

Licenciatura em Economia

Econometria I

ISCTE-IUL, Business School, 2023/2024

EXERCÍCIOS PRÁTICOS

Docente: Joaquim J. S. Ramalho
E-mail: jjsro@iscte-iul.pt
Gabinete: D5.10

1. Introdução

1.1 A tabela seguinte contém despesas mensais com a habitação (X) de 10 famílias.

Família	X (euros)
1	300
2	440
3	350
4	1100
5	640
6	480
7	450
8	700
9	670
10	530

- Calcule a despesa média mensal com a habitação.
- Calcule a despesa mediana mensal com a habitação.
- Se as despesas com a habitação fossem medidas em centenas de euros, em vez de euros, qual seria a despesa média e mediana?
- Suponha que a família 8 aumenta as suas despesas mensais com a habitação em 900 euros, mas as despesas de todas as outras famílias se mantêm. Calcule a despesa média e mediana com a habitação.

1.2 Considere que Y e X são duas variáveis aleatórias. Um investigador recolheu uma amostra com os seguintes oito pares de elementos:

Y	X
5.1	10.3
4.5	8.4
7.6	9.3
9.5	15.4
13.2	14.1
12.0	11.3
2.1	5.2
3.5	4.7

- Estime as médias, as variâncias e os desvios padrão de Y e X .
- Estime a covariância e o coeficiente de correlação entre Y e X .
- Se X for multiplicado por 10, qual o efeito nos cálculos da alínea anterior? Comente.

1.3 Com base numa amostra de 10 observações, foram obtidos os seguintes resultados:

$$\begin{aligned}\Sigma Y &= 1110 & \Sigma Y^2 &= 132100 & \Sigma XY &= 205500 \\ \Sigma X &= 1700 & \Sigma X^2 &= 322000 & r &= 0.98\end{aligned}$$

Ao verificar os cálculos encontraram-se dois pares de observações que estavam incorretos, ou seja, haviam sido utilizados:

Y	X		Y	X
90	120	em vez de	80	110
140	220		150	210

Qual será o efeito deste erro no coeficiente de correlação? Obtenha o valor de r correto.

1.4 Seja X o salário anual de um professor universitário nos EUA, em milhares de dólares. Suponha que o salário médio é 52.3 com um desvio padrão de 14.6. Obtenha a média e o desvio padrão quando o salário é medido em dólares.

1.5 Suponha que duas variáveis Y e X estão relacionadas pela expectativa condicionada:

$$E(Y|X) = 0.7 + 0.002X$$

- Obtenha o valor esperado de Y quando $X = 800$. Obtenha também $E(Y|X = 1400)$. Comente a diferença.
- Se o valor esperado de X for a média dos seus dois valores referidos na alínea anterior, qual acha que será o valor esperado de Y ? Confirme a sua resposta usando a lei das expectativas iteradas.

1.6 Suponha que um professor da população referida em (1.4) ganha 62760 dólares por ano.

- Qual a percentagem exacta em que este salário excede a média?
- Calcule agora a percentagem aproximada usando a diferença nos logaritmos naturais. Comente.

2. O Modelo de Regressão Linear Simples

2.1 Seja $fert$ o número de filhos de uma mulher, e $educ$ o número de anos de escolaridade da mesma mulher. Um modelo simples relacionando a fertilidade com a educação será:

$$fert = \beta_0 + \beta_1 educ + u$$

onde u é o erro não observável.

- Que fatores poderão estar incluídos em u ? Estarão esses fatores provavelmente relacionados com o nível de educação?
- Será que uma regressão simples poderá mostrar o efeito *ceteris paribus* da educação na fertilidade? Explique.

2.2 Um dos fatores que poderá influenciar o peso do bebé à nascença ($peso$) é o número médio de cigarros fumado por dia pela mãe ($cigs$). Usando dados de 1388 nascimentos, estimou-se a seguinte regressão linear simples:

$$\widehat{peso} = 3.4 - 0.015cigs$$

- Qual o peso à nascença previsto para o bebé de uma mãe não fumadora? E se a mãe fumar um maço (20 cigarros) por dia? Comente a diferença.
- Será que esta regressão simples capta necessariamente uma relação causal entre o peso do bebé à nascença e o hábito de fumar da mãe?

2.3 Usando observações do rendimento e consumo anuais (ambos medidos em dólares) para 100 famílias, foi estimada a seguinte função consumo linear:

$$\widehat{consumo} = -124.84 + 0.85rend; \quad n = 100; \quad R^2 = 0.162$$

- Interprete o termo constante nesta equação e comente o seu sinal.
- Qual o consumo previsto se o rendimento familiar é 30 000 dólares?
- Com $rend$ no eixo das abcissas, trace um gráfico da propensão marginal ao consumo (PmgC) e da propensão média ao consumo (PMeC) estimadas.

2.4 Assuma que lhe são fornecidos os seguintes dados sobre a despesa em publicidade (X) e as vendas de detergente (Y) de 10 empresas, em euros, num determinado período:

X	2	4.8	3	5	2.5	4	3.4	4.6	3.5	4.2
Y	5	9.5	6	10	5.5	7.7	7.2	9	7	8.6

O modelo proposto para a relação existente entre as variáveis é: $Y = \beta_0 + \beta_1 X + u$.

- Estime e interprete β_0 e β_1 . Quanto se espera que as vendas aumentem, caso se gastem mais €3 em publicidade?
- Represente graficamente os valores observados, bem como a reta estimada.

- c) Calcule o valor do resíduo para cada observação, bem como a média de todos os resíduos.
- d) Que proporção da variação das vendas destas 10 empresas é explicada pela publicidade? Justifique.
- e) Qual o valor das vendas previsto para uma empresa que gaste €5,20 em publicidade?

2.5 Use os dados em SONO.DTA para estudar se existe um “trade-off” entre o tempo passado a dormir por semana e o tempo passado em trabalho pago. Qualquer das variáveis poderia ser usada como independente. Para concretizar, estime o modelo

$$sono = \beta_0 + \beta_1 trab + u$$

onde *sono* é o tempo de sono noturno semanal, em minutos, e *trab* é o tempo de trabalho semanal, em minutos.

- a) Apresente a equação estimada, juntamente com o número de observações e o R^2 . O que é que significa o termo constante nesta equação?
- b) Represente graficamente os valores observados e os valores previstos.
- c) Se trabalharmos mais 2 horas por semana, em quanto se estima que diminua o tempo semanal de sono? O que pensa da magnitude deste efeito?

2.6 Certo investigador recolheu uma amostra de 5 pares de valores (X_i, Y_i) e estimou uma recta cuja equação é:

$$\hat{Y}_i = 10 - 2X_i$$

Mais tarde, querendo estimar outro modelo, procurou os dados originais e verificou que apenas tinha a seguinte informação:

$$X_1 = 2; \quad X_2 = 3; \quad X_3 = 5; \quad X_4 = 4; \quad X_5 = 1.$$

$$\hat{u}_1 = -1; \quad \hat{u}_2 = ?; \quad \hat{u}_3 = 0; \quad \hat{u}_4 = ?; \quad \hat{u}_5 = 0.$$

Recordando as propriedades algébricas dos estimadores dos mínimos quadrados, recupere os valores de Y_i .

2.7 Considere os seguintes pares de observações, relativos às variáveis X e Y :

Y	8	6	1	2	4
X	2	1	0	3	4

O modelo proposto é da forma: $Y = \beta_0 + \beta_1 X + u$. Usando o método dos mínimos quadrados, sem recorrer a software, estime:

- a) Os parâmetros β_0 e β_1 .
- b) A soma de quadrados residuais.
- c) A variância do erro.
- d) A variância de $\hat{\beta}_0$ e a variância de $\hat{\beta}_1$.

e) O coeficiente de determinação.

2.8 Um estudo das colheitas de 7 agricultores forneceu os seguintes resultados, onde Y é a produção em toneladas e X é a quantidade de chuva medida em mm por período de colheita:

$$\text{Colheita A: } \hat{Y} = 200 + 0.8X ; \hat{\sigma}^2 = 30; R^2 = 0.49$$

$$\text{Colheita B: } \hat{Y} = 500 + 1.2X ; \hat{\sigma}^2 = 20; R^2 = 0.81$$

- Se no período em causa a chuva fosse de $95mm$, qual das colheitas lucraria mais com a existência de chuva? Indique sucintamente as bases da sua resposta.
- Para qual das duas colheitas se poderá prever a produção com maior rigor? Porquê?
- Estime $\text{Var}(\hat{\beta}_1)$ para a colheita A.

3. O Modelo de Regressão Linear Múltipla

3.1 Considere a seguinte regressão estimada, referente a trabalhadores do sexo masculino:

$$\widehat{educ} = 10.36 - 0.094 \textit{irmaos} + 0.131 \textit{educm} + 0.210 \textit{educp}; n = 722; R^2 = 0.214$$

onde *educ* são os anos de escolaridade, *irmaos* é o número de irmãos e *educm* e *educp* são o número de anos de escolaridade da mãe e do pai, respetivamente.

- O efeito de *irmaos* é o esperado? Explique. Mantendo *educm* e *educp* constantes, quanto é que o número de irmãos deve aumentar para que a educação prevista se reduza um ano? (É aceitável um número não inteiro.)
- Discuta a interpretação do coeficiente de *educm*.
- Suponha que o André não tem irmãos, e que os seus pais têm ambos 12 anos de escolaridade. O Bento também não tem irmãos, e os seus pais têm ambos 16 anos de escolaridade. Qual a diferença prevista nos anos de educação do Bento e do André?

3.2 O modelo seguinte é uma versão simplificada do modelo de regressão múltipla de Biddle e Hamermesh (1990) para estudar o “trade-off” entre o tempo passado a dormir e a trabalhar e para analisar outros fatores que afectam o sono:

$$\textit{sono} = \beta_0 + \beta_1 \textit{trab} + \beta_2 \textit{educ} + \beta_3 \textit{idade} + u,$$

onde *sono* e *trab* são medidos em minutos por semana e *educ* e *idade* em anos.

- Se os adultos renunciam a sono em troca de trabalho, qual é o sinal de β_1 ?
- Que sinais acha que β_2 e β_3 irão ter?
- Com base nas estimativas abaixo apresentadas, preveja quantos minutos de sono irá perder alguém que decida trabalhar mais 5 horas por semana.

$$\widehat{\textit{sono}} = 3638.25 - 0.148 \textit{trab} - 11.13 \textit{educ} + 2.20 \textit{idade}; n = 706; R^2 = 0.113$$

- Discuta o sinal e a magnitude do coeficiente de *educ*.
- Diria que o trabalho, a educação e a idade explicam muita da variação no sono? Que outros fatores poderiam afetar o tempo passado a dormir? Estarão esses fatores provavelmente correlacionados com o trabalho?

3.3 Com base numa amostra de 55 observações e no modelo abaixo apresentado, obtiveram-se os seguintes resultados:

$$Y_i = \beta_0 + \beta_1 X_{i1} + \beta_2 X_{i2} + u_i$$

$$(X'X)^{-1} = \begin{bmatrix} 2.1 & -0.15 & -0.05 \\ -0.15 & 0.1 & -0.04 \\ -0.05 & -0.04 & 0.01 \end{bmatrix} \quad X'Y = \begin{bmatrix} 74 \\ 282 \\ 375 \end{bmatrix} \quad YY=4019.75$$

- Estime os coeficientes de regressão.
- Comente o ajustamento do modelo.

3.4 Use os dados em PRECASA.DTA para estimar o modelo

$$preco = \beta_0 + \beta_1 area + \beta_2 quartos + u$$

onde o preço de uma casa, em 10^3 dólares, depende da área (m^2) e do número de quartos.

- Escreva os resultados na forma de equação, incluindo n e R^2 .
- Qual o aumento previsto no preço de uma casa com mais um quarto, mantendo a área constante?
- Qual o aumento estimado no preço de uma casa com um quarto adicional de $13m^2$ de tamanho? Compare a resposta com b).
- A primeira casa da amostra tem uma área de $226m^2$ e 4 quartos. Encontre o preço de venda previsto para esta casa a partir da reta de regressão dos mínimos quadrados.
- O preço de venda verificado para a primeira casa da amostra foi de 300 mil dólares. Encontre o resíduo para esta casa. O valor deste sugere que o comprador fez um bom ou um mau negócio?

3.5 Considere que as vendas (em quantidade) de um determinado tipo de cigarros (Y) são função do preço (X_1) e dos gastos em publicidade (X_2), podendo a relação ser expressa por um modelo de regressão linear. Foram obtidos os seguintes dados, em euros, referentes a 10 empresas:

Y	80	100	110	120	90	85	70	105	95	115
X_1	2	1	1	2	1.2	1.5	1.5	2	2.5	2
X_2	25	30	40	45	30	20	30	60	50	60

- Estime os coeficientes da regressão de Y sobre X_1 , bem como o erro padrão da regressão e o R^2 . O que pensa da estimativa de β_1 ?
- Estime a regressão de Y sobre X_1 e X_2 , e compare os resultados com a).
- Qual o montante previsto de vendas de cigarros para uma empresa que pratique um preço de venda e tenha gastos em publicidade iguais aos valores médios da amostra?

3.6 Num estudo que relaciona a média das classificações de alunos universitários com o tempo passado em várias atividades, foi distribuído um inquérito a vários estudantes. Perguntou-se quantas horas eles passavam por semana em quatro atividades: estudo, sono, trabalho e lazer. Dado que estas categorias esgotam o tempo disponível, a soma das horas passadas nas quatro atividades, para cada estudante, deve ser 168. O modelo proposto foi:

$$média = \beta_0 + \beta_1 estudo + \beta_2 sono + \beta_3 trabalho + \beta_4 lazer + u$$

- No modelo acima, faz sentido manter constantes *sono*, *trabalho*, e *lazer*, enquanto se altera o *estudo*?
- Por que razão este modelo viola a premissa da ausência de colinearidade perfeita?
- Como é que o modelo poderá ser reformulado de forma a que satisfaça a premissa indicada em b) e os parâmetros tenham uma interpretação útil?

3.7 Suponha que as seguintes observações são o resultado da medição da produção agrícola (Y) obtida em várias parcelas de terra, para cada nível de adubo (X):

X	Y			
1	2	3	1	
2	4	1	5	
3	5	6		
4	2	1	3	2

O modelo proposto é $Y_i = \beta_0 + \beta_1 X_i + \beta_2 X_i^2 + u_i$.

- Estime a função de produção, e comente a diferença entre este tipo de dados e os usualmente obtidos na análise económica empírica.
- Encontre o efeito na produção prevista de se usar mais uma unidade de adubo e preveja a produção máxima que é possível obter.
- Esboce um gráfico para a produtividade marginal e a produtividade média estimadas. (Inclua explicitamente o ponto de interseção entre as duas linhas.)

3.8 Admita a seguinte função de Custo: $C_i = \alpha Q_i^\beta$.

- Mostre que β é a elasticidade do custo em ordem à produção.
- Construa o modelo de regressão linear adequado para obter estimativas de α e β e calcule-as, com base na amostra seguinte:

C_i	8	28	70	52	32
Q_i	2	4	6	5	4

3.9 Use os dados de SAL.DTA para este exercício.

- Estime a equação $sal = \beta_0 + \beta_1 educ + \beta_2 exper + \beta_3 antig + u$, calcule os resíduos e represente graficamente um histograma.
- Repita a), mas com $\ln(sal)$ como variável dependente.
- Com qual dos modelos anteriores lhe parece que o pressuposto da normalidade do erro está mais próximo de ser satisfeito?

3.10 Considere o modelo $\ln(Y_i) = \beta_0 + \beta_1 \ln(X_{i1}) + \beta_2 X_{i2} + u_i$ e os dados do exercício 3.5.

- Demostre teoricamente que se os valores de Y e X_1 forem multiplicados pelas constantes c e d , respectivamente, apenas o valor de β_0 se alterará.
- Comprove a alínea anterior estimando o modelo quer com os dados originais quer após alteração das unidades de medida, com $c = 2$ e $d = 10$.

3.11 Considere o modelo $Y_i = \beta_0 + \beta_1 X_{i1} + \beta_2 X_{i2} + u_i$ e o conjunto de observações:

X_1	-1	2	0	2	2
X_2	1	-1	-2	1	1
Y	2	6	5	6	6

- Estime a regressão de Y sobre X_1 e X_2 .
- Estime o modelo estandardizado $z_{iY} = \beta_0 + \beta_1 z_{i1} + \beta_2 z_{i2} + z_{iu}$, onde $z_{iY} = \frac{Y_i - \bar{Y}}{S_Y}$ e $z_{ij} = \frac{X_{ij} - \bar{X}_j}{S_{X_j}}$, $j = 1, 2$, sendo S_Y e os S_{X_j} 's desvios padrão amostrais.
- Mostre como a partir do modelo estimado em b) poderia obter as estimativas encontradas em a).
- Multiplique os valores de X_1 por 10 e volte a resolver as alíneas a) e b). Compare os resultados obtidos ao nível dos coeficientes estimados e do R^2 .

4. Inferência e Previsão

4.1 A variável ID é a despesa em investigação e desenvolvimento (I&D) como percentagem das vendas. As vendas estão medidas em milhões de dólares. A variável $mglucro$ representa os lucros como percentagem das vendas. Usando dados de 32 empresas da indústria química, foi estimada a seguinte equação (por baixo de cada coeficiente, entre parênteses, é dada a estimativa do respectivo desvio-padrão):

$$ID = 0.472 + 0.321 \ln(vendas) + 0.050mglucro; \quad n = 32; \quad R^2 = 0.099$$

(1.369) (0.216) (0.046)

- Interprete o coeficiente de $\ln(vendas)$. Em particular, se as vendas aumentam 10%, qual a variação em pontos percentuais estimada para ID ? Trata-se de um efeito elevado em termos económicos?
- Teste a hipótese de que a intensidade de I&D não se altera com as vendas, contra a alternativa de que aumenta com as vendas. Faça o teste usando um nível de significância de 5%.
- A variável $mglucro$ tem um efeito estatisticamente significativo em ID ?

4.2 Reconsidere o Exercício 3.4, baseado nos dados do ficheiro PRECASA.DTA. Use agora o logaritmo natural do preço da habitação como variável dependente, ou seja, $\ln(preco) = \beta_0 + \beta_1 area + \beta_2 quartos + u$.

- Estime o modelo.
- Considerando um nível de significância de 5%, teste as seguintes hipóteses: $H_0: \beta_1 = 0.1$; $H_0: \beta_2 = 0$
- Calcule intervalos de confiança a 95% para β_1 e β_2 .
- Estime a variação percentual que ocorre no preço da habitação quando um quarto de $14m^2$ é acrescentado a essa habitação.
- Determine o erro padrão da variação calculada na alínea anterior.
- Use o erro padrão calculado em e) para estimar um intervalo de confiança a 95% para a variação calculada em d).

4.3 A análise de regressão pode ser usada para testar se o mercado usa de forma eficiente a informação na avaliação das ações. Seja y a rentabilidade da ação, ou rendimento total obtido por guardar uma ação de uma empresa no período de quatro anos desde o final de 1990 ao final de 1994. A hipótese dos mercados eficientes diz que essas rentabilidades não devem estar sistematicamente relacionados com informação conhecida em 1990. Se as características da empresa conhecidas no princípio do período ajudarem a prever a rentabilidade da ação, então essa informação pode ser usada na escolha dos ativos. Seja rdk o rácio da dívida pelo capital da empresa, ga os ganhos por ação, $rendliq$ o rendimento líquido, sal a remuneração total do executivo. Para 1990 foi estimada a seguinte equação:

$$\hat{y} = -14.37 + 0.321rdk + 0.043ga - 0.0051rendliq + 0.0035sal; \quad n = 142; \quad R^2 = 0.0395$$

(6.89) (0.201) (0.078) (0.0047) (0.0022)

- Teste se as variáveis explicativas são conjuntamente significativas ao nível de 5%. Verifique também se alguma variável explicativa é individualmente significativa.

- b) O modelo foi reestimado usando a forma logarítmica para *rendliq* e *sal*, com os resultados abaixo indicados. Alguma das conclusões obtidas em a) se altera?

$$\hat{y} = -36.30 + 0.327 rdk + 0.069 ga - 4.74 \ln(\text{rendliq}) + 7.24 \ln(\text{sal}); n = 142; R^2 = 0.033$$

(39.37)
(0.203)
(0.080)
(3.39)
(6.31)

- c) Porque é que não se usaram logaritmos de *rdk* e *ga* em b)?
d) No conjunto, a evidência de previsibilidade da rentabilidade das ações é fraca ou forte?

4.4 Numa análise de dados em que se usou o modelo abaixo indicado e a amostra de (3.3), alargada com a inclusão de observações de duas novas variáveis, obtiveram-se os seguintes resultados:

$$Y_i = \beta_0 + \beta_1 X_{1i} + \beta_2 X_{2i} + \beta_3 X_{3i} + \beta_4 X_{4i} + u_i$$

$$(X'X)^{-1} = \begin{bmatrix} 1.9 & -0.1 & -0.03 & 0.05 & -0.08 \\ -0.1 & 0.05 & -0.01 & -0.02 & 0.03 \\ -0.03 & -0.01 & 0.07 & -0.04 & -0.03 \\ 0.05 & -0.02 & -0.04 & 0.01 & 0.02 \\ -0.08 & 0.03 & -0.03 & 0.02 & 0.01 \end{bmatrix} \quad X'y = \begin{bmatrix} 74 \\ 282 \\ 375 \\ 450 \\ 250 \end{bmatrix}$$

$N=55$ $y'y=4019.75$

- a) Estime os coeficientes do modelo e escreva a equação de regressão, colocando por baixo de cada coeficiente a estimativa do respetivo desvio padrão.
b) Teste a hipótese de que $0.5\beta_2 - 2\beta_3 = 12$, ao nível de significância de 5%.
c) Calcule e interprete o coeficiente de determinação, R^2 .
d) Teste a hipótese de que o modelo não se ajusta aos dados, ao nível de 5%.
e) Use um teste que lhe permita inferir qual dos dois modelos, (4.4) ou (3.3), se ajusta melhor aos dados.

4.5 Considere os seguintes resultados de uma regressão estimada:

$$\hat{Y}_i = 6 + X_{i1} - X_{i2} + 2X_{i3}$$

$$\bar{Y} = 6; \quad y'y = 360; \quad y'X = [54 \quad 6 \quad -4 \quad 4]$$

- a) Qual a percentagem da variação em Y que é explicada pelo modelo?
b) Será que o valor obtido em a) é significativamente diferente de zero, a um nível de 5%? Ou seja, poder-se-á considerar que o modelo como um todo se ajusta aos dados?

4.6 Numa análise de regressão linear simples foram obtidos, a partir de uma amostra de 6 pares de valores de X e Y , os seguintes resultados: $R^2 = 0.64$, $S_x = 3$ e $S_y = 5$, sendo estes últimos os desvios padrão das variáveis X e Y na amostra.

- Determine o intervalo de confiança a 95% para β_1 , sabendo que Y é uma função crescente de X .
- Teste ao nível de significância de 5% a hipótese $H_0: \beta_1 = 0$ contra $H_1: \beta_1 \neq 0$; compare com a).

4.7 Considere a seguinte função de produção, em que Q é a quantidade produzida, K representa o factor produtivo capital e L o factor trabalho:

$$Q_i = \alpha L_i^{\beta_1} K_i^{\beta_2} e^{u_i}$$

Os resultados da estimação do logaritmo natural dessa função de produção (incluindo os erros padrão das estimativas por baixo das mesmas) são:

$$\hat{Y}_i = ? + \underset{(0.257)}{0.632} X_{1i} + \underset{(0.219)}{0.452} X_{2i}, \quad n = 20, \quad R^2 = 0.98 \quad X'Y = \begin{bmatrix} 88 \\ 240 \\ 214.4 \end{bmatrix}$$

$$\text{Cov}(\hat{\beta}_1, \hat{\beta}_2) = 0.055, \quad \bar{X}_1 = 2.56, \quad \bar{X}_2 = 2.1$$

- Obtenha uma estimativa para α .
- Teste a hipótese de que as elasticidades relativas ao capital e ao trabalho são idênticas.
- Elabore um quadro de análise de variância para o modelo transformado.

4.8 De um estudo em que se utilizou o modelo $Y_i = \beta_0 + \beta_1 X_{1i} + \beta_2 X_{2i} + u_i$ conhecem-se os seguintes resultados:

$$n = 6 \qquad \hat{\beta}_1 = 3.5716 \qquad \hat{\beta}_2 = 4.204$$

$$(X'X)^{-1} = \begin{bmatrix} 2.078 & -0.224 & -0.286 \\ ? & ? & ? \\ ? & ? & 0.051 \end{bmatrix} \quad X'Y = \begin{bmatrix} 231 \\ 760 \\ 1050 \end{bmatrix} \quad Y'Y = 11050.098$$

- Calcule $\hat{\beta}_0$ e os valores assinalados com “?”.
- Apresente um quadro de análise de variância para o modelo.

4.9 Para estudar a racionalidade da avaliação dos preços das casas, propõe-se o modelo

$$preco = \beta_0 + \beta_1 aval + u$$

sendo a avaliação racional se $\beta_1 = 1$ e $\beta_0 = 0$. A equação estimada é:

$$prêco = -14.47 + \underset{(16.27)}{0.976} aval; \quad n = 88; \quad SQR = 165645; \quad R^2 = 0.82$$

- Teste separadamente as hipóteses $H_0: \beta_0 = 0$ e $H_0: \beta_1 = 1$. Que conclui?

- b) Considerando agora a hipótese conjunta $H_0: \beta_0 = 0$ e $\beta_1 = 1$, verifique que a SQR do modelo restringido é $\sum (preco_i - aval_i)^2$. Sendo este valor $SQR^* = 209449$, teste a hipótese indicada.
- c) Teste agora $H_0: \beta_2 = 0, \beta_3 = 0$ e $\beta_4 = 0$ no modelo

$$preco = \beta_0 + \beta_1 aval + \beta_2 area + \beta_3 lote + \beta_4 quartos + u$$

o qual foi estimado com as mesmas 88 casas, obtendo-se $R^2 = 0.829$.

4.10 Use os dados de PRECASA.DTA para estimar o modelo

$$preco = \beta_0 + \beta_1 lote + \beta_2 area + \beta_3 quartos + u$$

- a) Estime os coeficientes do modelo e o erro padrão da regressão e preveja o preço de uma casa construída num lote de $1000m^2$, com $230m^2$ de área e 4 quartos.
- b) Estime um intervalo de confiança a 95% para o valor previsto em a).

5. Notas sobre Teoria Assimptótica

5.1 Considere os dados em PESO.DTA e o seguinte modelo para explicar o peso à nascença:

$$peso = \beta_0 + \beta_1 cigs + \beta_2 ordn + \beta_3 rend + \beta_4 educm + \beta_5 educp + u$$

onde *peso* é o peso à nascença, *cigs* é o número médio de cigarros fumados pela mãe durante a gravidez, *ordn* é a ordem de nascimento da criança, *rend* é o rendimento anual familiar, *educm* e *educp* são o número de anos de escolaridade da mãe e do pai, respetivamente. Usando o teste *F* e o teste do multiplicador de Lagrange (*LM*):

- a) Teste a hipótese de que, após ter em conta os outros fatores, a educação dos pais não tem efeito no peso do bebé à nascença.
- b) Teste a significância global do modelo.

6. Análise da Especificação do Modelo

6.1 A equação seguinte descreve o preço mediano da habitação em função do montante de poluição (*nox*, óxido de nitrogénio) e do número médio de quartos nas casas de uma comunidade (*quartos*):

$$\ln(\widehat{preco}) = \beta_0 + \beta_1 \ln(nox) + \beta_2 \text{quartos} + u$$

- Quais os sinais prováveis de β_1 e β_2 ? Qual a interpretação de β_1 ? Explique.
- Porque é que *nox* (mais precisamente, o seu logaritmo) e *quartos* poderão estar negativamente correlacionadas? Se assim for, a regressão simples de $\ln(\widehat{preco})$ sobre $\ln(nox)$ produzirá um estimador de β_1 enviesado para cima ou para baixo?
- Após recolher os dados necessários foram estimadas as seguintes equações:

$$\ln(\widehat{preco}) = 11.71 - 1.043 \ln(nox); \quad n = 506; \quad R^2 = 0.264;$$

$$\ln(\widehat{preco}) = 9.23 - 0.718 \ln(nox) + 0.306 \text{quartos}; \quad n = 506; \quad R^2 = 0.514.$$

A relação entre as estimativas da elasticidade do preço em relação a *nox* na regressão simples e na regressão múltipla é aquela que teria previsto, dada a sua resposta em b)? Isto quer dizer que (-0.718) está certamente mais próxima da verdadeira elasticidade que (-1.043)?

6.2 Para explicar o salário dos executivos (*sal*) usou-se o modelo

$$\ln(\widehat{sal}) = \beta_0 + \beta_1 \ln(vendas) + \beta_2 \text{valmerc} + \beta_3 \text{mglucro} + \beta_4 \text{ase} + \beta_5 \text{ast} + u$$

onde *valmerc* é o valor de mercado da empresa, *mglucro* é o lucro como percentagem das vendas, *ase* os anos de serviço como executivo na empresa atual e *ast* os anos de serviço totais na empresa atual. A estimação deste modelo pelo método dos mínimos quadrados, com $n = 177$, forneceu um R^2 de 0.353. Quando ase^2 e ast^2 são adicionadas, obtém-se $R^2 = 0.375$. Há evidência de má especificação da forma funcional do modelo apresentado?

6.3 Considere os dados de PRECASA.DTA e os modelos

$$(1) \widehat{preco} = \beta_0 + \beta_1 \text{lote} + \beta_2 \text{area} + \beta_3 \text{quartos} + u$$

$$(2) \widehat{preco} = \beta_0 + \beta_1 \text{lote} + v$$

$$(3) \widehat{preco} = \beta_0 + \beta_1 \ln(\text{lote}) + \beta_2 \ln(\text{area}) + \beta_3 \text{quartos} + w$$

- Através de testes e critérios apropriados, verifique qual dos modelos é mais adequado para explicar a variação no preço da habitação.
- Verifique se a forma funcional do modelo que selecionou na alínea anterior foi especificada corretamente, usando o teste RESET (versão F).
- Repita a alínea anterior mas usando a versão LM do teste RESET.

7. Modelo de Regressão Linear com Variáveis Explicativas Qualitativas

7.1 Pretende-se estudar as diferenças ao nível do salário (*salario*) mensal entre quatro grupos de indivíduos: homens licenciados (*HL*), mulheres licenciadas (*ML*), homens não licenciados (*HNL*) e mulheres não licenciadas (*MNL*). A partir de uma mostra de 498 observações, obteve-se o seguinte modelo estimado:

$$\ln(\widehat{\text{salario}}) = \underset{(0.100)}{0.321} + \underset{(0.055)}{0.213HL} + \underset{(0.058)}{0.148ML} - \underset{(0.054)}{0.110MNL} - \underset{(0.070)}{0.079casado} + \underset{(0.006)}{0.027exper}$$

onde *HL*, *ML* e *MNL* são variáveis *dummy* que indicam se o indivíduo pertence ao grupo referido (=1) ou não (=0), *casado* é outra variável *dummy* que indica se o indivíduo é casado (=1) ou não (=0) e *exper* representa o número de anos de experiência profissional.

- Interprete os coeficientes estimados.
- Indique como poderia testar se existe discriminação sexual no mercado dos trabalhadores licenciados.
- Usando um nível de significância de 5%, verifique se existe discriminação sexual no mercado dos trabalhadores não licenciados.
- Comente a seguinte afirmação: “Um trabalhador do sexo masculino, casado, com o 12º ano de escolaridade ganha significativamente menos que um trabalhador do mesmo sexo e com a mesma experiência, solteiro, com a 4ª classe”.

7.2 Considere o seguinte modelo para comparar os resultados de três métodos de ensinos diferentes:

$$Y = \delta_1 X_1 + \delta_2 X_2 + \delta_3 X_3 + u$$

onde *Y* é a classificação obtida pelo aluno num teste e

$$X_j = \begin{cases} 1 & \text{se foi usado o método } j \\ 0 & \text{caso contrário} \end{cases},$$

$j = 1, 2, 3$. Para cada método de ensino foram obtidas as classificações de n_j alunos, $j = 1, 2, 3$, sendo $n_1 + n_2 + n_3 = n$.

- De acordo com a informação dada escreva teoricamente as matrizes Y , X , $X'X$ e $X'Y$.
- Mostre que o vetor das estimativas dos mínimos quadrados é $\hat{\delta} = (\bar{Y}_1, \bar{Y}_2, \bar{Y}_3)'$.
- Com base no modelo estimado abaixo apresentado (onde os erros padrão estão entre parênteses) teste a hipótese de que os alunos submetidos aos métodos 2 e 3 obtêm em média os mesmos resultados.

$$\hat{Y} = \underset{(2.18)}{10.55}X_1 + \underset{(3.21)}{12.86}X_2 + \underset{(4.11)}{13.67}X_3; \quad n = 63$$

7.3 Os dados em SONO.DTA referem-se ao modelo

$$sono = \beta_0 + \beta_1 trab + \beta_2 educ + \beta_3 idade + \beta_4 idade^2 + \beta_5 filpeq + u$$

com $filpeq = 1$ se tem filhos pequenos, e $masc = 1$ se é do sexo masculino.

- a) Estime a equação separadamente para homens e mulheres. Há diferenças substanciais?
- b) Estime o modelo

$$sono = \beta_0 + \beta_1 trab + \beta_2 educ + \beta_3 idade + \beta_4 idade^2 + \beta_5 filpeq + \gamma_0 masc + \gamma_1 masc \cdot trab + \gamma_2 masc \cdot educ + \gamma_3 masc \cdot idade + \gamma_4 masc \cdot idade^2 + \gamma_5 masc \cdot filpeq + v$$

e compare os resultados obtidos com os da alínea anterior.

- c) Faça o teste de Chow para a igualdade dos parâmetros nas equações para ambos os sexos de duas maneiras diferentes (nível de significância: 10%).
- d) Permita agora diferenças no termo independente para homens e mulheres, e teste se os termos de interação que envolvem $masc$ são conjuntamente significativos.
- e) Dados os resultados de c) e d), qual seria o seu modelo final?
- f) Use o modelo escolhido em e) para prever quanto dorme em média por noite uma mulher de 30 anos, com o 12.º ano de escolaridade, que trabalha 8 horas por dia (de 2.ª a 6.ª) e tem 2 filhos pequenos. Comente.

8. Heterocedasticidade

8.1 Considere um modelo linear para explicar o consumo mensal de cerveja:

$$\begin{aligned} \text{cerveja} &= \beta_0 + \beta_1 \text{rend} + \beta_2 \text{preco} + \beta_3 \text{educ} + \beta_4 \text{fem} + u \\ E(u|\text{rend}, \text{preco}, \text{educ}, \text{fem}) &= 0 \\ \text{Var}(u|\text{rend}, \text{preco}, \text{educ}, \text{fem}) &= \sigma^2 \text{rend}^2 \end{aligned}$$

Escreva a equação transformada que tenha um erro homoscedástico.

8.2 Use os dados em PRECASA.DTA para este exercício.

- Estime o modelo $\text{preco} = \beta_0 + \beta_1 \text{lote} + \beta_2 \text{area} + \beta_3 \text{quartos} + u$, calculando os erros padrão usuais e os robustos à heteroscedasticidade. Discuta quaisquer diferenças importantes entre eles.
- Repita a) para o modelo $\ln(\text{preco}) = \beta_0 + \beta_1 \ln(\text{lote}) + \beta_2 \ln(\text{area}) + \beta_3 \text{quartos} + u$.
- O que é que este exemplo sugere sobre a heteroscedasticidade e a transformação usada na variável dependente?

8.3 Use os dados de SONO.DTA para estimar a seguinte equação do sono:

$$\text{sono} = \beta_0 + \beta_1 \text{trab} + \beta_2 \text{educ} + \beta_3 \text{idade} + \beta_4 \text{idade}^2 + \beta_5 \text{filpeq} + \beta_6 \text{masc} + u$$

- Escreva uma equação para a heteroscedasticidade que permita que a variância de u seja diferente para homens e mulheres, sem depender de outros fatores.
- Estime os parâmetros da equação anterior. [Terá que estimar a equação do *sono* primeiro para obter os resíduos dos mínimos quadrados.] A variância estimada de u é maior para homens ou para mulheres?
- A variância de u é estatisticamente diferente para homens e mulheres?

8.4 Sabendo que o investimento de uma empresa (Y) depende do seu volume de vendas (X) pretende-se ajustar o modelo:

$$Y_i = \beta_0 + \beta_1 X_i + u_i, \quad i = 1, 2, \dots, 9 \text{ empresas.}$$

Após estimar o modelo pelo método dos mínimos quadrados, e admitindo poder haver problemas com a utilização deste método, estimou-se posteriormente a seguinte regressão auxiliar:

$$\hat{u}_i^2 = 0.0118 + 0.0603X_i; \quad n = 9; \quad R^2 = 0.0658$$

- Qual lhe parece ter sido a razão que levou o investigador a realizar a regressão auxiliar? De acordo com os resultados obtidos pensa ser o método dos mínimos quadrados o melhor para a estimação do modelo?

- b) Admitindo que a variância do erro é proporcional ao volume de vendas, ou seja $\text{Var}(u_i|X_i) = \sigma^2 X_i$, use um método de estimação alternativo, considerando os seguintes valores para X e Y :

Y	1	3	2	4	3	5	4	4	4
X	1	5	3	7	8	9	6	5	7

8.5 Para o modelo usado em 8.2.b) calcule sucessivamente as versões F e LM , bem como os valores- p , dos testes:

- Breusch-Pagan;
- White;
- White, caso especial.

9. Problemas com os Dados

9.1 Considere os seguintes dados:

Y	80	100	110	120	90	85	70	105	95	115
X ₁	2	1	1	2	1.2	1.5	1.5	2	2.5	2
X ₂	25	30	40	45	30	20	30	60	50	60
X ₃	2.5	2	5	4	3	1.5	3.5	5	5.5	6

- Efectue a regressão de Y nas restantes variáveis.
- Suspeita-se que exista multicolineariedade neste modelo. Usando o critério VIF, verifique se há fundamento para esta suspeita.

9.2 Considere os dados em ANSCOMBE.DTA para este exercício.

- Confirme que as variáveis $Y_j, j = 1, 2, 3, 4$, por um lado, e as variáveis $X_j, j = 1, 2, 3, 4$, por outro lado, têm a mesma média e desvio-padrão amostrais.
- Estime os seguintes modelos, guardando os valores estimados de Y_j e confirmando que em todos os casos $\hat{\beta}_0 = 3, \hat{\beta}_1 = 0.5$ e $R^2 = 0.67$:

$$Y_1 = \beta_0 + \beta_1 X_1 + u_1$$

$$Y_2 = \beta_0 + \beta_1 X_2 + u_2$$

$$Y_3 = \beta_0 + \beta_1 X_3 + u_3$$

$$Y_4 = \beta_0 + \beta_1 X_4 + u_4$$

- Represente graficamente os valores observados e os valores estimados e comente os resultados obtidos.
- Reestime o segundo modelo adicionando a variável X_2^2 ao modelo.
- Reestime o terceiro modelo omitindo a observação outlier.