

I [13 valores]

Um estudo sobre a variedade de macieira "**Bravo** de Esmolfe", realizado um ano após a transplantação das árvores para o terreno, visa encontrar um modelo para prever o número médio de frutos à colheita (variável `nfrColh`) a partir de outras 4 variáveis: o diâmetro das árvores 10 cm acima do ponto de enxertia (variável `diametro`, em cm), a altura da árvore (variável `altura`, em m), o número médio de frutos contados em Junho (variável `nfrJun`) e o número médio de frutos contados em Setembro (variável `nfrSet`). Dispõem-se de valores médios de todas as variáveis para 66 parcelas plantados ao acaso num ensaio.

- Um dos técnicos que realizou este estudo decidiu ajustar o modelo de regressão linear múltipla do número médio de frutos à colheita (variável `nfrColh`) sobre as restantes variáveis observadas. Eis os resultados obtidos com o ajustamento desse modelo, bem como a matriz de (co-)variâncias estimadas dos estimadores dos parâmetros do modelo:

```
> macieirabravo1.lm<-lm(nfrColh~diametro+altura+nfrJun+nfrSet, data=macieirabravo)
> summary(macieirabravo1.lm)
```

Coefficients:

	Estimate	Std. Error	t value	Pr(> t)
(Intercept)	1.33619	0.97581	1.369	0.176
diametro	0.01684	0.05833	0.289	0.774
altura	-1.22301	0.77971	-1.569	0.122
nfrJun	-0.08156	0.16230	-0.502	0.617
nfrSet	0.85605	0.19427	A	4.33e-05

Residual standard error: 0.5034 on B degrees of freedom
 Multiple R-squared: 0.9496, Adjusted R-squared: 0.9463
 F-statistic: C on 4 and 61 DF, p-value: < 2.2e-16

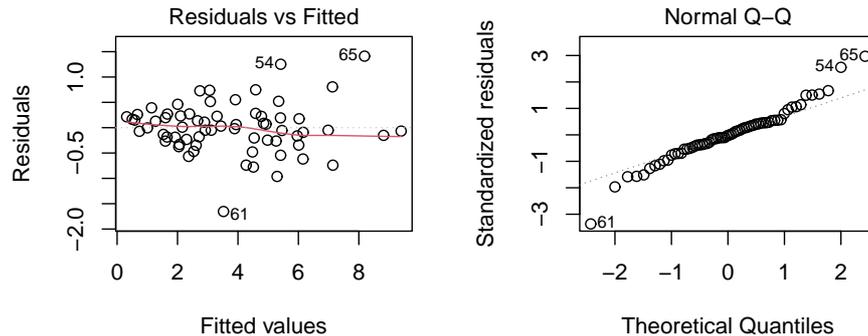
```
> round(vcov(macieirabravo1.lm), 3)
      (Intercept) diametro altura nfrJun nfrSet
(Intercept)    0.952   -0.001 -0.526  0.022 -0.019
diametro       -0.001    0.003 -0.032  0.001 -0.002
altura         -0.526   -0.032    D   -0.024  0.031
nfrJun         0.022    0.001 -0.024  0.026 -0.031
nfrSet        -0.019   -0.002  0.031 -0.031  0.038
>
```

- No *output* dos comandos `summary` e `vcov` do R identifique e calcule, justificando, os valores em falta A, B, C e D .
- Ao nível de significância $\alpha = 0.05$, o modelo ajustado difere significativamente do modelo nulo? Justifique a sua resposta.
- Dado o Modelo de Regressão Linear Múltipla, e sabendo que o vector de estimadores dos parâmetros é dado por $\vec{\beta} = (\mathbf{X}^t \mathbf{X})^{-1} \mathbf{X}^t \vec{Y}$, prove que a matriz de (co-)variâncias do vector de estimadores é dada por $V[\vec{\beta}] = \sigma^2 (\mathbf{X}^t \mathbf{X})^{-1}$.
- Após a aplicação do algoritmo de exclusão sequencial com base em testes T aos parâmetros do modelo (para $\alpha = 0.10$), chegou-se ao seguinte submdelo:

```
> macieirabravo2.lm<-lm(nfrColh~altura+nfrSet, data=macieirabravo)
> summary(macieirabravo2.lm)
Coefficients:
              Estimate Std. Error t value Pr(>|t|)
(Intercept)  1.41493    0.95357   1.484  0.1428
altura      -1.10790    0.54136  -2.047  0.0449
nfrSet       0.76444    0.02365  32.322 <2e-16
---
```

```
Residual standard error: 0.4968 on 63 degrees of freedom
Multiple R-squared:  0.9493, Adjusted R-squared:  0.9477
F-statistic: 589.8 on 2 and 63 DF,  p-value: < 2.2e-16
```

- i. Qual foi a ordem de exclusão das duas variáveis que saíram do modelo? Explique e justifique a sua resposta.
- ii. A qualidade do ajustamento do modelo completo e do seu submodelo difere significativamente ($\alpha=0.05$)? Descreva, em pormenor, o teste efectuado para responder à questão.
- iii. Interprete o significado da estimativa do coeficiente associado ao preditor **altura**.
- iv. Calcule um intervalo a 95% de confiança para o coeficiente associado ao preditor **altura**. Explique o seu significado.
- v. Alguns dos gráficos dos resíduos obtidos com o ajustamento deste submodelo com dois preditores apresentam-se seguidamente:



- A. Analise os 2 gráficos e discuta as suas implicações para o estudo efetuado.
- B. Calcule o valor exacto do resíduo usual associado à observação 61 (valores das variáveis na observação 61: $altura_{61} = 1.917$, $nfrSet_{61} = 5.533$, $nfrColh_{61} = 1.867$).

2. No estudo efetuado, as árvores das 66 parcelas são de diferentes regiões, estando 22 parcelas plantadas com material originário de cada uma de 3 regiões de origem: Trás-os-Montes (TM), Beira Interior (BI) e Beira Litoral (BL). Assim, o técnico, considerando válidos os pressupostos do modelo e olhando para o resultado do ajustamento do submodelo ao nível $\alpha=0.01$, decidiu ajustar um modelo de Análise de Covariância à totalidade das $n = 66$ observações, tendo como variável resposta o número médio de frutos à colheita (variável **nfrColh**), variável preditora numérica o número médio de frutos contados em Setembro (variável **nfrSet**) e variável preditora categórica a **origem** (factor, com 3 níveis). Eis os resultados do ajustamento deste modelo:

```
> macieirabravo3.lm<-lm(nfrColh~nfrSet*origem, data=macieirabravo)
> summary(macieirabravo3.lm)
Coefficients:
              Estimate Std. Error t value Pr(>|t|)
(Intercept)  -0.16111    0.22461  -0.717  0.4760
nfrSet       0.64392    0.04845  13.290 <2e-16
```

```

origemBL      -0.29445    0.34268   -0.859    0.3936
origemTM      -0.70381    0.36783   -1.913    0.0605
nfrSet:origemBL 0.10240    0.06123    1.672    0.0996
nfrSet:origemTM 0.15256    0.06316    2.416    0.0188
---
```

```

Residual standard error: 0.4987 on 60 degrees of freedom
Multiple R-squared:  0.9513, Adjusted R-squared:  0.9473
F-statistic: 234.6 on 5 and 60 DF,  p-value: < 2.2e-16
```

- (a) Interprete as estimativas dos parâmetros do modelo e escreva a equação da recta ajustada referente a cada região de origem de "**Bravo de Esmolfe**".
 - (b) Os declives das rectas de regressão para as origens Trás-os-Montes (*TM*) e Beira Interior (*BI*) são significativamente diferentes ao nível $\alpha=0.05$? Justifique a sua resposta com o teste de hipóteses adequado, indicando todos os seus passos.
3. Um outro técnico que também analisou os resultados dos modelos ajustados, sugeriu ajustar uma regressão linear simples para prever o logaritmo do número médio de frutos à colheita a partir do logaritmo do número médio de frutos contados em Setembro. O resultado do ajustamento foi o seguinte:

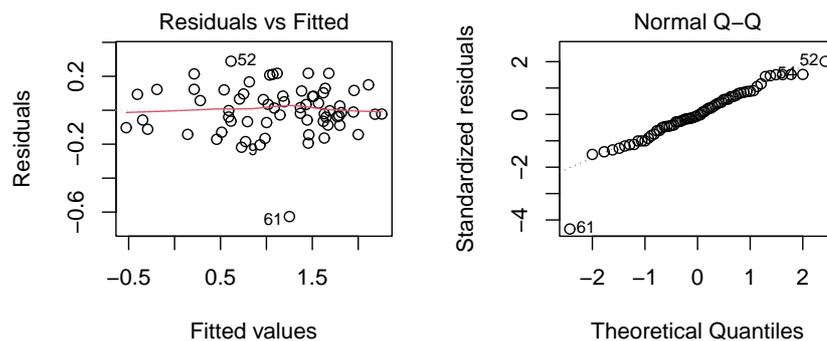
```

> macieirabravo22.lm<-lm(log(nfrColh)~log(nfrSet), data=macieirabravo)
> summary(macieirabravo22.lm)
Coefficients:
              Estimate Std. Error t value Pr(>|t|)
(Intercept) -0.73860    0.05327  -13.87  <2e-16
log(nfrSet)  1.16293    0.03143   37.00  <2e-16
---
```

```

Residual standard error: 0.1454 on 64 degrees of freedom
Multiple R-squared:  0.9553, Adjusted R-squared:  0.9546
F-statistic: 1369 on 1 and 64 DF,  p-value: < 2.2e-16
```

- (a) Interprete o valor do coeficiente de determinação R^2 . Qual o valor do coeficiente de correlação entre as variáveis transformadas?
- (b) Deduza a relação não linear entre o número médio de frutos à colheita e o número médio de frutos contados em Setembro que corresponde à regressão linear ajustada. Escreva a equação da curva ajustada.
- (c) Com o ajustamento deste modelo obtiveram-se os gráficos dos resíduos apresentados seguidamente. Considera que o técnico fez uma boa opção? Justifique sucintamente a sua resposta.



II [7 valores]

1. No estudo sobre a variedade de macieira "**Bravo** de Esmolfe" anteriormente descrito foram estudadas no mesmo local as 3 regiões de origem das árvores plantadas nas parcelas, designadas TM, BI e BL. No ensaio realizado, foram aleatoriamente associadas 22 parcelas a cada região de origem e avaliou-se o número médio de frutos à colheita em cada parcela. A média amostral de todas as observações e as médias amostrais por região de origem são indicadas seguidamente:

```
> model.tables(macieirabravo.aov, type="means")
Tables of means
Grand mean
```

```
3.727788
```

```
  origem
origem
  BI    BL    TM
2.468 4.248 4.467
```

- (a) Descreva o delineamento experimental adotado para o ensaio e, em pormenor, o modelo ANOVA adequado ao problema sob estudo.
 (b) Seguidamente apresenta-se a tabela ANOVA relativa ao estudo efectuado:

```
> summary(macieirabravo.aov)
              Df Sum Sq Mean Sq F value Pr(>F)
origem         2    A      26.441    C      0.00258
Residuals     B 253.83    4.029
```

Complete a tabela, indicando como obtém cada um dos valores em falta A, B e C.

- (c) Pode afirmar-se que o número médio de frutos à colheita é igual para todas as regiões de origem? Formalize e efectue o teste F adequado ao problema, ao nível $\alpha=0.05$.
 (d) Quais as estimativas dos parâmetros do modelo?
 (e) O número médio de frutos à colheita em parcelas com origem Beira Litoral é igual ao número médio de frutos à colheita em parcelas com origem Beira Interior? Justifique a sua resposta com o teste de Tukey ($\alpha=0.05$)
 (f) Prove que, no contexto da ANOVA descrita neste exercício, o resíduo da observação Y_{ij} é dado pela sua diferença em relação à média amostral de nível

$$E_{ij} = Y_{ij} - \bar{Y}_i.$$

- (g) Prove que no contexto da ANOVA descrita neste exercício, o Quadrado Médio Residual é a média (simples) das k variâncias de nível S_i^2 da variável resposta Y :

$$QMRE = \frac{1}{k} \sum_{i=1}^k S_i^2$$

2. O técnico que realizou este estudo não ficou satisfeito quando analisou os gráficos dos resíduos para validação dos pressupostos do modelo. Dada a natureza dos dados, adoptou de seguida uma abordagem não paramétrica. A soma das ordenações do número médio de frutos à colheita das 22 parcelas avaliadas para cada uma das 3 regiões de origem (R_i) foi a seguinte: $R_{BI} = 474$, $R_{BL} = 854$, $R_{TM} = 883$.

Descreva em pormenor o teste não paramétrico que neste contexto deverá ser realizado. O que conclui sobre o estudo efectuado ao nível $\alpha=0.05$?

($\chi_{0.05(1)}^2 = 3.841$; $\chi_{0.05(2)}^2 = 5.991$; $\chi_{0.05(3)}^2 = 7.815$; $\chi_{0.05(4)}^2 = 9.488$).

3. Ainda neste estudo, pretendeu-se determinar o conteúdo de vitamina C na polpa da maçã. Para tal, ao acaso, separaram-se 2 frutos de cada uma das 22 parcelas de cada região de origem, tendo sido levados para o laboratório.
- (a) Indique as unidades experimentais do ensaio.
 - (b) Esta experiência tem pseudo-repetições?
 - (c) Quantas repetições existem por região de origem?