

I

1. O valor  $R^2 = 0.9308$  indica que este modelo, com  $p=4$  preditores e  $n=149$  observações, explica 93,08% da variabilidade observada na variável resposta **producao**, um valor muito elevado. É de esperar que um teste de ajustamento global conduza à rejeição da Hipótese Nula. Tem-se:

**Hipóteses:**  $H_0 : \mathcal{R}^2 = 0$  vs.  $H_1 : \mathcal{R}^2 > 0$ .

**Estatística do Teste:**  $F = \frac{QMR}{QMRE} = \frac{n-(p+1)}{p} \frac{R^2}{1-R^2} \cap F_{(p, n-(p+1))}$ , sob  $H_0$ .

**Nível de significância:**  $\alpha = 0.05$ .

**Região Crítica:** (Unilateral direita) Rejeitar  $H_0$  se  $F_{calc} > f_{\alpha[4,144]}$  que, pelas tabelas, é um valor entre os valores tabelados 2.37 e 2.45.

**Conclusões:** No enunciado está omissa o valor calculado da estatística  $F$ , mas esse valor é calculável a partir da expressão acima, uma vez que é conhecido  $R^2$ , sendo  $F_{calc} = 484.2312$ . A rejeição de  $H_0$  é muito clara, pelo que o modelo ajustado é muito significativamente diferente do Modelo Nulo, como seria de esperar dado o valor muito elevado de  $R^2$ .

2. O valor  $b_1 = 0.014061$  corresponde ao aumento esperado na variável resposta, associado a cada unidade adicional na variável  $x_1$ , mantendo as restantes variáveis fixas. Assim, para iguais valores dos restantes preditores, cada cm a mais no diâmetro das árvores corresponde, em média, a um aumento na produção de 0.014061 kg/árvore. A expressão geral do intervalo a  $(1-\alpha) \times 100\%$  de confiança para o verdadeiro valor populacional de  $\beta_1$  é dado por:

$$\left] b_1 - t_{\frac{\alpha}{2}; n-(p+1)} \cdot \hat{\sigma}_{\hat{\beta}_1}, b_1 + t_{\frac{\alpha}{2}; n-(p+1)} \cdot \hat{\sigma}_{\hat{\beta}_1} \right[ .$$

O enunciado disponibiliza a estimativa  $b_1 = 0.014061$  e o erro padrão  $\hat{\sigma}_{\hat{\beta}_1} = 0.005772$ . Tem-se ainda, para um IC a 95% de confiança,  $t_{0.025(144)} \approx 1.98$ . Logo, o intervalo a 95% de confiança para  $\beta_1$  é  $] 0.00263, 0.02549 [$ . O IC não contém o valor zero, pelo que o preditor **diâmetro** tem uma contribuição significativa para o modelo (apesar de  $b_1$  ser pequeno em valor absoluto).

3. É pedido um teste  $F$  parcial, para comparar o modelo de  $p=4$  preditores inicial e o submodelo de  $k=2$  preditores desta alínea. Tem-se:

**Hipóteses:**  $H_0 : \mathcal{R}_c^2 = \mathcal{R}_s^2$  vs.  $H_1 : \mathcal{R}_c^2 > \mathcal{R}_s^2$ , onde  $\mathcal{R}_c^2$  e  $\mathcal{R}_s^2$  indicam os coeficientes de determinação populacional, respectivamente, do modelo completo e do submodelo.

**Estatística do Teste:**  $F = \frac{n-(p+1)}{p-k} \frac{R_c^2 - R_s^2}{1-R_c^2} \cap F_{(p-k, n-(p+1))}$ , sob  $H_0$ .

**Nível de significância:**  $\alpha = P[\text{Erro do tipo I}] = P[\text{Rej. } H_0 \mid H_0 \text{ verdade}] = 0.05$ .

**Região Crítica:** (Unilateral direita) Rejeitar  $H_0$  se  $F_{calc} > f_{0.05[2,144]} \approx 3.05$ .

**Conclusões:** Tem-se  $F_{calc} = \frac{144}{2} \times \frac{0.9308 - 0.8954}{1 - 0.9308} = 36.83237$ . Logo, rejeita-se  $H_0$ , isto é, considera-se que a qualidade de ajustamento do modelo completo difere significativamente (ao nível  $\alpha = 0.05$ ) da do submodelo. Deste modo, o modelo completo é preferível ao submodelo, apesar da proximidade dos respectivos Coeficientes de Determinação.

4. É pedido para considerar um algoritmo de exclusão sequencial, baseado em testes  $t$  ao nível  $\alpha = 0.05$ , sobre o modelo completo original. Os testes dizem respeito às Hipóteses Nulas da forma  $H_0 : \beta_j = 0$  e alternativas da forma  $H_1 : \beta_j \neq 0$ , e as variáveis  $x_j$  candidatas a exclusão são aquelas em que *não* se rejeita  $H_0$  (para o  $\beta_j$  correspondente).

- (a) Os valores das estatísticas de teste são dadas no enunciado, na coluna de nome 't value' e, com uma exceção, os respectivos valores de prova ( $p$ -values) surgem ao lado, na coluna final. Existe pelo menos uma variável candidata à exclusão, já que no teste associado ao preditor **nfrJun**, o  $p$ -value é  $p = 0.0860 > 0.05$ , não se rejeitando a Hipótese Nula  $\beta_3 = 0$ . Embora esteja omissa a  $p$ -value para o teste associado ao último preditor, é evidente pelo valor enorme da estatística  $t$  ( $t_{calc} = 7.713$ ) que o respectivo valor de prova será muito pequeno, concretamente, ainda mais pequeno do que os  $p$ -values associados aos dois primeiros preditores. Assim, o último preditor não é dispensável (a rejeição da respectiva Hipótese Nula é a mais enfática de todas). Há, pois, uma única variável preditora candidata a sair, **nfrJun**, sendo o submodelo resultante deste primeiro passo o que inclui os três restantes preditores. Este resultado pode, à primeira vista, parecer surpreendente, dado que o coeficiente de correlação entre **nfrJun** e **producao** é muito elevado ( $r = 0.9444425$ ), pelo que **nfrJun** é um bom preditor de **producao**. A sua exclusão logo no primeiro passo do algoritmo resulta do facto de que se trata dum preditor altamente correlacionado com outro preditor, **nfrSet**, ainda mais fortemente correlacionado com **producao**. Assim, desde que este último preditor permaneça no modelo, a contribuição *adicional* do preditor **nfrJun** para a previsão da produção é marginal, e esse preditor é descartável. Dito de outra forma: o conhecimento do número de frutos em Junho é uma boa maneira de prever a produção final. Mas o número de frutos em Setembro (mais perto da data da colheita) é um ainda melhor preditor, que dispensa o conhecimento do número de frutos na data anterior.
- (b) Para determinar o valor de  $R_S^2$  é crucial saber que o valor da estatística dum teste  $F$  parcial, quando se compara um modelo completo e um submodelo *com apenas menos um preditor* é o quadrado do valor da estatística do teste  $t$  a  $H_0 : \beta_j = 0$ , associado a esse preditor. Assim, o valor da estatística do teste  $F$  parcial para comparar o submodelo com os preditores **diametro**, **altura** e **nfrSet**, e o modelo completo que inclui também o preditor **nfrJun**, é  $F_{calc}^2 = (-1.729)^2 = 2.989441$ . Mas esse valor tem de ser igual à expressão geral da estatística do teste, dada na resolução da alínea 3). Assim, tem-se:

$$\begin{aligned}
 2.989441 &= F_{calc} = \frac{n - (p + 1)}{p - k} \frac{R_c^2 - R_s^2}{1 - R_c^2} = \frac{144}{1} \times \frac{0.9308 - R_S^2}{1 - 0.9308} \\
 \Leftrightarrow 0.9308 - R_S^2 &= \frac{2.989441}{144} \times 0.0692 = 0.001436592 \\
 \Leftrightarrow R_S^2 &= 0.9308 - 0.001436592 = 0.9293634 .
 \end{aligned}$$

Assim, o submodelo tem um Coeficiente de Determinação muito ligeiramente inferior ao do modelo completo.

5. Sabemos que, numa Regressão Linear, o AIC (cuja expressão é dada no formulário), é constituído por duas parcelas, a primeira das quais mede a qualidade do ajustamento do modelo (através do valor de  $SQRE$ ) e a segunda mede a complexidade do modelo (através do número de parâmetros do modelo,  $k + 1$ ). Em ambos os casos, menores valores da parcela indicam um melhor modelo: mais bem ajustado, isto é com menor Soma de Quadrados Residual, na primeira parcela; e mais parcimonioso, no caso da segunda parcela. Os AICs de modelos diferentes são comparáveis, mesmo que não se trate (como é o caso) de modelos encaixados, ou seja, de um

modelo e submodelo. Apenas é necessário que a variável resposta seja igual e os dados com que se ajustaram os modelos sejam os mesmos (como é o caso). Ora, na regressão linear simples há um modelo mais parcimonioso (um único preditor) e que tem uma melhor qualidade de ajustamento, já que tem um  $R^2$  superior:  $R^2 = (0.9853879)^2 = 0.9709893$ . Assim, mesmo sem calcular o valor dos dois AICs, é possível assegurar que ambas as parcelas do modelo de regressão linear simples são mais pequenas, pelo que o respectivo AIC é também menor. Assim, o modelo de regressão linear simples de **producao** sobre **nfrColh** é preferível ao modelo de quatro preditores, ao abrigo do critério AIC.

**Nota:** Contraste-se a situação desta alínea com o que acontece com a tradicional utilização do AIC para comparar um modelo com um seu submodelo: nesse caso, o submodelo é sempre mais parcimonioso, mas tem necessariamente um ajustamento igual ou pior (um  $SQRE$  igual ou mais elevado). Não é possível saber à partida se o valor do AIC do submodelo é, ou não, menor que o do modelo completo: isso dependerá da relação entre a perda na primeira parcela do AIC e o ganho na segunda parcela. Apenas efectuando as contas será possível sabê-lo.

## II

É evidente que se está num contexto ANOVA, com a variável resposta dada pelo *rendimento*. Trata-se duma questão muito semelhante à do Exercício ANOVA 13 das aulas práticas.

1. Existem dois factores para explicar o rendimento: o *local* (com dois níveis, Régua e Tabuaço), e o *ano*. O mero facto de os anos em cada local serem diferentes permite concluir que *não* estamos perante um delineamento factorial (em cujo caso todos os anos teriam de surgir combinados com ambos os locais). Estamos perante um delineamento hierarquizado, em que o factor *ano* está subordinado ao factor *local*, tendo a experiência sido feita na Régua em  $b_1 = 5$  anos diferentes e no Tabuaço em  $b_2 = 2$  diferentes anos. Em cada uma das  $b_1 + b_2 = 7$  situações experimentais há o mesmo número de observações:  $n_c = 8$ . Assim, estamos perante um delineamento equilibrado, e um total de  $7 \times 8 = 56$  observações. Cada uma dessas observações é identificada por uma tripla indexação:  $Y_{ijk}$  onde  $i$  indica o nível do factor dominante (*local*, logo  $i = 1, 2$ );  $j$  indica o *ano* (podendo, na Régua, ter-se  $j = 1, 2, 3, 4, 5$ , e no Tabuaço  $j = 1, 2$ ). O modelo ANOVA para este delineamento hierarquizado é o seguinte:

- A equação do modelo é  $Y_{ijk} = \mu_{11} + \alpha_i + \beta_{j(i)} + \epsilon_{ijk}$ , sendo  $\mu_{11}$  o rendimento esperado na primeira localidade (Régua) no primeiro ano aí observado (1999);  $\alpha_i$  o efeito principal (aumento esperado no rendimento) associado à localidade  $i$  (com a restrição  $\alpha_1 = 0$ , pelo que apenas existe o parâmetro  $\alpha_2$ , do efeito principal associado a Tabuaço);  $\beta_{j(i)}$  o efeito (acréscimo no rendimento médio) associado ao ano  $j$  da localidade  $i$  (com a restrição  $\beta_{1(i)} = 0$ , para qualquer localidade  $i = 1, 2$ ); e sendo  $\epsilon_{ijk}$  o erro aleatório associado à observação  $Y_{ijk}$ .
- Admite-se que os erros aleatórios são Normais, de média zero e variâncias homogéneas:  $\epsilon_{ijk} \sim \mathcal{N}(0, \sigma^2)$ , para qualquer  $i, j, k$ .
- Admite-se que os erros aleatórios  $\epsilon_{ijk}$  são variáveis aleatórias independentes.

Com base neste modelo, tem-se que o rendimento esperado no Tabuaço ( $i = 2$ ) em 1999 ( $j = 1$  também no Tabuaço) é dado (tendo em conta as propriedades dos valores esperados) por:

$$\mu_{21} = E[Y_{21k}] = E[\underbrace{\mu_{11} + \alpha_2}_{=0} + \underbrace{\beta_{1(2)}}_{=0} + \epsilon_{21k}] = \mu_{11} + \alpha_2 + \underbrace{E[\epsilon_{21k}]}_{=0} = \mu_{11} + \alpha_2 .$$

Já para o Tabuaço ( $i=2$ ) em 2003 ( $j=2$ ), tem-se:

$$\mu_{22} = E[Y_{22k}] = E[\mu_{11} + \alpha_2 + \beta_{2(2)} + \epsilon_{22k}] = \mu_{11} + \alpha_2 + \beta_{2(2)} + \underbrace{E[\epsilon_{22k}]}_{=0} = \mu_{11} + \alpha_2 + \beta_{2(2)} .$$

Assim, o parâmetro  $\beta_{2(2)}$  corresponde à diferença no rendimento médio populacional no Tabuaço, nos dois anos em que o estudo abrangeu essa localidade.

2. O quadro de síntese desta ANOVA tem uma linha associada a cada tipo de efeito previsto no modelo (Factor dominante A, *local*; e Factor subordinado B, *ano*), e ainda uma linha correspondente à variabilidade Residual. Para obter as quantidades correspondentes à tabela, podem usar-se os valores disponíveis no enunciado, as fórmulas disponíveis no formulário, bem como a conhecida relação de que as três Somas de Quadrados totalizam  $SQT$ . Assim, tem-se:

- $g.l.(SQA) = a - 1 = 1$ ;
- $g.l.(SQB(A)) = (b_1 - 1) + (b_2 - 1) = 4 + 1 = 5$ ;
- $g.l.(SQRE) = n - (b_1 + b_2) = 56 - 7 = 49$ ;
- $SQA = 0.6402$  (enunciado);
- $SQRE = 8.311$  (enunciado);
- $SQB(A) = SQT - (SQA + SQRE) = (n-1)s_y^2 - (0.6402 + 8.311) = 55 \times 0.329922 - 8.9512 = 9.19451$ .

Como de costume, os Quadrados Médios obtêm-se dividindo cada Soma de Quadrados pelos respectivos graus de liberdade, e o valor das duas estatística  $F$  obtém-se dividindo o Quadrado Médio de cada tipo de efeito pelo Quadrado Médio Residual. Assim, a tabela completa é a seguinte:

Variação	g.l.	Soma de Quadrados	Quadrado Médio	$F_{calc}$
Local	$a - 1 = 1$	$SQA = 0.6402$	$QMA = 0.6402$	$F_A = 3.7745$
Anos	$(b_1 - 1) + (b_2 - 1) = 5$	$SQB(A) = 9.19451$	$QMB(A) = 1.838902$	$F_{B(A)} = 10.8418$
Residual	$n - (b_1 + b_2) = 49$	$SQRE = 8.311$	$QMRE = 0.1696122$	-

3. É pedido para indicar se os efeitos de ano ( $\beta_{j(i)}$ ) são significativos. O teste  $F$  a esses efeitos permite responder à pergunta:

**Hipóteses:**  $H_0 : \beta_{j(i)} = 0, \forall i, j$  vs.  $H_1 : \exists i, j$  tal que  $\beta_{j(i)} \neq 0$ .

**Estatística do Teste:**  $F_{B(A)} = \frac{QMB(A)}{QMRE} \cap F_{[\sum_{i=1}^a (b_i - 1), n - \sum_{i=1}^a b_i]}$ , sob  $H_0$ .

**Nível de significância:**  $\alpha = 0.05$ .

**Região Crítica:** (Unilateral direita) Rejeitar  $H_0$  se  $F_{calc} > f_{0.05(5,49)} \approx 2.40$ .

**Conclusões:** Como  $F_{calc} = 10.8418 > 2.40$ , rejeita-se  $H_0$ , concluindo-se pela existência de efeitos significativos de ano (ao nível  $\alpha = 0.05$ ). Assim, a variabilidade de ano para ano é importante, e caso tivesse sido ignorada (tratando anos diferentes como meras repetições, ou apenas realizando a experiência num único ano), estar-se-ia a ignorar uma importante fonte de variabilidade dos rendimentos, o que poderia mascarar a existência de efeitos de localidade, mesmo quando estes estejam presentes.

4. É pedido para efectuar um teste  $F$  aos efeitos principais do factor dominante *local*. Como já se viu, existem apenas  $a = 2$  níveis, pelo que após a restrição  $\alpha_1 = 0$ , apenas existe um parâmetro desse tipo de efeitos:  $\alpha_2$ . Eis o teste pedido:

**Hipóteses:**  $H_0 : \alpha_2 = 0$  vs.  $H_1 : \alpha_2 \neq 0$ .

**Estatística do Teste:**  $F_A = \frac{QMA}{QMRE} \cap F_{[a-1, n-\sum_{i=1}^a b_i]}$ , sob  $H_0$ .

**Nível de significância:**  $\alpha = 0.05$ .

**Região Crítica:** (Unilateral direita) Rejeitar  $H_0$  se  $F_{calc} > f_{0.05(1,49)} \approx 4.04$ .

**Conclusões:** Como  $F_{calc} = 3.7745 < 4.04$ , não se rejeita  $H_0$ , pelo que não se pode concluir pela existência de efeitos significativos de local (ao nível  $\alpha=0.05$  ou inferior). Por outras palavras, a mera transição de um local para outro não permite afirmar que o rendimento populacional difere. Um olhar para as médias em cada uma das 7 situações experimentais permite compreender o porquê desta conclusão: havendo uma enorme variabilidade nos rendimentos entre anos diferentes na Régua, o rendimento médio verificado nos cinco anos na Régua foi 0.992 kg/planta, não havendo sustentação para a conclusão de que seja significativamente diferente do rendimento médio observado no Tabuaço: 0.7553.

**Nota:** Uma vez que as Hipóteses neste teste envolvem um único parâmetro ( $\alpha_2$ ), e uma vez que os modelos ANOVA são Modelos Lineares, seria possível igualmente efectuar um teste  $t$  às mesmas hipóteses. Os resultados desse teste alternativo seriam equivalentes.

5. Nesta alínea é pedido para utilizar a teoria de Tukey para comparar a média populacional da situação experimental Régua ( $i=1$ ) em 1999 ( $j=1$ ), ou seja,  $\mu_{11}$ , com as restantes. Nessa situação experimental tem-se a menor média amostral:  $\bar{y}_{11} = 0.291$ . Ao nível global de significância  $\alpha=0.05$ , o termo de comparação de Tukey é dado por:

$$q_{\alpha(b_1+b_2, n-(b_1+b_2))} \sqrt{\frac{QMRE}{n_c}} = q_{0.05(7,49)} \sqrt{\frac{0.1696122}{8}} \approx 4.34 \times 0.1456074 = 0.6319363 .$$

Sempre que  $|\bar{y}_{ij} - \bar{y}_{11}| > 0.6319363$ , deve concluir-se que  $\mu_{ij} \neq \mu_{11}$  (com nível global de significância 0.05). Assim, qualquer rendimento médio amostral superior a  $0.291 + 0.6319363 = 0.9229$  corresponde a uma média populacional que é significativamente diferente de  $\mu_{11}$ . Tal situação apenas ocorre com dois outros anos na Régua: 2002 (para o qual a média amostral é  $\bar{y}_{13} = 1.327$ ) e 2003 (para o qual a média amostral é  $\bar{y}_{14} = 1.682$ ). Assim, não é possível afirmar que o menor dos rendimentos amostrais médios seja significativamente diferente de *todos* os outros rendimentos amostrais médios nas situações experimentais consideradas.

6. Pede-se para ajustar, aos mesmos dados, um modelo ANOVA a um único factor, o factor *local*. Sabemos que, nesse caso, a Soma de Quadrados, graus de liberdade e Quadrado Médio correspondente ao único factor previsto no modelo permanecem iguais, pelo que a primeira linha desta nova tabela será (com excepção do valor da estatística  $F$ ) igual. A nova tabela apenas conterà mais uma linha, correspondente à variabilidade residual (não explicada pelo modelo a um único factor). Uma vez que a soma de todas as Somas de Quadrados, em qualquer modelo ANOVA, tem de ser  $SQT = (n-1) s_y^2$  (quantidade que não depende do modelo ajustado), é já possível concluir que a nova Soma de Quadrados Residual será  $SQRE = (55 \times 0.329922) - 0.6402 = 17.50551$  (alternativamente, seria possível ter somado as antigas Somas de Quadrados Residual e de efeitos do Factor subordinado B, no modelo hierarquizado:  $9.19451 + 8.311 = 17.50551$ ). Os novos graus de liberdade residuais serão (de acordo com a expressão genérica para os modelos ANOVA a um factor)  $n-a = 56 - 2 = 54$  (que também poderiam ser calculados como a soma dos graus de liberdade associados às mesmas duas parcelas do modelo hierarquizado atrás consideradas:  $5 + 49 = 54$ ). Daqui resulta que, no modelo a um factor, o Quadrado Médio Residual será a razão  $QMRE = \frac{SQRE}{n-a} = \frac{17.50551}{54} = 0.3241761$ . Este valor é aproximadamente o dobro do antigo  $QMRE$ , pelo que a nova estatística do teste  $F$  aos efeitos de local será sensivelmente metade

do que era no modelo hierarquizado:  $F_A = \frac{QMA}{QMRE} = \frac{0.6402}{0.3241761} = 1.974853$ . A tabela ANOVA do modelo a um único factor será portanto a seguinte:

Variação	g.l.	Soma de Quadrados	Quadrado Médio	$F_{calc}$
Local	$a-1=1$	$SQA=0.6402$	$QMA=0.6402$	$F_A=1.974853$
Residual	$n-a=54$	$SQRE=17.50551$	$QMRE=0.3241761$	–

O único teste  $F$  que ainda faz sentido executar é o teste  $F$  aos efeitos do factor *local*, com a Hipótese Nula  $H_0 : \alpha_2=0$ . O valor fronteira da Região Crítica é agora  $F_{0.05(1,54)} \approx 4.02$ , pelo que não se rejeita  $H_0$ . Embora a conclusão seja qualitativamente a mesma que no modelo hierarquizado, está-se muito mais distante de rejeitar  $H_0$  no modelo a um factor, em que a variabilidade entre anos (que é considerável) não é explicada e passa a ser considerada variabilidade residual.

### III

- (a) Seja  $\vec{Y}$  o vector aleatório com as  $n$  observações da variável resposta, e  $\vec{\epsilon}$  o vector aleatório dos correspondentes erros aleatórios. Seja  $\mathbf{X}_{n \times (p+1)}$  a matriz (não aleatória) do modelo, cuja primeira coluna é constituída por  $n$  uns, e cujas colunas seguintes contêm as  $n$  observações de cada uma das  $p$  variáveis predictoras. Seja  $\vec{\beta}$  o vector (não aleatório) constituído pelos  $p+1$  parâmetros do modelo:  $\vec{\beta} = (\beta_0, \beta_1, \dots, \beta_p)^t$ . O Modelo de Regressão Linear Múltipla admite os seguintes pressupostos:

- Equação do Modelo:  $\vec{Y} = \mathbf{X}\vec{\beta} + \vec{\epsilon}$ ;
- Pressupostos sobre os erros aleatórios:  $\vec{\epsilon} \sim \mathcal{N}_n(\vec{0}, \sigma^2 \mathbf{I}_n)$ .

A equação do Modelo corresponde à relação linear de fundo entre os preditores e a variável resposta. Os erros aleatórios representam a variabilidade em torno dessa relação linear, admitindo-se a Multinormalidade, independência e variâncias homogêneas no segundo pressuposto do Modelo.

- (b) O vector dos estimadores é dado pela fórmula que consta do formulário:  $\vec{\hat{\beta}} = (\mathbf{X}^t \mathbf{X})^{-1} \mathbf{X}^t \vec{Y}$ . Usando a equação do Modelo, tem-se:

$$\vec{\hat{\beta}} = (\mathbf{X}^t \mathbf{X})^{-1} \mathbf{X}^t \vec{Y} = (\mathbf{X}^t \mathbf{X})^{-1} \mathbf{X}^t (\mathbf{X}\vec{\beta} + \vec{\epsilon}) = \underbrace{(\mathbf{X}^t \mathbf{X})^{-1} \mathbf{X}^t \mathbf{X}}_{\mathbf{I}_{p+1}} \vec{\beta} + (\mathbf{X}^t \mathbf{X})^{-1} \mathbf{X}^t \vec{\epsilon} = \vec{\beta} + (\mathbf{X}^t \mathbf{X})^{-1} \mathbf{X}^t \vec{\epsilon}.$$

Pelas propriedades da distribuição Multinormal sabe-se que a Multinormalidade dum vector aleatório (como é  $\vec{\epsilon}$ ) não é destruída, nem pela pré-multiplicação por uma matriz não aleatória (como  $(\mathbf{X}^t \mathbf{X})^{-1} \mathbf{X}^t$ ), nem pela soma dum vector não aleatório (como  $\vec{\beta}$ ). Logo, o vector aleatório  $\vec{\hat{\beta}}$  tem distribuição Multinormal. Falta apenas identificar os seus dois parâmetros, que sabemos ser o vector esperado e a matriz de (co-)variâncias respectivos.

Usando as propriedades operatórias dos vectores esperados e das matrizes de (co-)variâncias, bem como as propriedades de matrizes (estudadas nas aulas), tem-se:

$$E[\vec{\hat{\beta}}] = E[\vec{\beta} + (\mathbf{X}^t \mathbf{X})^{-1} \mathbf{X}^t \vec{\epsilon}] = \vec{\beta} + (\mathbf{X}^t \mathbf{X})^{-1} \mathbf{X}^t \underbrace{E[\vec{\epsilon}]}_{=\vec{0}} = \vec{\beta}.$$

e

$$\begin{aligned} V[\vec{\hat{\beta}}] &= V[\vec{\beta} + (\mathbf{X}^t \mathbf{X})^{-1} \mathbf{X}^t \vec{\epsilon}] = V[(\mathbf{X}^t \mathbf{X})^{-1} \mathbf{X}^t \vec{\epsilon}] = (\mathbf{X}^t \mathbf{X})^{-1} \mathbf{X}^t V[\vec{\epsilon}] [(\mathbf{X}^t \mathbf{X})^{-1} \mathbf{X}^t]^t \\ &= (\mathbf{X}^t \mathbf{X})^{-1} \mathbf{X}^t \sigma^2 \mathbf{I}_n [\mathbf{X}^t]^t [(\mathbf{X}^t \mathbf{X})^{-1}]^t = \sigma^2 (\mathbf{X}^t \mathbf{X})^{-1} \mathbf{X}^t \mathbf{X} [(\mathbf{X}^t \mathbf{X})^{-1}]^t \\ &= \sigma^2 \underbrace{(\mathbf{X}^t \mathbf{X})^{-1} \mathbf{X}^t \mathbf{X}}_{\mathbf{I}_{p+1}} [(\mathbf{X}^t \mathbf{X})^{-1}]^t = \sigma^2 (\mathbf{X}^t \mathbf{X})^{-1}. \end{aligned}$$

Logo, tem-se a distribuição indicada no enunciado.

- (c) i. A partir da expressão para  $R_{mod}^2$  dada no formulário, e das definições de  $QMRE$ ,  $QMT$  e  $R^2$ , tem-se:

$$\begin{aligned} R_{mod}^2 &= 1 - \frac{QMRE}{QMT} = 1 - \frac{SQRE/[n - (p + 1)]}{SQT/(n - 1)} = 1 - \frac{n - 1}{n - (p + 1)} \frac{SQRE}{SQT} \\ &= 1 - \frac{n - 1}{n - (p + 1)} \frac{SQT - SQR}{SQT} = 1 - \frac{n - 1}{n - (p + 1)} (1 - R^2). \end{aligned}$$

- ii. A expressão para  $R_{mod}^2$  do ponto anterior significa que  $R_{mod}^2$  é uma função crescente em  $R^2$ , ou seja, a maiores valores de  $R^2$ , maiores valores de  $R_{mod}^2$ . Logo, basta substituir na expressão anterior o maior (1) e menor (0) valores possíveis de  $R^2$  para se ter a gama de possíveis valores de  $R_{mod}^2$ . É imediato que, quando  $R^2 = 1$ , também  $R_{mod}^2 = 1$ . Quando  $R^2 = 0$ , tem-se:

$$R_{mod}^2 = 1 - \frac{n - 1}{n - (p + 1)} = \frac{[n - (p + 1)] - (n - 1)}{n - (p + 1)} = \frac{-p}{n - (p + 1)},$$

como se pedia para provar.

- iii. Trata-se apenas de interpretar o significado de  $R_{mod}^2 = 1 - \frac{QMRE}{QMT}$  quando este indicador toma valores negativos. Nesse caso, tem-se  $QMRE > QMT$ . Ora, em qualquer Modelo Linear  $QMRE$  é o estimador de  $\sigma^2$ , ou seja, da variância da variável resposta  $Y$  em torno da hipersuperfície de regressão (que é o significado de  $\sigma^2$ ). Por outro lado,  $QMT = \frac{SQT}{n - 1} = \frac{(n - 1)s_y^2}{n - 1} = s_y^2$ , que é a variância amostral das observações de  $Y$ , ou seja, é o estimador da variância de  $Y$ , na ausência da relação linear com os preditores.

2. A equação do modelo  $M_{A+B}$  é  $Y_{ijk} = \mu_{11} + \alpha_i + \beta_j + \epsilon_{ijk}$ . A equação do modelo  $M_{A*B}$  tem ainda os parâmetros de interação:  $Y_{ijk} = \mu_{11} + \alpha_i + \beta_j + (\alpha\beta)_{ij} + \epsilon_{ijk}$ .

- (a) Não se deve confundir os *tipos* de parâmetros de cada modelo ( $\mu$ , os efeitos do Factor A, do Factor B e, eventualmente, de interação) com o *número* desses parâmetros. É o *número* de parâmetros do modelo que define os graus de liberdade associados à Soma de Quadrados Residual, que são dados pelo número de observações,  $n$ , menos esse número total de parâmetros do modelo. Em ambos os modelos considerados existe um único parâmetro  $\mu_{11}$ . Em relação aos parâmetros  $\alpha_i$ , associados aos  $a$  níveis do factor A, haveria à partida  $a$  parâmetros, mas após a introdução da restrição  $\alpha_1 = 0$  (comum a ambos os modelos) apenas sobram  $a - 1$  parâmetros desse tipo. De forma análoga, haveria (em ambos os modelos), à partida,  $b$  parâmetros  $\beta_j$ , um para cada nível do factor B, mas com a restrição  $\beta_1 = 0$  (comum a ambos os modelos) sobram  $b - 1$ . No modelo  $M_{A+B}$  não há mais parâmetros, tendo-se nesse modelo um total de  $1 + (a - 1) + (b - 1) = a + b - 1$  parâmetros. No modelo  $M_{A*B}$  existem ainda os parâmetros  $(\alpha\beta)_{ij}$ , associados aos efeitos de interação. As restrições  $(\alpha\beta)_{ij} = 0$  caso  $i = 1$  e/ou  $j = 1$  significam que haverá ao todo  $(a - 1)(b - 1)$  parâmetros desse tipo. Logo, no modelo  $M_{A*B}$  o número total de parâmetros é dado por  $a + (b - 1) + (a - 1)(b - 1) = a + [\cancel{1} + (a - \cancel{1})](b - 1) = a + a(b - 1) = a[\cancel{1} + (b - \cancel{1})] = ab$  parâmetros.
- (b) A forma mais simples de verificar que não é possível estudar o modelo com efeitos de interação caso não existam repetições nas  $ab$  células será o de constatar que com apenas  $n_c = 1$  observação em cada uma dessas situações experimentais, o número total de observações ( $n$ ) será igual ao número total de parâmetros do modelo ( $ab$ ). Logo, haverá  $n - ab = 0$  graus de liberdade associados à Soma de Quadrados Residual, pelo que nem será possível definir um Quadrado Médio Residual. Esta impossibilidade exprime o facto de não existir informação suficiente para ajustar o modelo com efeitos de interação. Nesta situação de ausência de

repetições nas situações experimentais dum delineamento factorial, a única possibilidade de estudar os dados passa por ajustar o modelo sem efeitos de interacção, ou seja, o modelo  $M_{A+B}$ .

- (c) A matriz do modelo  $M_{A+B}$ , ou seja, a matriz  $\mathbf{X}_{A+B}$ , é constituída por uma coluna de uns e por colunas indicatrizes de pertença a cada nível do factor A, excepto o primeiro, bem como colunas indicatrizes de pertença a cada nível do factor B, excepto o primeiro. A matriz do modelo  $M_{A*B}$ ,  $\mathbf{X}_{A*B}$ , tem essas mesmas colunas e ainda as colunas indicatrizes de pertença a cada célula resultante do cruzamento de cada nível (excepto  $i=1$ ) do factor A com cada nível (excepto  $j=1$ ) do factor B.

Por definição, o espaço das colunas duma matriz é o conjunto de todas as possíveis combinações lineares das colunas dessa matriz. Ora todas as colunas da matriz  $\mathbf{X}_{A+B}$  são também colunas da matriz  $\mathbf{X}_{A*B}$ , pelo que o espaço das colunas  $\mathcal{C}(\mathbf{X}_{A+B})$  tem de estar contido no espaço das colunas  $\mathcal{C}(\mathbf{X}_{A*B})$ . No entanto, algumas combinações lineares das colunas de  $\mathbf{X}_{A*B}$  (nomeadamente as que envolvam as indicatrizes de células) não podem ser criadas por combinações lineares das colunas de  $\mathbf{X}_{A+B}$ , pelo que o espaço das colunas de  $\mathbf{X}_{A*B}$  é maior que o espaço das colunas de  $\mathbf{X}_{A+B}$ .

Como se viu nas aulas teóricas, a Soma de Quadrados Residual é a distância ao quadrado entre o vector das observações da variável resposta,  $\vec{y}$ , e a sua projecção ortogonal sobre o espaço das colunas da matriz do modelo. Esse vector projectado é o vector do subespaço que está mais próximo de  $\vec{y}$ . Assim, a projecção ortogonal de  $\vec{y}$  sobre  $\mathcal{C}(\mathbf{X}_{A+B}) \subseteq \mathcal{C}(\mathbf{X}_{A*B})$  é o vector de  $\mathcal{C}(\mathbf{X}_{A+B})$  que está mais próximo de  $\vec{y}$ . Trata-se de um vector que também pertence a  $\mathcal{C}(\mathbf{X}_{A*B})$ . Logo, a menor distância entre o vector  $\vec{y}$  e um vector de  $\mathcal{C}(\mathbf{X}_{A*B})$  nunca poderá ser maior que  $SQRE_{A+B}$ . Poderá ser igual, no caso de as duas projecções coincidirem (o que apenas acontecerá em situações excepcionais), ou poderá ser menor quando (como acontece em geral), a projecção de  $\vec{y}$  sobre  $\mathcal{C}(\mathbf{X}_{A*B})$  produzir um vector diferente do obtido na primeira projecção.