

INSTITUTO SUPERIOR DE AGRONOMIA  
MATEMÁTICA E ESTATÍSTICA – 2009/10

1 de Fevereiro, 2010

**SEGUNDA CHAMADA DE EXAME**  
(Parte de Estatística)

**Duração:** 1h45

**I**

A relação entre quantidade de precipitação num dia (em *mm*) e quantidade de água que escorre pelo tronco duma árvore (escorrimento ao longo do tronco, em *ml*) é de interesse no estudo da intercepção da precipitação pelo coberto vegetal. No âmbito dum estudo destas relações, foi medida a precipitação em 28 dias de chuva, e os correspondentes escorrimentos para três árvores (numa mesma parcela experimental) da espécie *Liriodendron tulipifera*. Experiência prévia destes estudos sugere que as relações são melhor estudadas quando se procede à logaritmização das variáveis. Eis alguns dos dados logaritmizados obtidos em cada dia, bem como as respectivas médias e variâncias globais:

dia	ln(precipitação)	ln(escorrimento)		
		Árvore 1	Árvore 2	Árvore 3
1	2.4423	6.9613	6.4069	9.1407
2	2.7663	7.7446	6.0307	9.3384
3	2.0412	5.3375	5.1930	6.0426
⋮	⋮	⋮	⋮	⋮
27	1.1632	3.9512	3.4965	2.9444
28	1.9459	1.6094	4.9200	4.3820

Para as 84 observações de cada variável logaritmizada, tem-se:

	ln-precipit.	ln-escorrim.
Média	2.213738	6.454755
Variância	0.866739	7.3268

Foi ajustada uma regressão linear simples de logaritmos do escorrimento (variável *ln.esc*) sobre logaritmos da precipitação (*ln.prec*), utilizando as 84 observações, com os seguintes resultados:

```
> summary(lm(ln.esc ~ ln.prec, data=dadosEx2))
Coefficients:
              Estimate Std. Error t value Pr(>|t|)
(Intercept)  0.9971      0.4084   2.442  0.0168
ln.prec      2.4654      0.1702  14.485 <2e-16
---
Residual standard error: 1.444 on 82 degrees of freedom
Multiple R-squared: 0.719, Adjusted R-squared: 0.7156
F-statistic: ??? on 1 and 82 DF, p-value: < 2.2e-16
```

1. Qual o valor da estatística  $F$  no teste de ajustamento global do modelo?
2. Qual o coeficiente de correlação entre as variáveis (logaritimizadas) envolvidas nesta regressão? Justifique, em particular, o sinal dessa correlação.
3. Determine um intervalo a 95% de confiança para o valor esperado do log-escorrimento, associado aos dias em que se verifiquem 10 *mm* de precipitação.
4. Com base na referida regressão linear simples, diga qual a equação ajustada para a relação entre as variáveis precipitação e escorrimento (não logaritimizadas)?
5. Será admissível afirmar que o escorrimento (em *ml*) é proporcional ao quadrado da precipitação (em *mm*)? Responda utilizando um procedimento estatístico adequado.

## II

Num estudo sobre uma população experimental de clones da casta Tinta Francisca, realizado em 2003 em Tabuaço, foram medidos os valores das seguintes variáveis em 24 videiras: teor de antocianinas (em  $mg/dm^3$ , variável `antoci`); teor de açúcar (variável `acucar`, em  $g/l$ ); pH (variável `pH`); acidez total (em  $g$  de ácido tartárico por  $dm^3$ , variável `actot`); e fenóis totais (variável `fentot`). Uma característica muito importante de algumas castas é a cor do bago, que está associada à pigmentação da película do bago, e portanto ao teor em antocianinas. Pretende-se modelar esta variável, à custa das restantes variáveis observadas. Foram obtidos os seguintes resultados.

```
Call: lm(formula = antoci ~ acucar + pH + actot + fentot, data = Ex2RM)
```

Coefficients:

	Estimate	Std. Error	t value	Pr(> t )
(Intercept)	908.6751	679.2284	1.338	0.1968
acucar	0.9885	0.7308	1.353	0.1920
pH	-234.0446	123.6247	-1.893	0.0737
actot	-17.3130	50.0359	-0.346	0.7331
fentot	20.8702	2.5662	8.133	1.31e-07

---

Residual standard error: 45.12 on 19 degrees of freedom

Multiple R-squared: 0.8225, Adjusted R-squared: 0.7851

F-statistic: 22.01 on 4 and 19 DF, p-value: 6.501e-07

1. Comente a qualidade do modelo ajustado, efectuando um teste de hipóteses apropriado e discutindo o valor do coeficiente de determinação.
2. Comente a diferença entre os valores indicados para o  $R^2$  e para o  $R^2$  modificado (*adjusted*).
3. Construa um intervalo de confiança para a alteração esperada no teor de antocianinas, associado a um aumento de  $1 g/l$  no teor de açúcar.
4. Foi efectuado um algoritmo de exclusão sequencial com o objectivo de estudar a possível simplificação do modelo. A listagem de resultados produzidos pelo programa R é a seguinte:

```
> step(lm(antoci ~ acucar + pH + actot + fentot, data=Ex2RM))
Start: AIC=187.24
antoci ~ acucar + pH + actot + fentot
      Df Sum of Sq  RSS   AIC
- actot  1      244 38920   185
<none>                38676   187
- acucar  1     3724 42401   187
- pH      1     7296 45972   189
- fentot  1    134631 173308  221
      NOTA: ‘RSS’ são as
            iniciais em inglês
            da Soma de Quadrados
            Residual.

Step: AIC=185.39
antoci ~ acucar + pH + fentot
      Df Sum of Sq  RSS   AIC
<none>                38920   185
- acucar  1      4220 43140   186
- pH      1     9209 48129   188
- fentot  1    148138 187057  221
```

O submodelo seleccionado tem apenas três variáveis predictoras: `acucar`, `pH` e `fentot`.

- (a) Com base na informação disponível, determine o valor do coeficiente de determinação associado ao submodelo seleccionado.
- (b) A partir deste submodelo, seleccionado pelo programa R, qual a variável cuja exclusão menos afecta a qualidade do ajustamento? Justifique.
- (c) Efectue um teste  $F$  parcial comparando o submodelo de dois preditores que escolheu na alínea anterior, com o submodelo de três preditores escolhido pelo programa R, e comente as conclusões deste teste, para um nível de significância 0.05.

### III

Considere um modelo ANOVA, a um factor com  $k = 3$  níveis. Admita que o modelo é equilibrado, e ajustado com  $n_c$  observações em cada nível.

1. Descreva a matriz  $\mathbf{X}$  do delineamento.
2. Mostre que o subespaço das colunas desta matriz,  $\mathcal{C}(\mathbf{X})$ , é igual ao subespaço das colunas da matriz  $\mathbf{Y}$ , sendo esta última matriz constituída pelas três variáveis indicatrizes dos três níveis do factor,  $\mathbf{I}_1$ ,  $\mathbf{I}_2$  e  $\mathbf{I}_3$ .
3. Tendo em conta a alínea anterior, mostre que a matriz de projecção ortogonal sobre o subespaço das colunas de  $\mathbf{X}$  é uma matriz da forma:

$$\mathbf{H} = \begin{bmatrix} \mathbf{A}_{n_c} & \mathbf{0}_{n_c} & \mathbf{0}_{n_c} \\ \mathbf{0}_{n_c} & \mathbf{A}_{n_c} & \mathbf{0}_{n_c} \\ \mathbf{0}_{n_c} & \mathbf{0}_{n_c} & \mathbf{A}_{n_c} \end{bmatrix},$$

sendo  $\mathbf{A}_{n_c}$  uma matriz  $n_c \times n_c$  cujos valores são todos iguais a  $\frac{1}{n_c}$ , e  $\mathbf{0}_{n_c}$  uma matriz  $n_c \times n_c$  cujos valores são todos iguais a zero.

4. A partir do resultado da alínea anterior, mostre que o valor ajustado de qualquer das observações do nível  $i$  é sempre igual à média amostral das observações nesse nível, ou seja, que  $\hat{y}_{ij} = \bar{y}_i, \forall i$ .