

INSTITUTO SUPERIOR DE AGRONOMIA  
**ESTATÍSTICA E DELINEAMENTO – 2015/16**

5 de Janeiro de 2016

Segundo Teste

Duração: 2h30

I [10 valores]

No quadro de um estudo sobre transpiração em olival foram medidos rigorosamente no terreno valores diários de transpiração (variável Tr, em mm/dia) em dias escolhidos ao acaso ao longo de 3 anos. Numa tentativa de relacionar transpiração com variáveis obtidas por observação da terra por satélite, foi ajustado um modelo de regressão linear cujos preditores são reflectâncias à superfície em várias bandas de comprimento de onda (variáveis BLUE, GREEN, RED, NIR, SWIR1 e SWIR2, adimensionais, com valores entre 0 e 1) para sensores Landsat; o índice de vegetação NDVI (adimensional, com valores entre -1 e 1) derivado das bandas RED e NIR; e a temperatura (variável TIR, em graus centígrados) derivada da banda térmica dos sensores. Eis a matriz de correlações das observações e as médias e desvios padrão de cada variável:

	Tr	BLUE	GREEN	RED	NIR	SWIR1	SWIR2	NDVI	TIR		média	desv.padrão
Tr	1.00	0.86	0.89	0.89	0.47	0.86	0.87	-0.83	0.83	Tr	1.3360	0.90107068
BLUE	0.86	1.00	0.98	0.97	0.60	0.91	0.89	-0.86	0.81	BLUE	0.0770	0.01762375
GREEN	0.89	0.98	1.00	0.98	0.69	0.94	0.92	-0.83	0.86	GREEN	0.1073	0.02440693
RED	0.89	0.97	0.98	1.00	0.62	0.97	0.95	-0.89	0.90	RED	0.1264	0.03308019
NIR	0.47	0.60	0.69	0.62	1.00	0.65	0.58	-0.22	0.51	NIR	0.2793	0.02962072
SWIR1	0.86	0.91	0.94	0.97	0.65	1.00	0.99	-0.85	0.92	SWIR1	0.2872	0.06304776
SWIR2	0.87	0.89	0.92	0.95	0.58	0.99	1.00	-0.87	0.90	SWIR2	0.2105	0.06055228
NDVI	-0.83	-0.86	-0.83	-0.89	-0.22	-0.85	-0.87	1.00	-0.86	NDVI	0.3853	0.09287009
TIR	0.83	0.81	0.86	0.90	0.51	0.92	0.90	-0.86	1.00	TIR	25.8878	8.93238028

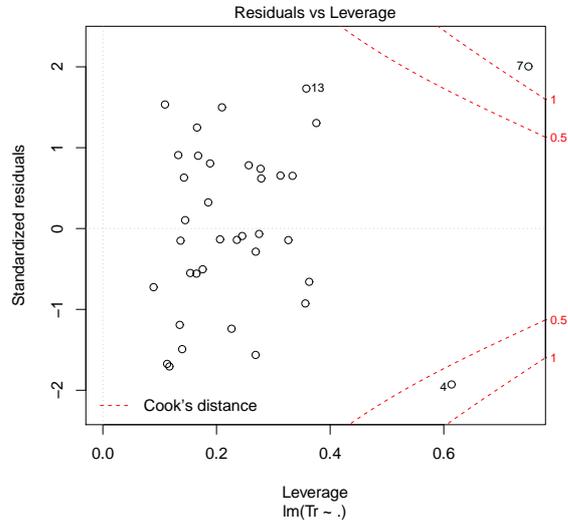
Eis o ajustamento dum regressão linear múltipla de Tr sobre as restantes variáveis:

	Estimate	Std.Error	t value	Pr(> t )
(Intercept)	-5.92560	2.05224	-2.887	0.00741
BLUE	-14.11886	20.26174	-0.697	0.49166
GREEN	64.48073	21.24687	3.035	0.00515
RED	31.97623	20.36151	1.570	0.12755
NIR	-36.21879	10.34842	-3.500	0.00158
SWIR1	-7.61723	14.60201	-0.522	0.60601
SWIR2	10.21927	9.83247	1.039	0.30754
NDVI	16.55497	5.46086	3.032	0.00519
TIR	0.04466	0.02403	1.858	0.07365

Residual standard error: 0.3179 on 28 DF  
Multiple R-squared: 0.9032, Adjusted R-squared: 0.8755  
F-statistic: 32.64 on 8 and 28 DF, p-value: 3.262e-12

1. Com base em quantas observações foi ajustado o modelo? Justifique.
2. Como interpretar, no contexto do problema, o valor da estimativa  $-14.11886$  associada à variável BLUE, tendo em conta que essa variável só toma valores no intervalo  $]0.04, 0.12[$ ?
3. Teste formalmente ( $\alpha = 0.05$ ) se se pode concluir que um aumento da temperatura está associado a um aumento da transpiração, para valores iguais nas restantes variáveis. Exija o ónus da prova para esta afirmação.

4. Com base no modelo completo foi produzido o seguinte gráfico de diagnósticos. Descreva o gráfico e discuta as principais conclusões da sua análise.



5. Foi escolhido um submodelo do modelo original, apenas com quatro preditores: GREEN, NIR, NDVI e TIR. Foram obtidos os seguintes resultados:

Coefficients:

	Estimate	Std. Error	t value	Pr(> t )	
(Intercept)	-3.64659	1.21674	-2.997	0.00523	**
GREEN	66.82066	13.29883	5.025	1.85e-05	***
NIR	-24.96892	6.95825	-3.588	0.00110	**
NDVI	9.04922	3.29300	2.748	0.00977	**
TIR	0.05009	0.01710	2.930	0.00620	**

---

Residual standard error: 0.3384 on 32 degrees of freedom

Multiple R-squared: 0.8746, Adjusted R-squared: 0.859

F-statistic: 55.82 on 4 and 32 DF, p-value: 5.574e-14

- Teste formalmente ( $\alpha = 0.05$ ) se este submodelo tem um ajustamento significativamente diferente do modelo completo. Comente as suas conclusões.
- Com base na informação disponível, discuta possíveis razões pelas quais o facto das variáveis BLUE e RED terem sido excluídas deste submodelo tenha pouco efeito sobre o valor do coeficiente de determinação.
- Calcule neste submodelo a distância de Cook da observação 7, sabendo que o seu resíduo usual é  $e_7 = -0.1333$  e que o seu efeito alavanca é  $h_{7,7} = 0.39051$ . Comente, tendo também em atenção o gráfico do ponto 4, criado a partir do modelo completo.

## II [6 valores]

No âmbito de um estudo realizado em Mangualde sobre o rendimento de diferentes genótipos da casta de videira Alfrocheiro, foram ensaiados cada um de  $a$  genótipos nos anos 1994, 1996, 1997, 1999 e 2000. Foi efectuada uma Análise de Variância para estudar os efeitos dos factores **genótipo** e **ano** sobre a variável resposta **rendimento** (medida em kg/planta) em cada uma das  $n$  parcelas observadas, tendo sido obtida a seguinte tabela resumo:

	Df	Sum Sq	Mean Sq	F value	Pr(>F)
genótipo	11	15.31	1.39	2.945	0.000904
ano	4	208.25	52.06	???	???
genótipo:ano	44	22.29	0.51	1.072	0.354088
Residuals	420	198.44	???		

1. Descreva pormenorizadamente o tipo de delineamento e o modelo ANOVA correspondente, sabendo que o delineamento utilizado era equilibrado. Em particular, indique com base na informação disponível e justificando, qual o número de diferentes genótipos que foram usados no estudo e qual o número de observações efectuadas em cada ano, para cada genótipo.
2. Qual o valor estimado da variância dos erros aleatórios do modelo, e quais as suas unidades de medida?
3. Utilize testes  $F$  para indicar quais os tipos de efeitos que devem ser considerados significativos ao nível  $\alpha = 0.05$  (caso necessite de vários testes, descreva um em pormenor e sintetize os restantes).
4. Um analista decidiu que bastava analisar estes dados com uma ANOVA a um factor, o factor **genótipo**. Construa, justificando, a tabela ANOVA obtida pelo referido analista. As conclusões do teste aos efeitos do factor **genótipo** obtidas pelo analista são coerentes com as obtidas inicialmente? Discuta os seus resultados.

## III [4 valores]

1. Seja dada uma matriz rectangular  $\mathbf{X}_{n \times m}$ .
  - (a) Mostre que a projecção ortogonal de qualquer vector  $\vec{z} = \mathbf{X}\vec{a} \in \mathcal{C}(\mathbf{X})$  sobre o próprio subespaço  $\mathcal{C}(\mathbf{X})$  deixa o vector  $\vec{z}$  invariante.
  - (b) Mostre que a matriz de projecção ortogonal sobre  $\mathcal{C}(\mathbf{X})$  é simétrica e idempotente.
2. Considere o modelo ANOVA para um delineamento a um factor, equilibrado. Tratando-se dum modelo linear, é possível calcular o respectivo coeficiente de determinação  $R^2$ , embora não seja usual fazê-lo em modelos ANOVA.
  - (a) Indique condições equivalentes ao valor extremo  $R^2 = 0$ , envolvendo as médias amostrais de nível e da totalidade das observações. Interprete essa situação em termos do teste  $F$  da ANOVA.
  - (b) Indique condições equivalentes ao valor extremo  $R^2 = 1$ , envolvendo as variâncias amostrais de nível. Interprete essa situação em termos do teste  $F$  da ANOVA.