

Exercícios de Inferência Estatística

Apresenta-se a resolução de alguns exercícios enunciados nas folhas de prática -
Capítulo 3. Tem-se ainda propostas de novos exercícios e respectivas resoluções.
Os últimos são aplicação do teste de ajustamento do qui-quadrado

1. (Ex. 3.27) Resolução

Trata-se de amostras emparelhadas (as medições são feitas nos mesmos pontos do rio).

Considere-se as variáveis X - medições antes da campanha e Y - medições depois da campanha

Sendo amostras emparelhadas o estudo é feito sobre a amostra aleatória das diferenças $D_i = X_i - Y_i$. Como se pretende saber se a campanha reduziu a poluição deve fazer-se um teste à média das diferenças, μ_D , isto é pretende-se averiguar se pode considerar-se $\mu_D > 0$.

Como $n = 10$ é pequeno e a variância σ_D^2 é desconhecida é necessária a verificação do pressuposto da normalidade da v.a. D .

Começemos então pelo estudo da normalidade - vamos aplicar o **Teste de Shapiro-Wilk**. As hipóteses a formular são

$$H_0 : X \sim \text{Normal} \quad H_1 : X \not\sim \text{Normal}$$

Veja-se de seguida a resolução do exercício no 

```
> x<-c(68,88,101,82,96,74,65,74,52,99)
> y<-c(67,87,90,76,98,69,68,65,59,70)
> d<-x-y;d
[1] 1 1 11 6 -2 5 -3 9 -7 29
> shapiro.test(d)
```

Shapiro-Wilk normality test

```
data: d
W = 0.8781, p-value = 0.1240
```

Tem-se $p\text{-value} > 0.05$, portanto não se rejeita H_0 , isto é não podemos rejeitar a hipótese da normalidade da v.a. D .

Vejamos agora os passos na realização do teste para verificarmos se a campanha reduziu de facto a poluição:

1. **Hipóteses:** $H_0 : \mu_D \leq 0$ $H_1 : \mu_D > 0$
 $\alpha = 0.05$

2. Estatística de teste: $T = \frac{\bar{D} - \mu_D}{S_D / \sqrt{n}} \sim t_{(n-1)}$, se a hipóteses H_0 verdadeira.

3. Região Crítica: Rejeita-se H_0 se $T_{calc} > t_{\alpha, (n-1)} = t_{0.05, (9)}$

$$R.C. : T_{calc} > 1.8333$$

4. Cálculo da Estatística de teste:

Tem-se $\bar{d} = 5$ e $s_d = 10.10$

$$T_{calc} = \frac{\bar{d} - 0}{s_d / \sqrt{n}} = 1.5655,$$

5. Conclusão: Como $T_{calc} \notin R.C$ não rejeitamos H_0 a um nível de significância de 5%, isto é, não há motivos para acreditar que a campanha tenha reduzido a poluição.

Também podemos resolver este exercício no \mathbb{R} , para as hipóteses formuladas em **1.**, bastando usar o comando:

```
> t.test(x,y,paired=T,alternative="greater")
```

```
Paired t-test
```

```
data: x and y
```

```
t = 1.5656, df = 9, p-value = 0.07595
```

```
alternative hypothesis: true difference in means is greater than 0
```

```
95 percent confidence interval:
```

```
-0.8544932      Inf
```

```
sample estimates:
```

```
mean of the differences
```

```
5
```

As etapas **2**, **3** e **4** apresentadas atrás são substituídas pelo cálculo de *p-value*. Vemos que *p-value* = 0.07595, portanto superior ao valor habitual de $\alpha = 0.05$, logo não rejeitamos H_0 , então não há motivos para acreditar que a campanha tenha reduzido a poluição.

2. (Ex. 3.30) A resolução deste exercício vai ser apoiada no *output* do \mathbb{R} apresentado. Vamos ver como o podemos usar.

a) Seja X_1 - v.a. que representa a acidez total do vinho, determinada pelo método clássico; pretende-se averiguar se em média a acidez total é superior a 3.5 g/l, i.e., sendo $\mu_1 = E[X_1]$, devemos realizar o teste de hipóteses:

$$H_0: \mu_1 \leq 3.5 \text{ vs. } H_1: \mu_1 > 3.5.$$

Observe-se que estamos em presença de uma amostra de dimensão pequena com variância populacional desconhecida, por isso (validados certos pressupostos) devemos usar o teste apresentado no comando do \mathbb{R}

```
t.test(classico,mu=3.5,alternative="greater").
```

Os pressupostos para a realização deste teste são:

- garrafas seleccionadas aleatoriamente,
- X_1 ter distribuição normal.

Vamos verificar a hipótese da normalidade

H_0 : X_1 tem distribuição normal vs. H_1 : X_1 não tem distribuição normal usando o teste de Shapiro-Wilk.

No \mathbb{R} o teste é efectuado com o comando `shapiro.test(classico)`.

Vemos que $p\text{-value} = 0.3827$, que é um valor elevado, pelo que não se rejeita a hipótese da normalidade.

Passemos agora à análise do resultado da aplicação do comando

`t.test(classico,mu=3.5,alternative="greater")`.

Tem-se $p\text{-value} = 0.1255$, que é um valor superior ao nível de significância $\alpha = 0.05$ (habitualmente considerado). Logo não se rejeita a hipótese nula e portanto não se pode concluir que o vinho cumpra os requisitos ($\mu_1 > 3.5$).

- b) X_2 - v.a. que representa a acidez total do vinho, determinada pelo método automático, $\mu_2 = E[X_2]$.

Trata-se de um delineamento em amostras emparelhadas por garrafa.

A resposta à questão pode ser obtida com recurso a um I.C. para $\mu_D = \mu_1 - \mu_2$ ou ao teste de hipóteses: $H_0: \mu_D = \mu_1 - \mu_2 = 0$ vs. $H_1: \mu_D = \mu_1 - \mu_2 \neq 0$, mas note-se que, sendo amostras emparelhadas, das opções apresentadas no *output* para comparar dois valores médios só interessa a que contém a informação `paired=TRUE`.

Os pressupostos são:

- garrafas seleccionadas aleatoriamente,
- a população das diferenças $D = X_1 - X_2$ ter distribuição normal.

A hipótese da normalidade de D é validada com recurso ao teste de Shapiro-Wilk

`shapiro.test(classico-automatico)`.

Como $p\text{-value} = 0.08413$ e é um valor superior a 0.05 (habitualmente considerado) não se rejeita a hipótese da normalidade.

Estamos ainda na situação de a variância de D não ser conhecida, então o teste a usar é `t.test(classico,automatico,paired=TRUE)`.

Tem $p\text{-value} = 0.03493$ pelo que, aos níveis de significância usuais de 0.05 ou 0.1, se rejeita a hipótese nula concluindo-se que os dois métodos de análise conduzem a resultados diferentes.

Note-se que o I.C. que também é dado no *output* $-1.12405128 < \mu_1 - \mu_2 < -0.04594872$, nos permite concluir que com uma confiança de 95% a média das diferenças é negativa, portanto os dois métodos conduzem a resultados diferentes.

3. Mediram-se 5 espigas de trigo da variedade A e 7 espigas da variedade B. Os resultados obtidos para os comprimentos das espigas em cm, foram os seguintes:

A	12.6	13.4	11.9	12.8	13.0		
B	13.1	13.4	12.8	13.5	13.3	12.7	12.4

Pretende-se verificar se os dados obtidos permitem estabelecer qualquer diferença significativa de comprimento das espigas entre as duas variedades de trigo.

Resolução

Como é evidente, não há qualquer emparelhamento dos dados; as medições de A são independentes das medições de B.

Como as amostras são de dimensão pequena, $n_1 = 5, n_2 = 7$, teremos de verificar a validade dos seguintes pressupostos:

i) normalidade de cada uma das variáveis:

X - comprimento das espigas da variedade A e

Y - comprimento das espigas da variedade B

ii) igualdade das variâncias: $\sigma_1^2 = \sigma_2^2$?

Verificando-se a validade destes pressupostos, o estudo da existência de diferença de comprimento entre os dois tipos de espigas pode ser feito considerando, por exemplo, um intervalo de confiança para

$$\mu_1 - \mu_2$$

com μ_1 - comprimento médio das espigas da variedade A e

μ_2 - comprimento médio das espigas da variedade B

- Vejamos se o pressuposto i) é verificado. Para isso vamos recorrer ao 

```
> x<-c(12.6,13.4,11.9,12.8,13.0)
> y<-c(13.1,13.4,12.8,13.5,13.3,12.7,12.4)
> shapiro.test(x)
```

Shapiro-Wilk normality test

```
data: x
W = 0.9706, p-value = 0.879
```

```
> shapiro.test(y)
```

Shapiro-Wilk normality test

```
data: y
W = 0.9426, p-value = 0.6622
```

Como qualquer dos valores de p - *value* é superior ao valor 0.05 (habitualmente considerado), não se rejeita a hipótese da normalidade de cada uma das variáveis X e Y .

- Passemos agora à verificação do pressuposto ii). Podemos calcular o intervalo de confiança para σ_1^2/σ_2^2 .

O intervalo a $(1 - \alpha) \times 100\%$ de confiança é dado por:

$$\frac{s_1^2}{s_2^2 f_{\alpha/2}(n_1 - 1, n_2 - 1)} < \frac{\sigma_1^2}{\sigma_2^2} < \frac{s_1^2 f_{\alpha/2}(n_2 - 1, n_1 - 1)}{s_2^2},$$

onde $s_1^2 = 0.308$ e $s_2^2 = 0.1657$

O comando no \mathbb{R} , para obter o I.C. a 95% é:

```
> var.test(x,y)
```

```
F test to compare two variances
```

```
data: x and y
```

```
F = 1.8586, num df = 4, denom df = 6, p-value = 0.4739
```

```
alternative hypothesis: true ratio of variances is not equal to 1  
95 percent confidence interval:
```

```
0.29847 17.09431
```

```
sample estimates:
```

```
ratio of variances
```

```
1.858621
```

Tem-se então o I.C. $]0.29847; 17.09431[$.

Como este intervalo contém o valor **1**, não temos motivos para duvidar que $\sigma_1^2 = \sigma_2^2$, com uma confiança de 95% .

Vamos então agora calcular o I.C. a 95% para $\mu_1 - \mu_2$, que é dado por

$$(\bar{x} - \bar{y}) - t_{0.025; (n_1+n_2-2)} s_p \sqrt{\frac{1}{n_1} + \frac{1}{n_2}} < \mu_1 - \mu_2 < (\bar{x} - \bar{y}) + t_{0.025; (n_1+n_2-2)} s_p \sqrt{\frac{1}{n_1} + \frac{1}{n_2}}$$

$$\text{com } s_p^2 = \frac{(n_1-1)s_1^2 + (n_2-1)s_2^2}{n_1+n_2-2}.$$

Tem-se $n_1 = 5; n_2 = 7; t_{0.025; (10)} = 2.22814; \bar{x} = 12.74; \bar{y} = 13.03$ e $s_p^2 = 0.2262$, donde o I.C. a 95% é então

$$-0.90416 < \mu_1 - \mu_2 < 0.32702$$

Portanto como este I.C. contém o valor **0** (que significa a igualdade dos dois valores médios) não podemos dizer que haja diferença no comprimento médio de cada uma das variedades, com uma confiança de 95%. A resposta a esta questão é obtida no \mathbb{R} , executando o comando

```
> t.test(x,y,paired=F,var.equal=T)
```

```
Two Sample t-test
```

```
data: x and y
```

```
t = -1.0445, df = 10, p-value = 0.3208
```

```
alternative hypothesis: true difference in means is not equal to 0  
95 percent confidence interval:
```

```
-0.9041582 0.3270154
```

```
sample estimates:
```

mean of x mean of y
 12.74000 13.02857

Podemos dar a resposta usando o *p-value* ou o intervalo de confiança.

Vejamos agora dois exercícios para ilustrar a utilização do teste de ajustamento do qui-quadrado

4. Realizou-se um estudo para averiguar se o número de faltas ao trabalho dos empregados de uma empresa se podia considerar ter uma distribuição uniforme pelos dias da semana. O registo efectuado ao longo de várias semanas está resumido no seguinte quadro:

Segunda	Terça	Quarta	Quinta	Sexta
24	18	15	21	28

Resolução: Dizer que a distribuição do nº de faltas, X , é uniforme na semana, significa que $P[X = i] = 1/5$, com $i = 1, \dots, 5$, designando os dias da semana de Segunda a Sexta. Pretendemos então testar

$$H_0 : p_i = 1/5, i = 1, \dots, 5 \quad \text{vs} \quad H_1 : \text{pelo menos dois } p_i \neq 1/5, i = 1, \dots, 5$$

Vamos então construir um quadro análogo ao apresentado no slide 182, das aulas teóricas

	Segunda	Terça	Quarta	Quinta	Sexta
O_i	24	18	15	21	28
p_i	1/5	1/5	1/5	1/5	1/5
$E_i = np_i$	21.2	21.2	21.2	21.2	21.2

$$X_{cal}^2 = \sum_{i=1}^5 \frac{(O_i - E_i)^2}{E_i} = 0.3698 + 0.483 + 1.8132 + 0.0019 + 2.1811 = 4.849 \quad \text{e} \quad \chi_{0.05,4}^2 = 9.488.$$

Então $X_{cal}^2 < \chi_{0.05,4}^2$, portanto, a um nível de significância de 5%, não se rejeita a hipótese de o número de faltas ser uniforme na semana.

5. Realizou-se um estudo do comportamento do gorgulho Azuki do feijão. Introduziram-se larvas desse gorgulho nos feijões que as alimentaram. As crisálidas saíram através de um buraco feito no feijão e, como tal, o nº de buracos por feijão indica-nos o nº de adultos que saíram. Os resultados observados em 100 feijões encontram-se na seguinte tabela:

nº de gorgulhos saídos de 1 feijão (x_i)	0	1	2	3	≥ 4
frequência observada (n_i)	60	22	10	5	3

Será o nº. de gorgulhos por feijão uma v.a. com distribuição de Poisson?

Resolução: Seja X a v.a. que designa o nº. de gorgulhos por feijão. As hipóteses a formular são:

$H_0 : X$ tem distribuição de Poisson vs $H_1 : X$ não tem distribuição de Poisson.

Note-se que não conhecemos o parâmetro da distribuição, então terá que ser estimado. Como é sabido, se $X \sim P(\lambda)$, tem-se $E[X] = \lambda$, então podemos considerar como estimativa para λ , $\hat{\lambda} = \bar{x}$.

No nosso problema temos $n = 100$ e $\bar{x} = \frac{\sum n_i x_i}{100} = 0.69$.

Temos que calcular a probabilidade de a variável X tomar os valores 0, 1, 2, 3 e ≥ 4 , que são fáceis de obter por consulta das tabelas da Poisson com $\lambda = 0.7$. Vejamos como obter estes valores no \mathbb{R}

```
> p1<-dpois(0:3,0.7);p1
[1] 0.49658530 0.34760971 0.12166340 0.02838813
```

o comando `dpois` permite obter $P[X = i] = \frac{e^{-\lambda} \lambda^i}{i!}$, neste caso $i = 0, 1, 2, 3$. Para se calcular $P[X \geq 4] = 1 - P[X \leq 3]$, no \mathbb{R} obtém-se com o comando `ppois`

```
> p2<-1-ppois(3,0.7)
```

O vector que contém as probabilidades para $x = 0, 1, 2, 3, \geq 4$, no caso de $X \sim P(0.7)$ é

```
> pi<-c(p1,p2);pi
[1] 0.496585304 0.347609713 0.121663399 0.028388127 0.005753458
```

Vamos então construir o quadro análogo ao apresentado no slide 182, das aulas teóricas

	0	1	2	3	≥ 4
O_i	60	22	10	5	3
\hat{p}_i	0.49659	0.34761	0.12166	0.02839	0.00575
$E_i = n\hat{p}_i$	49.659	34.761	12.166	2.839	0.575

Como a última classe apresenta uma frequência esperada (estimada) inferior a 1 (ver slide 183, teóricas) devem juntar-se as duas últimas classes, isto é o quadro deve ser

	0	1	2	≥ 3
O_i	60	22	10	8
\hat{p}_i	0.49659	0.34761	0.12166	0.03414
$E_i = n\hat{p}_i$	49.659	34.761	12.166	3.414

$$X_{cal}^2 = \sum_{i=1}^4 \frac{(O_i - E_i)^2}{E_i} = 13.384 \quad \text{e} \quad \chi_{0.05,2}^2 = 5.99.$$

Então $X_{cal}^2 > \chi_{0.05,2}^2$, logo rejeita-se a hipótese de a distribuição ser $Poisson(0.7)$ a um nível de significância de 5%.

Vamos agora executar o teste do qui-quadrado, para o que é necessário dar o vector com os valores observados.

```
> oi<-c(60,22,10,8)
> chisq.test(oi, p = pi)
Chi-squared test for given probabilities
```

```
data: oi
X-squared = 13.3836, df = 3, p-value = 0.003876
```

Warning message:

```
In chisq.test(oi, p = pi) : Chi-squared approximation may be incorrect
```

Atennda-se ao alerta dado, informando que deve haver cuidado na leitura do teste. Efectivamente tendo havido aqui necessidade de estimar o parâmetro da distribuição de Poisson o nº de graus de liberdade para o χ^2 é 2 e não 3 como está indicado.

Como é habitual a leitura do valor de *p - value* dado no *output* conduz, tal como atrás vimos, à rejeição da hipótese nula.