
INSTITUTO SUPERIOR DE AGRONOMIA
ESTATÍSTICA E DELINEAMENTO EXPERIMENTAL- 2024-25
Resoluções de exercícios teóricos de Regressão Linear - Abordagem Descritiva

1. Tem-se:

$$(a) \sum_{i=1}^n (x_i - \bar{x}) = \sum_{i=1}^n x_i - \sum_{i=1}^n \bar{x} = n\bar{x} - n\bar{x} = 0.$$

(b) Por definição, $(n-1)cov_{xy} = \sum_{i=1}^n (x_i - \bar{x})(y_i - \bar{y})$. Distribuindo o primeiro factor de cada parcela pelas parcelas do segundo factor e utilizando o resultado da alínea anterior, temos:

$$(n-1)cov_{xy} = \sum_{i=1}^n (x_i - \bar{x})y_i - \sum_{i=1}^n (x_i - \bar{x})\bar{y} = \sum_{i=1}^n (x_i - \bar{x})y_i - \bar{y} \underbrace{\sum_{i=1}^n (x_i - \bar{x})}_{=0} = \sum_{i=1}^n (x_i - \bar{x})y_i$$

Trocando o papel das variáveis x e y , mostra-se que $(n-1)cov_{xy} = \sum_{i=1}^n x_i(y_i - \bar{y})$.

(c) Por definição, $(n-1)s_x^2 = \sum_{i=1}^n (x_i - \bar{x})^2 = \sum_{i=1}^n (x_i - \bar{x})(x_i - \bar{x})$. Procedendo como na alínea anterior, tem-se $(n-1)s_x^2 = \sum_{i=1}^n (x_i - \bar{x})x_i - \bar{x} \underbrace{\sum_{i=1}^n (x_i - \bar{x})}_{=0} = \sum_{i=1}^n (x_i - \bar{x})x_i$

2. (a) Tendo em conta que os valores ajustados de y são dados por $\hat{y}_i = b_0 + b_1 x_i$, tem-se que a média dos valores ajustados é dada por:

$$\frac{1}{n} \sum_{i=1}^n \hat{y}_i = \frac{1}{n} \sum_{i=1}^n (b_0 + b_1 x_i) = \frac{1}{n} \sum_{i=1}^n b_0 + \frac{1}{n} \sum_{i=1}^n b_1 x_i = b_0 + b_1 \bar{x}.$$

Mas a ordenada de origem duma recta de regressão é dada por $b_0 = \bar{y} - b_1 \bar{x}$, pelo que a última expressão equivale à média \bar{y} dos valores observados de y .

(b) Tem-se, por definição, que $e_i = y_i - \hat{y}_i$. Logo (e tendo em conta a alínea anterior),

$$\bar{e} = \frac{1}{n} \sum_{i=1}^n e_i = \frac{1}{n} \sum_{i=1}^n (y_i - \hat{y}_i) = \frac{1}{n} \sum_{i=1}^n y_i - \frac{1}{n} \sum_{i=1}^n \hat{y}_i = \bar{y} - \bar{y} = 0.$$

(c) Por definição, a variância amostral de n observações z_i quaisquer, é dada por $s_z^2 = \frac{1}{n-1} \sum_{i=1}^n (z_i - \bar{z})^2$. Assim, a variância amostral das n observações y_i da variável resposta é dada por: $s_y^2 = \frac{1}{n-1} \sum_{i=1}^n (y_i - \bar{y})^2$. O somatório nesta expressão é, por definição, a Soma de Quadrados Total, SQT . Logo, $SQT = (n-1) \times s_y^2$, como se pedia para justificar. De forma análoga, a variância dos n valores ajustados da variável resposta, os \hat{y}_i , é dada por: $s_{\hat{y}}^2 = \frac{1}{n-1} \sum_{i=1}^n (\hat{y}_i - \bar{y})^2$. Repare-se que, nesta última expressão, a média dos valores \hat{y}_i é igual

à média dos n valores observados y_i , como se viu na alínea 2a. Mas o somatório nesta expressão é, por definição, SQR . Logo, $SQR = (n-1) \times s_y^2$. Finalmente, a variância amostral dos n resíduos e_i é, por definição, $s_e^2 = \frac{1}{n-1} \sum_{i=1}^n (e_i - \bar{e})^2$. Mas a média dos n resíduos é nula, como se viu na alínea 2b, e $\bar{e}=0$ implica que o somatório nesta última expressão é apenas a Soma de Quadrados Residual, $SQRE = \sum_{i=1}^n e_i^2$. Logo, $SQRE = (n-1) \times s_e^2$.

- (d) Ora, recordando a definição dos valores ajustados de y e a expressão da ordenada na origem da recta de regressão, b_0 , temos que $\hat{y}_i = b_0 + b_1 x_i = \bar{y} + b_1(x_i - \bar{x})$. Logo,

$$SQR = \sum_{i=1}^n (\hat{y}_i - \bar{y})^2 = \sum_{i=1}^n [b_1(x_i - \bar{x})]^2 = b_1^2 \sum_{i=1}^n (x_i - \bar{x})^2 = b_1^2 (n-1) s_x^2 .$$

- (e) Na expressão que define SQT vamos introduzir um par de parcelas de soma zero, que nos ajudarão nas contas subsequentes ($-\hat{y}_i + \hat{y}_i = 0$):

$$\begin{aligned} SQT &= \sum_{i=1}^n (y_i - \bar{y})^2 = \sum_{i=1}^n [(y_i - \hat{y}_i) + (\hat{y}_i - \bar{y})]^2 \\ &= \sum_{i=1}^n [(y_i - \hat{y}_i)^2 + (\hat{y}_i - \bar{y})^2 + 2(y_i - \hat{y}_i)(\hat{y}_i - \bar{y})] \\ &= \underbrace{\sum_{i=1}^n (y_i - \hat{y}_i)^2}_{= SQRE} + \underbrace{\sum_{i=1}^n (\hat{y}_i - \bar{y})^2}_{= SQR} + 2 \sum_{i=1}^n (y_i - \hat{y}_i)(\hat{y}_i - \bar{y}) \end{aligned} \quad (1)$$

Para que a igualdade pedida se verifique, é preciso que a última parcela na expressão (1) seja nula. Viu-se acima que $\hat{y}_i = b_0 + b_1 x_i = \bar{y} + b_1(x_i - \bar{x})$. Logo, o somatório na última parcela da equação (1) pode ser re-escrito como:

$$\begin{aligned} \sum_{i=1}^n (y_i - \hat{y}_i)(\hat{y}_i - \bar{y}) &= \sum_{i=1}^n [(y_i - \bar{y}) - b_1(x_i - \bar{x})] b_1(x_i - \bar{x}) \\ &= b_1 \left[\underbrace{\sum_{i=1}^n (x_i - \bar{x})(y_i - \bar{y})}_{=(n-1) cov_{xy}} - b_1 \underbrace{\sum_{i=1}^n (x_i - \bar{x})^2}_{=(n-1) s_x^2} \right] \end{aligned}$$

Tendo em conta que $b_1 = \frac{cov_{xy}}{s_x^2}$, tem-se $b_1 s_x^2 = cov_{xy}$. Logo, a diferença acima anula-se.

- (f) Pela definição de coeficiente de correlação entre x e y , tem-se:

$$r_{xy} = \frac{cov_{xy}}{s_x \cdot s_y} = \frac{cov_{xy}}{s_x^2} \cdot \frac{s_x}{s_y} = b_1 \cdot \frac{s_x}{s_y}$$

- (g) Por definição, $R^2 = \frac{SQR}{SQT}$. Tendo em conta que $SQT = (n-1)s_y^2$, que $SQR = b_1^2(n-1)s_x^2$ (Exercício 2d) e o resultado da alínea anterior, tem-se $R^2 = \frac{b_1^2 s_x^2}{s_y^2} = (r_{xy})^2$.

- (h) Os valores ajustados \hat{y}_i são dados por uma mesma transformação linear (afim) dos valores do preditor: $\hat{y}_i = b_0 + b_1 x_i$. São conhecidas as propriedades destas transformações sobre a covariância e a variância. Assim,

$$r_{y\hat{y}}^2 = \left(\frac{\text{cov}_{y\hat{y}}}{s_y s_{\hat{y}}} \right)^2 = \frac{\text{cov}_{y, b_0 + b_1 x}^2}{s_y^2 s_{b_0 + b_1 x}^2} = \frac{(b_1 \text{cov}_{y,x})^2}{s_y^2 b_1^2 s_x^2} = \frac{b_1^2 \text{cov}_{xy}^2}{b_1^2 s_x^2 s_y^2} = r_{xy}^2 = R^2.$$

Assim, o coeficiente de determinação duma regressão linear simples é também o quadrado do coeficiente de correlação linear entre os valores observados e os valores ajustados de y . Esta propriedade estende-se às regressões lineares múltiplas, embora seja necessário adaptar a justificação.

3. Começemos por recordar alguns resultados já previamente discutidos:

- Viu-se no Exercício 1b) da Regressão Linear Simples que, para qualquer conjunto de n pares de observações se tem: $(n-1) \text{cov}_{xy} = \sum_{i=1}^n (x_i - \bar{x})(y_i - \bar{y}) = \sum_{i=1}^n (x_i - \bar{x})y_i$. Distribuindo y_i e o somatório pela diferença, tem-se:

$$(n-1) \text{cov}_{xy} = \sum_{i=1}^n x_i y_i - \underbrace{\bar{x} \sum_{i=1}^n y_i}_{=n\bar{y}} = \sum_{i=1}^n x_i y_i - n\bar{x}\bar{y} \Leftrightarrow \sum_{i=1}^n x_i y_i = (n-1) \text{cov}_{xy} + n\bar{x}\bar{y}. \quad (2)$$

- Tomando $y_i = x_i$, para todo o i , na fórmula anterior, obtém-se:

$$(n-1) s_x^2 = \sum_{i=1}^n (x_i - \bar{x})^2 = \sum_{i=1}^n x_i^2 - n\bar{x}^2 \Leftrightarrow \sum_{i=1}^n x_i^2 = (n-1) s_x^2 + n\bar{x}^2 \quad (3)$$

- O produto de matrizes AB só é possível quando o número de colunas da matriz A for igual ao número de linhas da matriz B (matrizes *compatíveis* para a multiplicação). Se A é de dimensão $p \times q$ e B de dimensão $q \times r$, o produto AB é de dimensão $p \times r$.
- O elemento na linha i , coluna j , dum produto matricial AB , é dado pelo *produto interno*

da linha i de A com a coluna j de B : $(AB)_{ij} = (a_{i1} \ a_{i2} \ \dots \ a_{iq}) \begin{pmatrix} b_{1j} \\ b_{2j} \\ \vdots \\ b_{qj} \end{pmatrix} = \sum_{k=1}^q a_{ik} b_{kj}$.

- O produto interno de dois vectores n -dimensionais \vec{x} e \vec{y} é dado por $\vec{x}^t \vec{y} = \sum_{i=1}^n x_i y_i$. No

caso de um dos vectores ser o vector de n uns, $\vec{\mathbf{1}}_n$, o produto interno resulta na soma dos elementos do outro vector, ou seja, em n vezes a média dos elementos do outro vector:

$$\vec{\mathbf{1}}_n^t \vec{x} = \sum_{i=1}^n x_i = n\bar{x}.$$

- A *matriz inversa* duma matriz $n \times n$ A é definida (caso exista) como a matriz (única) A^{-1} , também de dimensão $n \times n$, tal que $AA^{-1} = \mathbf{I}_n$, onde \mathbf{I}_n é a matriz identidade de dimensão $n \times n$ (recorde-se que uma matriz identidade é uma matriz quadrada com todos os elementos diagonais iguais a 1 e todos os elementos não diagonais iguais a zero).

- No caso de A ser uma matriz 2×2 , de elementos $A = \begin{bmatrix} a & b \\ c & d \end{bmatrix}$, a matriz inversa é dada (verifique!) por:

$$A^{-1} = \frac{1}{ad - bc} \begin{bmatrix} d & -b \\ -c & a \end{bmatrix} \quad (4)$$

esta matriz inversa existe *se e só se o determinante* $ad - bc \neq 0$.

Com estes resultados prévios, as contas do exercício resultam de forma simples:

- A matriz do modelo \mathbf{X} é de dimensão $n \times (p+1)$, que no caso duma regressão linear simples ($p=1$), significa $n \times 2$. Tem uma primeira coluna de uns (o vector $\vec{\mathbf{1}}_n$) e uma segunda coluna com os n valores observados da variável preditora x , coluna essa que designamos pelo vector $\vec{\mathbf{x}}$. Logo, a sua transposta \mathbf{X}^t é de dimensão $2 \times n$. Como o vector $\vec{\mathbf{y}}$ é de dimensão $n \times 1$, o produto $\mathbf{X}\vec{\mathbf{y}}$ é possível e o resultado é um vector de dimensão 2×1 . O primeiro elemento (na posição (1,1)) desse produto é dada pelo produto interno da primeira linha de \mathbf{X}^t com a primeira e única coluna de $\vec{\mathbf{y}}$, ou seja, por $\vec{\mathbf{1}}_n^t \vec{\mathbf{y}} = \sum_{i=1}^n y_i = n\bar{y}$. O segundo elemento (posição (2,1)) desse vector é dado pelo produto interno da segunda linha de \mathbf{X}^t e a única coluna de $\vec{\mathbf{y}}$, ou seja, por $\vec{\mathbf{x}}^t \vec{\mathbf{y}} = \sum_{i=1}^n x_i y_i = (n-1) \text{cov}_{xy} + n\bar{x}\bar{y}$, tendo em conta a equação (2).
- Tendo em conta que \mathbf{X}^t é de dimensão $2 \times n$ e \mathbf{X} é de dimensão $n \times 2$, o produto $\mathbf{X}^t \mathbf{X}$ é possível e de dimensão 2×2 . O elemento na posição (1,1) é o produto interno da primeira linha de \mathbf{X}^t ($\vec{\mathbf{1}}_n$) com a primeira coluna de \mathbf{X} (igualmente $\vec{\mathbf{1}}_n$), logo é: $\vec{\mathbf{1}}_n^t \vec{\mathbf{1}}_n = n$. O elemento na posição (1,2) é o produto interno da primeira linha de \mathbf{X}^t ($\vec{\mathbf{1}}_n$) e segunda coluna de \mathbf{X} ($\vec{\mathbf{x}}$), logo é $\vec{\mathbf{1}}_n^t \vec{\mathbf{x}} = \sum_{i=1}^n x_i = n\bar{x}$. O elemento na posição (2,1) é o produto interno da segunda linha de \mathbf{X}^t ($\vec{\mathbf{x}}$) com a primeira coluna de \mathbf{X} ($\vec{\mathbf{1}}_n$), logo é também $n\bar{x}$. Finalmente, o elemento na posição (2,2) é o produto interno da segunda linha de \mathbf{X}^t ($\vec{\mathbf{x}}$) com a segunda coluna de \mathbf{X} ($\vec{\mathbf{x}}$), ou seja, $\vec{\mathbf{x}}^t \vec{\mathbf{x}} = \sum_{i=1}^n x_i^2 = (n-1) s_x^2 + n\bar{x}^2$. Fica assim provado o resultado do enunciado.
- A expressão da inversa dada no enunciado vem directamente de aplicar a fórmula (4) à matriz $(\mathbf{X}^t \mathbf{X})$ obtida na alínea anterior. Apenas há que confirmar a expressão do determinante $ad - bc = n \sum_{i=1}^n x_i^2 - \left(\sum_{i=1}^n x_i \right)^2 = n \sum_{i=1}^n x_i^2 - (n\bar{x})^2 = n \left(\sum_{i=1}^n x_i^2 - n\bar{x}^2 \right) = n(n-1) s_x^2$, tendo em conta a fórmula (3).
- Usando as expressões finais obtidas nas alíneas (c) e (a), obtém-se

$$\begin{aligned} (\mathbf{X}^t \mathbf{X})^{-1} \mathbf{X}^t \vec{\mathbf{y}} &= \frac{1}{n(n-1)s_x^2} \begin{bmatrix} (n-1)s_x^2 + n\bar{x}^2 & -n\bar{x} \\ -n\bar{x} & n \end{bmatrix} \begin{bmatrix} n\bar{y} \\ (n-1)\text{cov}_{xy} + n\bar{x}\bar{y} \end{bmatrix} \\ &= \frac{1}{n(n-1)s_x^2} \begin{bmatrix} (n-1)s_x^2 n\bar{y} + n^2\bar{x}^2\bar{y} - n\bar{x}(n-1)\text{cov}_{xy} - n^2\bar{x}^2\bar{y} \\ -n^2\bar{x}\bar{y} + n(n-1)\text{cov}_{xy} + n^2\bar{x}^2\bar{y} \end{bmatrix} \\ &= \begin{bmatrix} \frac{n(n-1)s_x^2\bar{y}}{n(n-1)s_x^2} - \frac{n(n-1)\text{cov}_{xy}\bar{x}}{n(n-1)s_x^2} \\ \frac{n(n-1)\text{cov}_{xy}}{n(n-1)s_x^2} \end{bmatrix} = \begin{bmatrix} \bar{y} - b_1\bar{x} \\ b_1 \end{bmatrix} = \begin{bmatrix} b_0 \\ b_1 \end{bmatrix}. \end{aligned}$$

- Sabemos que a matriz de projecção ortogonal referida é dada por $\mathbf{H} = \mathbf{X}(\mathbf{X}^t \mathbf{X})^{-1} \mathbf{X}^t$, onde \mathbf{X} é a matriz do modelo, ou seja, a matriz de dimensões $n \times (p+1)$ que tem na primeira coluna, n uns, e em cada uma das p restantes colunas, as n observações de cada variável preditora. Ora,

- (a) A idempotência é fácil de verificar, tendo em conta que $(\mathbf{X}^t \mathbf{X})^{-1}$ é a matriz inversa de $\mathbf{X}^t \mathbf{X}$:

$$\mathbf{H} \mathbf{H} = \mathbf{X}(\mathbf{X}^t \mathbf{X})^{-1} \mathbf{X}^t \mathbf{X}(\mathbf{X}^t \mathbf{X})^{-1} \mathbf{X}^t = \mathbf{X}(\mathbf{X}^t \mathbf{X})^{-1} \cancel{\mathbf{X}^t \mathbf{X}} (\mathbf{X}^t \mathbf{X})^{-1} \mathbf{X}^t = \mathbf{X}(\mathbf{X}^t \mathbf{X})^{-1} \mathbf{X}^t = \mathbf{H} .$$

A simetria resulta de três propriedades conhecidas de matrizes: a transposta de uma matriz transposta é a matriz original ($(\mathbf{A}^t)^t = \mathbf{A}$); a transposta dum produto de matrizes é o produto das correspondentes transpostas, pela ordem inversa ($(\mathbf{A}\mathbf{B})^t = \mathbf{B}^t \mathbf{A}^t$); e a transposta de uma matriz inversa é a inversa da transposta ($(\mathbf{A}^{-1})^t = (\mathbf{A}^t)^{-1}$). De facto, tem-se:

$$\mathbf{H}^t = [\mathbf{X}(\mathbf{X}^t \mathbf{X})^{-1} \mathbf{X}^t]^t = \mathbf{X}[(\mathbf{X}^t \mathbf{X})^{-1}]^t \mathbf{X}^t = \mathbf{X}[(\mathbf{X}^t \mathbf{X})^t]^{-1} \mathbf{X}^t = \mathbf{X}(\mathbf{X}^t \mathbf{X})^{-1} \mathbf{X}^t = \mathbf{H} .$$

- (b) Como foi visto nas aulas teóricas, qualquer vector do subespaço das colunas da matriz \mathbf{X} , ou seja, do subespaço $\mathcal{C}(\mathbf{X}) \subset \mathbb{R}^n$, se pode escrever como $\mathbf{X}\vec{\mathbf{a}}$, onde $\vec{\mathbf{a}} \in \mathbb{R}^{p+1}$ é o vector dos $p+1$ coeficientes na combinação linear das colunas de \mathbf{X} . Ora, a projecção ortogonal deste vector sobre o subespaço $\mathcal{C}(\mathbf{X})$ (que já o contém) é dada por

$$\mathbf{H}\mathbf{X}\vec{\mathbf{a}} = \mathbf{X}(\mathbf{X}^t \mathbf{X})^{-1} \mathbf{X}^t (\mathbf{X}\vec{\mathbf{a}}) = \mathbf{X}(\mathbf{X}^t \mathbf{X})^{-1} \cancel{\mathbf{X}^t \mathbf{X}} \vec{\mathbf{a}} = \mathbf{X}\vec{\mathbf{a}} .$$

Assim, o vector $\mathbf{X}\vec{\mathbf{a}}$ fica igual após a projecção.

- (c) Por definição, o vector dos valores ajustados é dado por $\hat{\vec{\mathbf{y}}} = \mathbf{H}\vec{\mathbf{y}}$. Ora, a média desses valores ajustados, que podemos representar por $\bar{\hat{y}} = \frac{1}{n} \sum_{i=1}^n \hat{y}_i$, pode ser calculado tomando o produto interno do vector $\vec{\mathbf{1}}_n$ de n uns com o vector $\hat{\vec{\mathbf{y}}}$, uma vez que esse produto interno devolve a soma dos elementos de $\hat{\vec{\mathbf{y}}}$. Assim, a média dos valores ajustados é $\bar{\hat{y}} = \frac{1}{n} \vec{\mathbf{1}}_n^t \hat{\vec{\mathbf{y}}} = \frac{1}{n} \vec{\mathbf{1}}_n^t \mathbf{H}\vec{\mathbf{y}} = \frac{1}{n} (\mathbf{H}\vec{\mathbf{1}}_n)^t \vec{\mathbf{y}} = \frac{1}{n} \vec{\mathbf{1}}_n^t \vec{\mathbf{y}}$, uma vez que $\mathbf{H}\vec{\mathbf{1}}_n = \vec{\mathbf{1}}_n$. Esta última afirmação decorre directamente da alínea anterior, uma vez que o vector $\vec{\mathbf{1}}_n$ pertence ao subespaço das colunas de \mathbf{X} , sendo a primeira das colunas dessa matriz (usando a notação da alínea anterior, tem-se $\vec{\mathbf{1}}_n = \mathbf{X}\vec{\mathbf{a}}$ com $\vec{\mathbf{a}} = (1, 0, 0, \dots, 0)^t$). Mas a expressão final obtida, $\frac{1}{n} \vec{\mathbf{1}}_n^t \vec{\mathbf{y}}$, é a média \bar{y} dos valores observados de Y (já que $\vec{\mathbf{1}}_n^t \vec{\mathbf{y}}$ devolve a soma dos elementos do vector dessas observações, $\vec{\mathbf{y}}$). Assim, também na regressão linear múltipla, valores observados de Y e correspondentes valores ajustados partilham o mesmo valor médio.

5. [Opcional]

A matriz de projecção ortogonal $\mathbf{P} = \vec{\mathbf{1}}_n (\vec{\mathbf{1}}_n^t \vec{\mathbf{1}}_n)^{-1} \vec{\mathbf{1}}_n^t$ é de dimensão $n \times n$ (confirme!), uma vez que o vector $\vec{\mathbf{1}}_n$ é $n \times 1$. Mas o seu cálculo é facilitado pelo facto de que $\vec{\mathbf{1}}_n^t \vec{\mathbf{1}}_n$ é, neste caso, um escalar. Concretamente, $\vec{\mathbf{1}}_n^t \vec{\mathbf{1}}_n = n$, pelo que $(\vec{\mathbf{1}}_n^t \vec{\mathbf{1}}_n)^{-1} = \frac{1}{n}$. Logo $\mathbf{P} = \frac{1}{n} \vec{\mathbf{1}}_n \vec{\mathbf{1}}_n^t$. O produto $\vec{\mathbf{1}}_n \vec{\mathbf{1}}_n^t$ resulta numa matriz $n \times n$ com todos os elementos iguais a 1 (não confundir com o produto pela ordem inversa, $\vec{\mathbf{1}}_n^t \vec{\mathbf{1}}_n$: recorde-se que o produto de matrizes **não** é comutativo). Assim,

$$\mathbf{P} = \frac{1}{n} \begin{bmatrix} 1 & 1 & 1 & \cdots & 1 \\ 1 & 1 & 1 & \cdots & 1 \\ 1 & 1 & 1 & \cdots & 1 \\ \vdots & \vdots & \vdots & \ddots & \vdots \\ 1 & 1 & 1 & \cdots & 1 \end{bmatrix}$$

Tem-se $\mathbf{P}^t = \left[\frac{1}{n} \vec{\mathbf{1}}_n \vec{\mathbf{1}}_n^t \right]^t = \frac{1}{n} [\vec{\mathbf{1}}_n^t]^t [\vec{\mathbf{1}}_n]^t = \frac{1}{n} \vec{\mathbf{1}}_n \vec{\mathbf{1}}_n^t = \mathbf{P}$, logo \mathbf{P} é simétrica. Por outro lado, $\mathbf{P}\mathbf{P} = \vec{\mathbf{1}}_n (\vec{\mathbf{1}}_n^t \vec{\mathbf{1}}_n)^{-1} \vec{\mathbf{1}}_n^t \cdot \vec{\mathbf{1}}_n (\vec{\mathbf{1}}_n^t \vec{\mathbf{1}}_n)^{-1} \vec{\mathbf{1}}_n^t = \vec{\mathbf{1}}_n (\vec{\mathbf{1}}_n^t \vec{\mathbf{1}}_n)^{-1} \vec{\mathbf{1}}_n^t = \mathbf{P}$, logo \mathbf{P} é idempotente.

- (b) O vector $\mathbf{P}\vec{Y}$ repete n vezes o valor médio \bar{Y} (confirme!). Logo, $\vec{Y} - \mathbf{P}\vec{Y}$ é o vector centrado das observações de \vec{Y} :

$$\vec{Y} - \mathbf{P}\vec{Y} = \begin{bmatrix} Y_1 - \bar{Y} \\ Y_2 - \bar{Y} \\ Y_3 - \bar{Y} \\ \vdots \\ Y_n - \bar{Y} \end{bmatrix} = \vec{Y}^c$$

A norma ao quadrado dum qualquer vector $\vec{z} = (z_1, z_2, \dots, z_n)^t$ pode ser escrita de duas formas equivalentes: $\|\vec{z}\|^2 = \sum_{i=1}^n z_i^2$, ou $\|\vec{z}\|^2 = \vec{z}^t \vec{z}$. Assim, tem-se $\|\vec{Y} - \mathbf{P}\vec{Y}\|^2 = \sum_{i=1}^n (Y_i - \bar{Y})^2 = SQT$. Tendo em conta as propriedades relativas a matrizes, incluindo a simetria e idempotência das matrizes \mathbf{I} (de verificação trivial) e \mathbf{P} (alínea anterior), tem-se também:

$$\begin{aligned} SQT &= \|\vec{Y} - \mathbf{P}\vec{Y}\|^2 = \|(\mathbf{I} - \mathbf{P})\vec{Y}\|^2 = [(\mathbf{I} - \mathbf{P})\vec{Y}]^t (\mathbf{I} - \mathbf{P})\vec{Y} = \vec{Y}^t (\mathbf{I} - \mathbf{P})^t (\mathbf{I} - \mathbf{P})\vec{Y} \\ &= \vec{Y}^t (\mathbf{I}^t - \mathbf{P}^t) (\mathbf{I} - \mathbf{P})\vec{Y} = \vec{Y}^t (\mathbf{I} - \mathbf{P}) (\mathbf{I} - \mathbf{P})\vec{Y} \\ &= \vec{Y}^t (\mathbf{I}^2 - \mathbf{IP} - \mathbf{PI} + \mathbf{P}^2)\vec{Y} = \vec{Y}^t (\mathbf{I} - \mathbf{P} - \mathbf{P} + \mathbf{P})\vec{Y} \\ &= \vec{Y}^t (\mathbf{I} - \mathbf{P})\vec{Y} \end{aligned}$$

De forma análoga, e como o vector \vec{Y} dos valores ajustados é dado por $\vec{Y} = \mathbf{X}\vec{\beta} = \mathbf{X}(\mathbf{X}^t \mathbf{X})^{-1} \mathbf{X}^t \vec{Y} = \mathbf{H}\vec{Y}$, temos que o vector $\mathbf{H}\vec{Y} - \mathbf{P}\vec{Y}$ tem como elementos $\hat{Y}_i - \bar{Y}$:

$$\mathbf{H}\vec{Y} - \mathbf{P}\vec{Y} = \begin{bmatrix} \hat{Y}_1 - \bar{Y} \\ \hat{Y}_2 - \bar{Y} \\ \hat{Y}_3 - \bar{Y} \\ \vdots \\ \hat{Y}_n - \bar{Y} \end{bmatrix}$$

pelo que o quadrado da sua norma é $SQR = \sum_{i=1}^n (\hat{Y}_i - \bar{Y})^2$.

Uma expressão alternativa para SQR resulta de considerar (como no caso de SQT) a definição duma norma ao quadrado, e usar as propriedades de matrizes, incluindo a simetria e idempotência de \mathbf{P} e da matriz \mathbf{H} (ver Exercício 4), bem como a propriedade $\mathbf{HP} = \mathbf{PH} = \mathbf{P}$. Esta última passagem resulta do facto de $\mathbf{P} = \vec{\mathbf{1}}_n (\vec{\mathbf{1}}_n^t \vec{\mathbf{1}}_n)^{-1} \vec{\mathbf{1}}_n^t$, pelo que $\mathbf{HP} = \mathbf{H}\vec{\mathbf{1}}_n (\vec{\mathbf{1}}_n^t \vec{\mathbf{1}}_n)^{-1} \vec{\mathbf{1}}_n^t$. Mas, como se viu no Exercício 4, a projecção dum vector sobre um subespaço ao qual esse vector pertence, deixa o vector invariante. Ora \mathbf{H} projecta ortogonalmente sobre o espaço das colunas da matriz \mathbf{X} , $\mathcal{C}(\mathbf{X})$, e o vector $\vec{\mathbf{1}}_n$ pertence a esse subespaço, uma vez que é a primeira coluna da matriz \mathbf{X} . Logo, $\mathbf{H}\vec{\mathbf{1}}_n = \vec{\mathbf{1}}_n$, pelo que $\mathbf{HP} = \mathbf{H}\vec{\mathbf{1}}_n (\vec{\mathbf{1}}_n^t \vec{\mathbf{1}}_n)^{-1} \vec{\mathbf{1}}_n^t = \vec{\mathbf{1}}_n (\vec{\mathbf{1}}_n^t \vec{\mathbf{1}}_n)^{-1} \vec{\mathbf{1}}_n^t = \mathbf{P}$. Por outro lado, a simetria de \mathbf{P} (e de \mathbf{H}) implica que $\mathbf{P} = \mathbf{P}^t = (\mathbf{HP})^t = \mathbf{P}^t \mathbf{H}^t = \mathbf{PH}$. Logo,

$$\begin{aligned} SQR &= \|\mathbf{H}\vec{Y} - \mathbf{P}\vec{Y}\|^2 = \|(\mathbf{H} - \mathbf{P})\vec{Y}\|^2 = \vec{Y}^t (\mathbf{H} - \mathbf{P})^t (\mathbf{H} - \mathbf{P})\vec{Y} \\ &= \vec{Y}^t (\mathbf{H}^t - \mathbf{P}^t) (\mathbf{H} - \mathbf{P})\vec{Y} = \vec{Y}^t (\mathbf{H} - \mathbf{P}) (\mathbf{H} - \mathbf{P})\vec{Y} \\ &= \vec{Y}^t (\mathbf{H}^2 - \mathbf{HP} - \mathbf{PH} + \mathbf{P}^2)\vec{Y} = \vec{Y}^t (\mathbf{H} - \mathbf{P} - \mathbf{P} + \mathbf{P})\vec{Y} \\ &= \vec{Y}^t (\mathbf{H} - \mathbf{P})\vec{Y} . \end{aligned}$$

Finalmente, o vector $\vec{\mathbf{Y}} - \mathbf{H}\vec{\mathbf{Y}} = \vec{\mathbf{Y}} - \vec{\hat{\mathbf{Y}}}$ é o vector dos resíduos, e a sua norma ao quadrado é $SQRE = \sum_{i=1}^n (Y_i - \hat{Y}_i)^2$. Mas, ao mesmo tempo, tem-se:

$$\begin{aligned}
 SQRE &= \|\vec{\mathbf{Y}} - \mathbf{H}\vec{\mathbf{Y}}\|^2 &= \|(\mathbf{I} - \mathbf{H})\vec{\mathbf{Y}}\|^2 &= \vec{\mathbf{Y}}^t(\mathbf{I} - \mathbf{H})^t(\mathbf{I} - \mathbf{H})\vec{\mathbf{Y}} \\
 & &= \vec{\mathbf{Y}}^t(\mathbf{I}^t - \mathbf{H}^t)(\mathbf{I} - \mathbf{H})\vec{\mathbf{Y}} &= \vec{\mathbf{Y}}^t(\mathbf{I} - \mathbf{H})(\mathbf{I} - \mathbf{H})\vec{\mathbf{Y}} \\
 & &= \vec{\mathbf{Y}}^t(\mathbf{I}^2 - \mathbf{I}\mathbf{H} - \mathbf{H}\mathbf{I} + \mathbf{H}^2)\vec{\mathbf{Y}} &= \vec{\mathbf{Y}}^t(\mathbf{I} - \mathbf{H} - \mathbf{H} + \mathbf{H})\vec{\mathbf{Y}} \\
 & &= \vec{\mathbf{Y}}^t(\mathbf{I} - \mathbf{H})\vec{\mathbf{Y}} .
 \end{aligned}$$

(c) Pelas expressões da alínea anterior, pondo em evidência $\vec{\mathbf{Y}}^t$ à esquerda e $\vec{\mathbf{Y}}$ à direita tem-se:

$$\begin{aligned}
 SQRE + SQR &= \vec{\mathbf{Y}}^t(\mathbf{I} - \mathbf{H})\vec{\mathbf{Y}} + \vec{\mathbf{Y}}^t(\mathbf{H} - \mathbf{P})\vec{\mathbf{Y}} &= \vec{\mathbf{Y}}^t[(\mathbf{I} - \mathbf{H}) + (\mathbf{H} - \mathbf{P})]\vec{\mathbf{Y}} \\
 &= \vec{\mathbf{Y}}^t[\mathbf{I} - \mathbf{P}]\vec{\mathbf{Y}} &= SQT .
 \end{aligned}$$