

I

É dada uma tabela de contingências, sendo os factores de classificação as proveniências ( $a=3$  níveis) e os terrenos ( $b=3$  níveis).

1. Não tendo sido fixados os totais marginais de quaisquer das dimensões (linhas ou colunas) da tabela, as probabilidades marginais podem ser estimadas a partir das frequências relativas marginais de linha e coluna. Assim, a probabilidade de proveniência Trás-os-Montes é estimada por  $\hat{\pi}_{3.} = \frac{N_{3.}}{N}$ , sendo  $N=1262$  o número total de frutos observados e  $N_{3.}=67+140+245=452$  o número de frutos observados provenientes de Trás-os-Montes. Logo,  $\hat{\pi}_{3.} = 0.3581616$ . De forma análoga, a probabilidade estimada de um fruto observado ser do Terreno 1 é dada por  $\hat{\pi}_{.1} = \frac{N_{.1}}{N} = \frac{85+76+67}{1262} = \frac{228}{1262} = 0.1806656$ .
2. Não tendo sido fixados os totais marginais de quaisquer das dimensões da tabela, iremos realizar um teste de independência entre estes factores de classificação. Designando por  $\pi_{ij}$  a probabilidade conjunta dum fruto ser da proveniência  $i$  e ter sido observado no terreno  $j$ , e as respectivas probabilidades marginais por  $\pi_{i.}$  e  $\pi_{.j}$ , tem-se:

**Hipóteses:**  $H_0 : \pi_{ij} = \pi_{i.} \times \pi_{.j} \quad \forall i, j$  vs.  $H_1 : \exists i, j$  tal que  $\pi_{ij} \neq \pi_{i.} \times \pi_{.j}$ .

**Estatística do Teste:** A estatística de Pearson, é dada por  $X^2 = \sum_{i=1}^3 \sum_{j=1}^3 \frac{(O_{ij} - \hat{E}_{ij})^2}{\hat{E}_{ij}}$ , sendo  $O_{ij}$

o número de observações correspondentes à célula  $(i, j)$  e  $\hat{E}_{ij}$  o valor esperado estimado correspondente ao abrigo da hipótese nula de independência, que é dado por  $\hat{E}_{ij} = \frac{N_{i.} \times N_{.j}}{N}$ . A distribuição assintótica desta estatística, caso seja verdade  $H_0$ , é  $\chi_{(a-1)(b-1)}^2$  com  $a, b=3$ . Logo, a distribuição assintótica será  $\chi_4^2$ .

**Nível de Significância** De acordo com o enunciado, escolhem-se dois valores de  $\alpha = P[\text{Erro do tipo I}] = P[\text{Rej. } H_0 | H_0 \text{ verdade}]$ :  $\alpha=0.05$  e  $\alpha=0.01$ .

**Região Crítica:** (Unilateral direita) Para um nível de significância  $\alpha=0.05$ , a regra de rejeição deve ser a de rejeitar  $H_0$  se  $X_{\text{calc}}^2 > \chi_{0.05(4)}^2 = 9.488$ . Para um nível de significância  $\alpha=0.01$ , a regra de rejeição corresponde a rejeitar  $H_0$  se  $X_{\text{calc}}^2 > \chi_{0.01(4)}^2 = 13.277$ .

**Conclusões** Como  $X_{\text{calc}}^2 = 10.305$ , rejeita-se  $H_0$  (a hipótese de independência) ao nível  $\alpha=0.05$ , mas não ao nível  $\alpha=0.01$ . Tal facto significa que o valor de prova ( $p$ -value) tem de estar entre estes dois valores, ou seja:  $0.01 < p < 0.05$ .

A validade deste teste depende da validade da distribuição assintótica da estatística do teste. O Critério de Cochran afirma que essa distribuição assintótica é admissível se nenhum valor esperado for inferior a 1, e não mais de 20% forem inferiores a 5. No nosso contexto, os valores esperados são estimados por  $\hat{E}_{ij} = \frac{N_{i.} \times N_{.j}}{N}$ . O menor destes valores esperados estimados corresponde à célula da linha e da coluna com menores totais marginais (ou seja, a  $(i, j)$  para a qual  $N_{i.}$  é a menor soma de linha e  $N_{.j}$  é a menor soma de coluna). Basta olhar para a tabela para verificar que a menor soma de coluna corresponde à coluna 1, que já vimos ser  $N_{.1} = 228$ .

Não é tão evidente qual a linha (proveniência) de menor soma, mas rapidamente se verifica que  $N_1 = 85 + 137 + 186 = 408$ , enquanto  $N_2 = 76 + 112 + 214 = 402$  (tendo sido visto em cima que  $N_3 = 452$ ). Logo, a célula com menor valor de  $\hat{E}_{ij}$  é a célula  $(i, j) = (2, 1)$ , para a qual  $\hat{E}_{2,1} = \frac{N_{2,1} \times N_{.1}}{N} = \frac{402 \times 228}{1262} = 72.62758 \gg 5$ . Assim, todas as células terão valores esperados estimados muito acima do que o necessário para passar o critério de Cochran.

3. A contribuição da célula (3, 1) para o valor da estatística calculada é dada por  $\frac{(O_{3,1} - \hat{E}_{3,1})^2}{\hat{E}_{3,1}}$ . Ora,  $O_{3,1} = 67$  e  $\hat{E}_{3,1} = \frac{N_{3,1} \times N_{.1}}{N} = \frac{452 \times 228}{1262} = 81.66086$ . Logo,  $\frac{(O_{3,1} - \hat{E}_{3,1})^2}{\hat{E}_{3,1}} = \frac{(67 - 81.66086)^2}{81.66086} = 2.632116$ .

## II

- Na tabela faltam: (i) o valor da estatística  $T$  no teste a  $H_0 : \beta_1 = 0$ , que é dado por  $T_{calc} = \frac{b_1}{\hat{\sigma}_{\hat{\beta}_1}} = \frac{0.053667}{0.001884} = 28.48567$ ; (ii) o valor dos graus de liberdade associados ao QMRE, e que são  $n - 2 = 238 - 2 = 236$ ; (iii) o valor dos segundos graus de liberdade na distribuição  $F$  do teste de ajustamento global, que é igualmente  $n - 2 = 236$ ; e (iv) o valor da estatística desse mesmo teste, que pode ser calculada como  $F_{calc} = (n - 2) \frac{R^2}{1 - R^2} = 236 \times \frac{0.7746}{1 - 0.7746} = 811.0275$ . Falta calcular um último valor omissso, o valor de  $s_x^2$ , onde  $x$  indica o número médio de lançamentos por videira. É possível obtê-lo utilizando a expressão do erro padrão (estimado) do estimador do declive da recta,  $\hat{\sigma}_{\hat{\beta}_1} = \sqrt{\frac{QMRE}{(n-1)s_x^2}}$ . O enunciado disponibiliza três valores nesta expressão:  $\hat{\sigma}_{\hat{\beta}_1} = 0.001884$ ,  $\sqrt{QMRE} = 0.1203$  e  $n = 238$ . Assim,  $s_x^2 = \frac{QMRE}{(n-1)\hat{\sigma}_{\hat{\beta}_1}^2} = \frac{0.1203^2}{237 \times (0.001884)^2} = 17.20367$ .
- Há dois aspectos a referir: (i) a discussão do valor do coeficiente de determinação,  $R^2 = 0.7746$ , que indica que cerca de 77.5% da variabilidade dos valores observados do peso da lenha à poda é explicada pela regressão (um valor bastante elevado); e (ii) o teste  $F$  de ajustamento global. Eis este teste:

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

**Estatística do Teste:**  $F = \frac{QMR}{QMRE} = (n - 2) \frac{R^2}{1 - R^2} \cap F_{(1, n-2)}$ , 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  $F_{calc} > f_{\alpha[1, 236]}$  que, pelas tabelas, é um valor entre os valores tabelados 3.84 e 3.92.

**Conclusões:** No enunciado está omissso o valor calculado da estatística  $F$ , mas esse valor foi calculado no primeiro ponto, sendo um valor elevadíssimo:  $F_{calc} = 811.0275$ . Assim, há uma clara rejeição de  $H_0$  e, em conjunto com o valor bastante elevado de  $R^2$ , parece adequado usar a recta de regressão para prever o peso da lenha de poda a partir do número médio de lançamentos na videira. **Nota:** Mesmo sem o valor de  $F_{calc}$ , seria possível tirar a conclusão do teste, uma vez que o seu valor de prova ( $p$ -value) está disponível no enunciado e é indistinguível de zero.

- A recta de regressão populacional tem equação  $y = \beta_0 + \beta_1 x$  e passa na origem se  $\beta_0 = 0$ . Assim, é pedido um intervalo de confiança para  $\beta_0$ . Sabemos que a respectiva expressão, ao nível de confiança  $(1 - \alpha) \times 100\%$ , é  $] b_0 - t_{\alpha/2(n-2)} \cdot \hat{\sigma}_{\hat{\beta}_0}, b_0 + t_{\alpha/2(n-2)} \cdot \hat{\sigma}_{\hat{\beta}_0} [$ . Das três quantidades necessárias para calcular este IC, duas estão no enunciado:  $b_0 = 0.001227$  e o erro padrão correspondente,  $\hat{\sigma}_{\hat{\beta}_0} = 0.013809$ . O valor da distribuição  $t$ -Student, usando um grau

de confiança de 95%, será  $t_{0.025(236)}$ . Na tabela apenas estão disponíveis os valores para 120 graus de liberdade (1.97993) e o valor indicado como associado a infinitos graus de liberdade (1.96234 e que corresponde ao valor da distribuição limite da  $t$ -Student, ou seja, da Normal reduzida). Usando o valor intermédio 1.97 no cálculo, o intervalo a 95% de confiança para  $\beta_0$  vem:  $] -0.02598, 0.02843 [$ . Estes são os valores admissíveis para  $\beta_0$ , que têm as mesmas unidades de medida que as da variável resposta  $Y$ , no nosso caso  $kg$ . Este intervalo contém o valor zero, pelo que  $\beta_0=0$  é um valor admissível. Assim, é admissível considerar que a recta de regressão populacional passa na origem. Repare-se que, nesse caso, a relação entre  $Y$  e  $X$  é uma relação de proporcionalidade simples:  $y = \beta_1 x$ .

4. Pede-se um intervalo de predição (a  $(1-\alpha) \times 100\%$ ) para um valor individual de  $Y$  (peso) quando o preditor toma o valor  $x$ , intervalo cuja expressão é dada no formulário:

$$\left[ (b_0 + b_1 x) - t_{\frac{\alpha}{2}; n-2} \cdot \sqrt{QMRE \cdot \left[ 1 + \frac{1}{n} + \frac{(x - \bar{x})^2}{(n-1) s_x^2} \right]}, (b_0 + b_1 x) + t_{\frac{\alpha}{2}; n-2} \cdot \sqrt{QMRE \cdot \left[ 1 + \frac{1}{n} + \frac{(x - \bar{x})^2}{(n-1) s_x^2} \right]} \right].$$

No enunciado são disponibilizados quase todos estes valores:  $b_0 = 0.001227$ ,  $b_1 = 0.053667$ ,  $\sqrt{QMRE} = 0.1203$ ,  $n = 238$ ,  $\bar{x} = 6.049$ ,  $s_x^2 = 17$  (em substituição do verdadeiro valor, que em todo o caso era muito próximo deste). Também já vimos nas alíneas anteriores que  $t_{0.025(236)} \approx 1.97$ . Usando estes valores, temos, com  $x = 10$ , o intervalo de predição (95%)  $] 0.300, 0.776 [$ . Assim, numa parcela de terreno com um número médio de 10 lançamentos por videira, o peso médio de lenha de poda estaria (95%) entre 0.300 e 0.776  $kg$ .

5. Neste ponto considera-se o modelo linear entre  $\log(\text{peso})$  e  $\log(\text{Nlançamentos})$ .

- (a) A afirmação não é válida, devido à transformação da variável resposta **peso**. O valor  $R^2 = 0.7746$  do modelo inicial é a proporção da variabilidade *dos pesos* observados explicada por essa regressão. O valor  $R^2 = 0.8049$  do modelo agora ajustado diz respeito à proporção da variância dos *log-pesos* explicada pela nova regressão. Não existe uma relação directa entre a variância dos pesos e a variância dos log-pesos que permita fazer a afirmação do enunciado.
- (b) A relação linear entre *os logaritmos* das duas variáveis observadas corresponde a admitir que a relação entre as variáveis originais  $x$  e  $y$  é de tipo potência. De facto, admitir a linearidade entre  $y^* = \ln(y)$  e  $x^* = \ln(x)$  corresponde a ter:

$$\begin{aligned} \ln(y) = b_0 + b_1 \ln(x) &\Leftrightarrow e^{\ln(y)} = e^{b_0 + b_1 \ln(x)} \\ &\Leftrightarrow y = \underbrace{e^{b_0}}_{=a} e^{b_1 \ln(x)} = a e^{\ln x^{b_1}} = a x^{b_1}. \end{aligned}$$

Assim, a curva potência ajustada à relação original entre **peso** ( $y$ ) e **Nlançamentos** ( $x$ ) é dada por  $y = e^{-2.96320} x^{1.00085} = 0.05165336 x^{1.00085}$ . Como sabemos das aulas teóricas, este tipo de relação potência corresponde a admitir que ambas as variáveis são funções duma terceira variável  $t$  (que, neste contexto se poderia supôr ser o comprimento das videiras, ou o tempo) e que as respectivas taxas de variação relativas são proporcionais, sendo a constante de proporcionalidade dada pelo declive da recta na relação linear entre as variáveis logaritmizadas ou, de forma equivalente, pela potência na relação entre as variáveis originais. Assim, a relação que se admite existir na população entre as taxas de variação relativas das variáveis  $y$  e  $x$  é  $\frac{y'(t)}{y(t)} = \beta_1 \frac{x'(t)}{x(t)}$ . A relação estimada (uma vez que  $b_1 = 1.00085$ ) é, aproximadamente, uma relação de igualdade entre as duas taxas de variação relativas.

- (c) Na pergunta 3 deste Grupo, já se viu que o modelo que admite a linearidade entre as variáveis originais **peso** ( $Y$ ) e **Nlançamentos** ( $X$ ) pode ser admitido como um modelo

de proporcionalidade directa entre  $Y$  e  $X$ . Uma conclusão análoga num modelo potência corresponde a admitir que na relação populacional  $Y = \alpha x^\beta$  se tem  $\beta = 1$ . Como já se viu na alínea anterior, isso corresponde a admitir que o declive da recta de regressão relacionando as variáveis logaritmizadas é igual a 1. Assim, pode estudar-se a admissibilidade dessa hipótese através dum teste a  $\beta_1$ :

**Hipóteses:**  $H_0 : \beta_1 = 1$  vs.  $H_1 : \beta_1 \neq 1$ .

**Estatística do Teste:**  $T = \frac{\hat{\beta}_1 - \beta_{1|H_0}}{\hat{\sigma}_{\hat{\beta}_1}} \cap t_{n-2}$ , 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:** (Bilateral) Rejeitar  $H_0$  se  $|T_{calc}| > t_{\frac{\alpha}{2}(n-2)} = t_{0.025(236)}$  que, como já se viu, é um valor próximo de 1.97.

**Conclusões:** Tem-se  $T_{calc} = \frac{b_1 - 1}{\hat{\sigma}_{\hat{\beta}_1}}$ . No enunciado são dados os valores de  $b_1 = 1.00085$  e  $\hat{\sigma}_{\hat{\beta}_1} = 0.03208$ . Logo,  $T_{calc} = \frac{1.00085 - 1}{0.03208} = 0.02649626$ , um valor que está muito longe de pertencer à Região Crítica, pelo que, de forma muito clara, indica a não rejeição de  $H_0$  (ao nível  $\alpha = 0.05$  usado).

Assim, também este modelo sugere que é admissível considerar que o peso médio da lenha à poda é (aproximadamente) proporcional ao número de lançamentos. Ambos os modelos ajustam relações aproximadamente iguais a  $y = 0.05x$ , ou seja, que aproximam o peso, em  $kg$ , da lenha de poda dividindo por 20 o número de lançamentos da videira.

### III

1. Pedem-se para fazer com  $\beta_0$  o que foi feito nas aulas teóricas para o parâmetro  $\beta_1$ , e que se encontra na página *web* da disciplina, na subsecção de materiais de apoio relativos às aulas teóricas com a designação *Demonstrações de resultados teóricos*. Sabemos pelo enunciado que  $\frac{\hat{\beta}_0 - \beta_0}{\hat{\sigma}_{\hat{\beta}_0}} \cap t_{n-2}$ . Designando por  $t_{\alpha/2(n-2)}$  o valor que, numa distribuição  $t_{n-2}$  deixa à sua direita uma região de probabilidade  $\alpha/2$ , e uma vez que o simétrico desse valor,  $-t_{\alpha/2(n-2)}$ , será (dada a simetria da distribuição  $t$ -Student em torno de zero) o valor que deixa à sua *esquerda* uma área  $\alpha/2$ , pode-se escrever a seguinte equação:

$$P \left[ -t_{\alpha/2(n-2)} < \frac{\hat{\beta}_0 - \beta_0}{\hat{\sigma}_{\hat{\beta}_0}} < t_{\alpha/2(n-2)} \right] = 1 - \alpha$$

Substituindo a dupla desigualdade por outras duplas desigualdades equivalentes não altera a probabilidade  $1 - \alpha$ . Vamos efectuar essas substituições com o objectivo de deixar o parâmetro para o qual se pretende construir o intervalo de confiança ( $\beta_0$ ) sozinho no meio duma dupla desigualdade. Tem-se (primeiro multiplicando a dupla desigualdade por  $\hat{\sigma}_{\hat{\beta}_0}$ , depois por  $-1$  e finalmente somando  $\hat{\beta}_0$ ):

$$\begin{aligned} -t_{\alpha/2(n-2)} \cdot \hat{\sigma}_{\hat{\beta}_0} &< \hat{\beta}_0 - \beta_0 < t_{\alpha/2(n-2)} \cdot \hat{\sigma}_{\hat{\beta}_0} \\ \Leftrightarrow t_{\alpha/2(n-2)} \cdot \hat{\sigma}_{\hat{\beta}_0} &> \beta_0 - \hat{\beta}_0 > -t_{\alpha/2(n-2)} \cdot \hat{\sigma}_{\hat{\beta}_0} \\ \Leftrightarrow \hat{\beta}_0 - t_{\alpha/2(n-2)} \cdot \hat{\sigma}_{\hat{\beta}_0} &< \beta_0 < \hat{\beta}_0 + t_{\alpha/2(n-2)} \cdot \hat{\sigma}_{\hat{\beta}_0} \end{aligned}$$

Assim, a probabilidade de o verdadeiro valor da ordenada na origem  $\beta_0$  da recta populacional estar contido entre os dois extremos indicados é  $1 - \alpha$ . O intervalo de confiança a  $(1 - \alpha) \times 100\%$

para  $\beta_0$  resulta de substituir os valores dos estimadores  $\hat{\beta}_0$  e de  $\hat{\sigma}_{\hat{\beta}_0}$  pelas suas estimativas amostrais, obtendo-se a fórmula conhecida:

$$\left] b_0 - t_{\alpha/2(n-2)} \cdot \hat{\sigma}_{\hat{\beta}_0} \quad , \quad b_0 + t_{\alpha/2(n-2)} \cdot \hat{\sigma}_{\hat{\beta}_0} \left[ .$$

2. Esta pergunta corresponde ao Exercício 19 da Regressão Linear Simples. Sabemos que  $\hat{\mu}_{Y|x} = \hat{\beta}_0 + \hat{\beta}_1 x$ . Nesta expressão, os estimadores  $\hat{\beta}_0$  e  $\hat{\beta}_1$  são variáveis aleatórias (os seus valores variam ao longo do universo de amostras), enquanto que o valor  $x$  fixado para a variável preditora é não aleatório. Tem-se então, usando as propriedades das (co)variâncias envolvendo produtos de constantes e variáveis aleatórias, bem como as expressões das variâncias de  $\hat{\beta}_0$  e  $\hat{\beta}_1$  e da respectiva covariância (todas disponíveis no formulário):

$$\begin{aligned} V[\hat{\mu}_{Y|x}] &= V[\hat{\beta}_0 + \hat{\beta}_1 x] = V[\hat{\beta}_0] + V[\hat{\beta}_1 x] + 2 \text{Cov}(\hat{\beta}_0, \hat{\beta}_1 x) \\ &= V[\hat{\beta}_0] + x^2 \cdot V[\hat{\beta}_1] + 2x \cdot \text{Cov}(\hat{\beta}_0, \hat{\beta}_1) \\ &= \sigma^2 \left[ \underbrace{\frac{1}{n} + \frac{\bar{x}^2}{(n-1)s_x^2}}_{=V[\hat{\beta}_0]} + x^2 \cdot \underbrace{\frac{\sigma^2}{(n-1)s_x^2}}_{=V[\hat{\beta}_1]} + 2x \cdot \underbrace{\frac{-\sigma^2 \bar{x}}{(n-1)s_x^2}}_{=\text{Cov}[\hat{\beta}_0, \hat{\beta}_1]} \right] \\ &= \sigma^2 \left[ \frac{1}{n} + \frac{\bar{x}^2 + x^2 - 2\bar{x}x}{(n-1)s_x^2} \right] = \sigma^2 \left[ \frac{1}{n} + \frac{(x - \bar{x})^2}{(n-1)s_x^2} \right] . \end{aligned}$$

3. Viu-se nas aulas teóricas que uma relação exponencial entre  $Y$  e  $X$  corresponde a admitir que  $y$  é função de  $x$  e que a sua taxa de variação relativa é constante, ou seja, corresponde a admitir a equação diferencial  $\frac{y'(x)}{y(x)} = b$ . De facto, primitivando ambos os lados da equação em ordem a  $x$ , e acrescentando a constante de primitivação do lado direito, obtém-se a equação  $\ln(y) = bx + C$ , ou seja, uma relação linear entre  $\ln(y)$  e  $x$ . Tomando exponenciais para isolar  $y$ , resulta  $y = e^{bx+C} = e^C \cdot e^{bx}$ . Esta equação é do tipo exponencial, como pedido.
4. A covariância amostral  $cov_{xY}$  é o numerador do estimador  $\hat{\beta}_1$  do declive da recta de regressão. Mais concretamente, tem-se  $\hat{\beta}_1 = \frac{cov_{xY}}{s_x^2} \Leftrightarrow cov_{xY} = \hat{\beta}_1 s_x^2$ . Nesta expressão,  $\hat{\beta}_1$  é uma variável aleatória e  $s_x^2$  é não aleatória. Assim, a covariância é uma transformação linear (afim) de  $\hat{\beta}_1$  (recorde-se que uma transformação linear afim duma variável aleatória  $X$  é uma quantidade  $a + bX$ , onde  $a$  e  $b$  são constantes). Sabemos que a distribuição de  $\hat{\beta}_1$  sob o Modelo Linear é Normal, e que qualquer transformação linear (afim) duma quantidade com distribuição Normal continua a ter distribuição Normal. Assim, está justificada a Normalidade de  $cov_{xY}$ . Falta identificar os respectivos parâmetros, ou seja,  $E[cov_{xY}]$  e  $V[cov_{xY}]$ . Usando as propriedades dos valores esperados e variâncias, dadas nas aulas, temos:

$$E[cov_{xY}] = E[\hat{\beta}_1 s_x^2] = s_x^2 E[\hat{\beta}_1] = s_x^2 \beta_1 ,$$

já que  $\hat{\beta}_1$  é um estimador centrado. Analogamente,

$$V[cov_{xY}] = V[\hat{\beta}_1 s_x^2] = (s_x^2)^2 V[\hat{\beta}_1] = (s_x^2)^2 \frac{\sigma^2}{(n-1)s_x^2} = s_x^2 \frac{\sigma^2}{n-1} ,$$

como se pedia para mostrar.