	0.0768	2.0820	-163.805
- X6	1	0.0977	2.1029	-163.265
- X1	1	0.6282	2.6335	-151.117
- X8	1	0.9002	2.9055	-145.809
- X2	1	2.7626	4.7678	-119.064
- X3	1	5.0801	7.0853	-97.672

Exemplo: *Backward Regression*

Call:

```
lm(formula = y ~ X1 + X2 + X3 + X5 + X6 + X8, data = Xy)
```

Coefficients:

(Intercept)	X1	X2	X3	X5	X6	X8
4.05397	0.07152	0.01376	0.01512	-0.00345	0.08732	0.35090

Exemplo: *Forward Stepwise Regression*

```
completo = lm(y~.,data=Xy)
vazio = lm(y~1, data=Xy)
step(vazio, scope=list(upper=completo, lower=vazio), direction='both', trace=TRUE)
```

Start: AIC=-75.7

y ~ 1

	Df	Sum of Sq	RSS	AIC
+ X3	1	5.4762	7.3316	-103.827
+ X4	1	5.3990	7.4087	-103.262
+ X2	1	2.8285	9.9792	-87.178
+ X8	1	1.7798	11.0279	-81.782
+ X1	1	0.7763	12.0315	-77.079
+ X6	1	0.6897	12.1180	-76.692
<none>			12.8077	-75.703
+ X5	1	0.2691	12.5386	-74.849
+ X7	1	0.2052	12.6025	-74.575

Exemplo: *Forward Stepwise Regression*

Step: AIC=-103.83

y ~ X3

	Df	Sum of Sq	RSS	AIC
+ X2	1	3.0191	4.3125	-130.483
+ X4	1	2.2019	5.1297	-121.113
+ X1	1	1.5506	5.7810	-114.658
+ X8	1	1.1376	6.1940	-110.932
<none>			7.3316	-103.827
+ X6	1	0.2585	7.0730	-103.765
+ X5	1	0.2388	7.0928	-103.615
+ X7	1	0.0650	7.2666	-102.308
- X3	1	5.4762	12.8077	-75.703

Exemplo: *Forward Stepwise Regression*

Step: AIC=-130.48

$y \sim X3 + X2$

	Df	Sum of Sq	RSS	AIC
+ X8	1	1.4696	2.8429	-150.985
+ X1	1	1.2040	3.1085	-146.161
+ X4	1	0.6984	3.6141	-138.023
+ X7	1	0.2263	4.0862	-131.394
+ X5	1	0.1646	4.1479	-130.585
<none>			4.3125	-130.483
+ X6	1	0.0824	4.2300	-129.526
- X2	1	3.0191	7.3316	-103.827
- X3	1	5.6667	9.9792	-87.178

Exemplo: *Forward Stepwise Regression*

Step: AIC=-150.98

$y \sim X3 + X2 + X8$

	Df	Sum of Sq	RSS	AIC
+ X1	1	0.6641	2.1788	-163.351
+ X4	1	0.4663	2.3766	-158.659
+ X6	1	0.1374	2.7055	-151.660
<none>			2.8429	-150.985
+ X5	1	0.0708	2.7721	-150.347
+ X7	1	0.0246	2.8182	-149.455
- X8	1	1.4696	4.3125	-130.483
- X2	1	3.3511	6.1940	-110.932
- X3	1	4.9456	7.7885	-98.562

Exemplo: *Forward Stepwise Regression*

Step: AIC=-163.35

$y \sim X3 + X2 + X8 + X1$

	Df	Sum of Sq	RSS	AIC
+ X6	1	0.0968	2.0820	-163.805
<none>			2.1788	-163.351
+ X5	1	0.0759	2.1029	-163.265
+ X4	1	0.0417	2.1371	-162.395
+ X7	1	0.0229	2.1559	-161.923
- X1	1	0.6641	2.8429	-150.985
- X8	1	0.9297	3.1085	-146.161
- X2	1	2.9873	5.1661	-118.731
- X3	1	5.4513	7.6301	-97.671

Exemplo: *Forward Stepwise Regression*

Step: AIC=-163.81

$y \sim X3 + X2 + X8 + X1 + X6$

	Df	Sum of Sq	RSS	AIC
+ X5	1	0.0768	2.0052	-163.834
<none>			2.0820	-163.805
- X6	1	0.0968	2.1788	-163.351
+ X7	1	0.0224	2.0596	-162.389
+ X4	1	0.0164	2.0656	-162.232
- X1	1	0.6235	2.7055	-151.660
- X8	1	0.9745	3.0565	-145.072
- X2	1	2.8268	4.9088	-119.490
- X3	1	5.0791	7.1611	-99.097

Exemplo: *Forward Stepwise Regression*

Step: AIC=-163.83

$y \sim X3 + X2 + X8 + X1 + X6 + X5$

	Df	Sum of Sq	RSS	AIC
<none>			2.0052	-163.834
- X5	1	0.0768	2.0820	-163.805
- X6	1	0.0977	2.1029	-163.265
+ X7	1	0.0332	1.9720	-162.736
+ X4	1	0.0023	2.0029	-161.896
- X1	1	0.6282	2.6335	-151.117
- X8	1	0.9002	2.9055	-145.809
- X2	1	2.7626	4.7678	-119.064
- X3	1	5.0801	7.0853	-97.672

Call:

`lm(formula = y ~ X3 + X2 + X8 + X1 + X6 + X5, data = Xy)`

Coefficients:

(Intercept)	X3	X2	X8	X1	X6	X5
4.05397	0.01512	0.01376	0.35090	0.07152	0.08732	-0.00345

Validação de Modelos

Introdução

Verificar se um modelo candidato tem bom desempenho em dados independentes daqueles usados para ajuste.

- Coletar novos dados para verificar o modelo e seu poder preditivo.
- Deixar parte dos dados de fora do ajuste, para usar na validação.

Validação Cruzada

Quando temos um grande número de observações, podemos dividir os dados em duas partes: *treinamento* e *teste*.

Com o subconjunto *treinamento* ajustamos o modelo.

Com o subconjunto *teste* verificamos o poder preditivo do modelo.

Calculamos o *mean squared prediction error*:

$$MSPR = \frac{\sum_{i=1}^{n^*} (Y_i - \hat{Y}_i)^2}{n^*}$$

em que Y_i é o valor da variável resposta da i -ésima observação do conjunto teste, \hat{Y}_i é o valor predito para a i -ésima observação do conjunto teste segundo o modelo usando o conjunto treinamento e n^* é o total de observações no conjunto teste.

Exemplo

Temos 54 observações que não foram utilizadas na escolha do modelo para os dados sobre cirurgia. Este será o conjunto de dados *teste*.

Com os dados de *treinamento*, obtemos, usando $PRESS_p$ e BIC_p :

Modelo 1:

$$\ln(Y) = \beta_0 + \beta_1 X_1 + \beta_2 X_2 + \beta_3 X_3 + \beta_8 X_8 + \varepsilon$$

Usando C_p , temos o Modelo 2:

$$\ln(Y) = \beta_0 + \beta_1 X_1 + \beta_2 X_2 + \beta_3 X_3 + \beta_5 X_5 + \beta_8 X_8 + \varepsilon$$

Usando AIC_p e $R_{a,p}^2$, temos o Modelo 3:

$$\ln(Y) = \beta_0 + \beta_1 X_1 + \beta_2 X_2 + \beta_3 X_3 + \beta_5 X_5 + \beta_6 X_6 + \beta_8 X_8 + \varepsilon$$

Exemplo - Modelo 1

```
dadosT <- read.table("./dados/CH09TA05.txt")
colnames(dadosT) <- c("X1", "X2", "X3", "X4", "X5", "X6", "X7", "X8", "Y", "lnY")
modelo1 <- lm(lnY ~ X1 + X2 + X3 + X8, data=dados)
yhat <- predict(modelo1, newdata=dadosT)
MSPR <- function(yhat, yobs){
  mean((yobs-yhat)^2)
}
```

Variável	Estimativa	Erro-Padrão
Intercepto	3.8524186	0.1926952
X_1	0.0733226	0.018973
X_2	0.0141851	0.0017306
X_3	0.0154527	0.0013956
X_8	0.3529676	0.0771906

MSE é 0.044 e $MSPR$ é 0.077

Exemplo - Modelo 2

```
modelo2 <- lm(lnY ~ X1 + X2 + X3 + X5 + X8,data=dados)
yhat <- predict(modelo2,newdata=dadosT)
```

Variável	Estimativa	Erro-Padrão
Intercepto	4.0381206	0.2376904
X_1	0.0736065	0.0188341
X_2	0.0140523	0.0017208
X_3	0.0154557	0.0013853
X_5	-0.0034296	0.0026061
X_8	0.3412188	0.0771389

MSE é 0.044 e $MSPR$ é 0.08

Exemplo - Modelo 3

```
modelo3 <- lm(lnY ~ X1 + X2 + X3 + X5 + X6 + X8,data=dados)
yhat <- predict(modelo3,newdata=dadosT)
```

Variável	Estimativa	Erro-Padrão
Intercepto	4.0539742	0.2347935
X_1	0.0715171	0.0186373
X_2	0.0137555	0.0017094
X_3	0.0151165	0.0013853
X_5	-0.0034501	0.0025718
X_6	0.0873166	0.0577017
X_8	0.3509039	0.0763914

MSE é 0.043 e $MSPR$ é 0.079

Agradecimento

- Slides criados por Samara F Kiihl / IMECC / UNICAMP

Leitura

- Applied Linear Statistical Models: Capítulo 9.
- Faraway - [Linear Models with R](#): Capítulo 10
- Draper & Smith - [Applied Regression Analysis](#): Capítulo 15.
- Tutorial: [Model Selection in R](#)
- [bestglm](#)

