

MAE-350 - MODELOS DE REGRESSÃO I

5ª Lista de Exercícios

Profa. Sílvia N. Eitan

1) Seja  $E(y|x) = \beta_0 + \beta_1 x$  o modelo de regressão linear simples. Deduza um intervalo de confiança para  $\beta_0 + \beta_1$ .

2) No exemplo,  $Y$  = tempo de reação,  $X$  = idade,  $Z$  = acuidade Visual, obter através do cálculo matricial:

a)  $\hat{\beta}_0, \hat{\beta}_1$  e  $\hat{\beta}_2$                       b) ANOVA

c)  $\text{Var}(\hat{\beta}_0), \text{Var}(\hat{\beta}_1), \text{Var}(\hat{\beta}_2)$  e as estimativas de todas as possíveis covariâncias entre os  $\hat{\beta}$ .

d) Um intervalo de confiança para o tempo médio de reação de indivíduos com 28 anos e acuidade visual 80.

3) Sejam

$X_1$	-1	1	-1	1	0	0	0
$X_2$	-1	-1	1	1	0	1	2
$Y$	1	4	8	9	3	8	9

a) Ajuste para esses dados o modelo  $\hat{y} = \hat{\beta}_0 + \hat{\beta}_1 x_1 + \hat{\beta}_2 x_2 + \hat{\beta}_3 x_1^2$

b) Teste ao nível  $\alpha = 0,05$  a hipótese  $H_0: \beta_{11} = 0, \beta_1 = \beta_2$

c) Baseado no resultado deste teste, qual seria o modelo adotado?

4) Seja  $\hat{y} = \hat{\beta}_0 + \hat{\beta}_1 x_1 + \hat{\beta}_2 x_2 + \dots + \hat{\beta}_k x_k$  o modelo de regressão linear com  $k$  variáveis independentes, onde  $(X'X)^{-1} = (a_{ij})_{i,j} = 0,1 \dots k$

a) Deduza um intervalo de confiança para  $\beta_1 - \beta_2$ .

b) Como seria o teste  $H_0: \beta_1 = \beta_2$  contra  $H_1: \beta_1 > \beta_2$ ?

5) Com o objetivo de ajustar o modelo  $y = \beta_0 + \beta_1 x_1 + \beta_2 x_2 + \beta_3 x_3 + \beta_4 x_4 + \epsilon$ , foi obtida uma amostra de 8 observações. Os valores das variáveis independentes estão na tabela

$X_1$	$X_2$	$X_3$	$X_4$	Verifique que, embora o valor dos coeficientes de
-1	-1	-1	-3	correlação entre pares de variáveis independentes
-1	-1	1	-1	seja sempre inferior a 0, 58, existe multicolinearidade
-1	1	-1	-1	perfeita.
-1	1	1	1	
1	-1	-1	-1	
1	-1	1	1	
1	1	-1	1	
1	1	1	3	

6) Deseja-se estudar a quantidade de nitrogênio ( $Y$ ) que não é absorvida por um processo químico, como função das variáveis:

$X_1$  = fluxo de ar                       $X_2$  = temperatura da água usada na refrigeração

$X_3$  = concentração ácida

Decidiu-se usar regressão linear como técnica exploratória para escolher o melhor modelo de dependência. Assim, as 7 possíveis equações de regressão produziram as somas de quadrados da regressão apresentadas abaixo. Escolha o melhor modelo e justifique.

Modelo	$f(X_1)$	$f(X_2)$	$f(X_3)$	$f(X_1, X_2)$	$f(X_1, X_3)$	$f(X_2, X_3)$	$f(X_1, X_2, X_3)$
SSregressão	1750	1580	330	1880	1760	1590	1890
$n = 21$	SST = 2070						

7) Mostre que uma fórmula alternativa para calcular a soma de quadrados da regressão é

$$SSR = \sum_{i=1}^n \hat{y}_i^2 - n\bar{y}^2$$

8) Sejam  $X_1, X_2$  e  $X_3$  variáveis independentes e  $Y$  variável dependente e os modelos:

i)  $y = \alpha_0 X_1^2 X_2 X_3^2 \in$

ii)  $y = e^{\beta_0 + \beta_1 X_1 + \beta_2 X_2 + \epsilon}$

iii)  $y = \frac{1}{\beta_0 + \beta_1 X_1 + \beta_2 X_2 + \epsilon}$

iv)  $y = \frac{1}{\beta_0 + \beta_1 X_1 + \beta_2 X_2 + \epsilon}$

a) Transforme cada um dos modelos acima num modelo de regressão linear.

b) Para cada modelo transformado, especifique quais são as variáveis independentes e dependentes, o resíduo e os parâmetros.

- 9) Sejam três regressões onde o número de observações e os valores das variáveis independentes são os mesmos. Na primeira, a variável dependente é  $Y_1$ , na segunda  $Y_2$  e na terceira  $Y_3 = Y_1 + Y_2$ .

Sejam  $\hat{\beta}_1, \hat{\beta}_2, \hat{\beta}_3$  os estimadores de mínimos quadrados dos parâmetros respectivamente

da 1a, 2a, e 3a. equação de regressão, prove que:  $\hat{\beta}_3 = \hat{\beta}_1 + \hat{\beta}_2$

- 10) Um ensaio de adubação forneceu os seguintes resultados:

onde	$X =$ dose de adubo por hectare	$Y =$ produção por hectare	
		$y_1$	$y_2$
0	6	8	
1	16	18	
2	18	20	
3	12	14	
	$\bar{y}_1 = 14$	$\bar{y}_2 = 17,6$	

Admitindo um modelo da forma  $y = \beta_0 + \beta_1 x + \beta_2 x^2 + \epsilon$

- a) Obtenha os estimadores de mínimos quadrados de  $\beta_0, \beta_1$  e  $\beta_2$ .  
 b) Teste a hipótese que a produção máxima é obtida aplicando 2 doses de adubo por hectare. (Obs.: Se  $y = ax^2 + bx + c$ , o ponto de máximo é  $x = -\frac{b}{2a}$ ).  
 c) Teste a hipótese  $H_0: \beta_2 = 0$  contra  $H_1: \beta_2 \neq 0$ .

- 11) O administrador de um hospital deseja estudar a relação entre o nível de satisfação do paciente ( $Y$ ), a idade do paciente ( $X_1$ , em anos), severidade da doença ( $X_2$ , um índice) e nível de ansiedade ( $X_3$ , um índice). Para isto, selecionou 23 pacientes e coletou os dados abaixo, onde grandes valores de  $Y, X_2$  e  $X_3$  estão respectivamente associados com mais satisfação, aumento da severidade da doença e mais ansiedade.

i	1	2	3	4	5	6	7	8	9
$X_{1i}$	50	36	40	41	28	49	42	45	52
$X_{2i}$	51	46	48	44	43	54	50	48	62
$X_{3i}$	2,3	2,3	2,2	1,8	1,8	2,9	2,2	2,4	2,9
$Y_i$	48	57	66	70	89	36	46	54	26
i	10	11	12	13	14	15	16	17	18
$X_{1i}$	29	29	43	38	34	53	36	33	29
$X_{2i}$	50	48	53	55	51	54	49	56	46
$X_{3i}$	2,1	2,4	2,4	2,2	2,3	2,2	2,0	2,5	1,9
$Y_i$	77	89	67	47	51	57	66	79	88
i	19	20	21	22	23				
$X_{1i}$	33	55	29	44	43				
$X_{2i}$	49	51	52	58	50				
$X_{3i}$	2,1	2,4	2,3	2,9	2,3				
$Y_i$	60	49	77	52	60				

- a) Ajuste a estes dados o modelo de regressão  $y_i = \beta_0 + \beta_1 x_{1i} + \beta_2 x_{2i} + \beta_3 x_{3i} + \epsilon_i$  e descreva a equação de regressão obtida. Qual o significado prático de  $\beta_2$  neste caso?  
 b) Faça um box plot dos resíduos. Este gráfico sugere a presença de outliers?  
 c) Construa o gráfico dos resíduos contra  $\hat{y}_i$  e contra cada variável independente envolvida. Construa o normal probability plot e com base nestas análises e na do item b), tire conclusões.  
 d) Teste, ao nível de significância 0,10 a existência de relação entre a variável resposta  $Y$  e as três variáveis explicativas consideradas. Calcule aproximadamente o p-value.  
 e) Calcule o coeficiente de correlação múltipla deste modelo.
- 12) No exercício anterior, admitindo válidas todas as suposições do modelo de regressão,
- a) Obtenha um intervalo de confiança para o nível médio de satisfação de pacientes com 35 anos, grau de severidade da moléstia 45 e nível de ansiedade 2,2. Use coeficiente de confiança de 0,90.  
 b) Obtenha um intervalo de previsão para o nível de satisfação de um novo paciente com 50 anos, severidade da moléstia 45 e nível de ansiedade 2,0.
- 13) No exercício 11, verifique se a variável  $X_3$  pode ser descartada do modelo, dado que  $X_1$  e  $X_2$  estão mantidas. Use  $\alpha = 0,025$ .
- 14) Repita o problema para testar se  $X_2$  e  $X_3$  podem ser descartadas dado que  $X_1$  é mantida. Use  $\alpha = 0,025$ .

*Resolver utilizando o R.*

15) Sejam as seguintes características relativas ao preço de 20 terrenos

Terreno	área (em milhares de pés quadr.) = $X_1$	grau de declive = $X_2$	Vista Panorâmica = $X_3$ escala: 1 (pobre) a 9 (excelente)	Preço = $Y$ (mil dólares)
1	14.7	1.5	2	4.1
2	14.2	1.8	2	3.9
3	12.7	2.9	1	3.2
4	13.8	1.0	1	2.9
5	14.4	0.5	2	3.9
6	17.4	1.0	2	4.1
7	21.8	5.7	4	5.8
8	14.0	5.4	6	5.1
9	17.5	17.5	9	6.8
10	23.0	14.5	9	6.8
11	18.3	14.4	9	6.5
12	19.4	12.2	9	7.0
13	15.2	5.0	8	5.8
14	18.3	13.1	6	5.1
15	21.7	15.2	8	5.3
16	16.7	10.1	8	4.9
17	13.6	7.4	7	6.0
18	14.5	5.8	7	5.3
19	12.1	5.1	7	4.8
20	17.4	17.3	1	4.3

Usando as variáveis independentes  $X_1$ ,  $X_2$  e  $X_3$ , qual seria a equação de regressão mais indicada para o problema?  
Obs.: Possíveis equações (23 possíveis equações)

$$\hat{y} = \hat{\beta}_0 + \hat{\beta}_1 x_1$$

$$\hat{y} = \hat{\beta}_0 + \hat{\beta}_1 x_1 + \hat{\beta}_2 x_2$$

$$\hat{y} = \hat{\beta}_0 + \hat{\beta}_1 x_1 + \hat{\beta}_2 x_2 + \hat{\beta}_3 x_3$$

$$\hat{y} = \hat{\beta}_0 + \hat{\beta}_1 x_2$$

$$\hat{y} = \hat{\beta}_0 + \hat{\beta}_1 x_1 + \hat{\beta}_3 x_3$$

$$\hat{y} = \bar{y}$$

$$\hat{y} = \hat{\beta}_0 + \hat{\beta}_3 x_3$$

$$\hat{y} = \hat{\beta}_0 + \hat{\beta}_2 x_2 + \hat{\beta}_3 x_3$$

Para selecionar o modelo utilize o teste F parcial como critério básico.  
A manutenção do modelo selecionado estará condicionada à análise posterior. Nesta análise, não esquecer de:

- 1) Calcular os coeficientes de Explicação:  $R^2$  e  $\bar{R}^2$ .
- 2) Fazer o teste de falta de ajuste (se possível).
- 3) Fazer uma análise de resíduos rigorosa, incluindo diagnóstico.
- 4) Interpretar todas as conclusões obtidas, estudar o significado prático das estimativas dos parâmetros, etc...
- 5) Com base nos itens estudados, apresentar uma conclusão geral, salientando as qualidades do modelo selecionado.