


1. a) Vamos então indicar os valores em falta no *output* (vale a pena introduzir no  e tentar executar os comandos, para ver e compreender os resultados)


```
A Ni
B 0.9686
C 0 a mediana é >= 1o quartil e <= 3o quartil, portanto só pode ser =0
D é dado por s/sqrt(n)=0.006587
E UCL Mean= média -(semi-amplitude do IC)=Mean-(0.178010-0.165099)=0.190922
```

- b) moda =0; mediana =0 e média = 0.17801 ovos/folha

A média é superior à moda=mediana, devido à assimetria positiva que os dados apresentam. Observe-se tb por exemplo o coeficiente de assimetria, *Skewness* =5.136906. Há um excesso de zeros e depois alguns valores são elevados, deslocando a média para a direita.

- c) Para construir o *boxplot* devem calcular-se as barreiras superiores e inferiores, para se fazer uma pesquisa de candidatos a *outliers*.

$BI = Q_1 - 1.5(Q_3 - Q_1)$   $BS = Q_3 + 1.5(Q_3 - Q_1)$ , como  $Q_1 = 0$ ,  $Q_3 = 0$  tem-se  $BI = 0$  e  $BS = 0$ , portanto não há valores observados inferiores à barreira inferior (logo não há outliers na cauda esquerda), mas os valores 1, 2, 3, 4, 5, 6, 7, 8 e 9 são todos eles candidatos a outliers. Ver abaixo o *boxplot* e por curiosidade o histograma (não era pedido),



- d) Uma estimativa da proporção de folhas com ovos é dada por  $p^* = xt_{tot}/7640 = 0.125$  (está também no final de qualquer dos comandos *binom (...)*, como

```
sample estimates:
probability of success
0.125
```

- e) Um intervalo de confiança a 95% para a proporção de folhas com ovos está no *output*

```
95 percent confidence interval:
0.1176628 0.1326246
```

$0.1176628 < p < 0.1326246$ , significando que, com 95% de confiança a verdadeira proporção de folhas com ovos está entre aqueles dois valores.

O intervalo acima é exacto (no sentido de ser usada a distribuição binomial na sua construção). Podemos usar a expressão do IC assintótico (que aqui não vai dar um resultado muito diferente, visto  $n$  ser muito grande)

$$\hat{p} - z_{\alpha/2} \sqrt{\frac{\hat{p}\hat{q}}{n}} < p < \hat{p} + z_{\alpha/2} \sqrt{\frac{\hat{p}\hat{q}}{n}} \Leftrightarrow 0.125 - 1.96 \sqrt{\frac{0.125 \times 0.875}{7640}} < p < 0.125 + 1.96 \sqrt{\frac{0.125 \times 0.875}{7640}}$$

donde o IC a 95% para  $p$  é  $]0.11758, 0.1324[$

f) A resposta a esta questão deve ser dada construindo um teste de hipóteses:

$$H_0 : p = 0.10 \quad vs \quad H_1 : p > 0.10, \quad \text{vamos considerar o nível de significância } \alpha = 0.05$$

Como  $n = 7640$  permite considerar a aproximação pela normal, sendo a Estatística de Teste

$$Z = \frac{X - n p_0}{\sqrt{n p_0 q_0}} \sim \mathcal{N}(0, 1)$$

A região de Rejeição ou região Crítica é  $RC : Z > z_{\alpha} \Leftrightarrow Z > 1.65$

Calculando o valor da Estatística de teste, no caso de  $H_0$  verdadeira, i.e. quando  $p \equiv p_0 = 0.1$ ,

$$Z_{calc} = \frac{955 - 746}{\sqrt{7640 \times 0.1 \times 0.9}} = 7.97, \text{ portanto } Z_{calc} \in RC \text{ logo rejeitamos } H_0, \text{ o que significa}$$

que, pode considerar-se a percentagem de folhas com ovos superior a 10%, com um nível de significância de 5%.

**Nota:** A resposta podia ser dada usando o *output*. O comando a escolher seria

`> binom.test(x=xtot, n=7640, p = 0.1, alternative = "greater")`

que realiza um teste exacto, mas para o qual se teve **p-value = 1.056e-12**, que portanto conduz à rejeição da hipótese nula.

g) Um intervalo de confiança a 95% para o número médio de pinheiros afectados/parcela é dado tb no output  $1.819692 < \mu < 2.130308$

2. a) Temos  $\theta > 0$  e o método dos momentos estabelece que um estimador é a solução de

$$E[X] = \frac{\sum X_i}{n} \Leftrightarrow \theta \sqrt{\pi/2} = \bar{X} \Leftrightarrow \theta = \bar{X} \sqrt{2/\pi}$$

Então o estimador é  $\Theta^* = \bar{X} \sqrt{2/\pi}$

b) Um estimador  $T$  de  $\theta$  é centrado se e só se  $E[T] = \theta$ .

Vamos então calcular  $E[\Theta^*] = E[\bar{X} \sqrt{2/\pi}] = \sqrt{2/\pi} E[\bar{X}]$ , pelas propriedades do valor médio. Como  $E[\bar{X}] = E[X] = \theta \sqrt{\pi/2}$ , substituindo em cima dá  $E[\Theta^*] = \theta$ , portanto é estimador centrado.

c) Para obter o Estimador de Máxima Verosimilhança é preciso escrever a função de verosimilhança:

$$L(\theta|x_1, \dots, x_n) = \frac{\prod_{i=1}^n x_i}{\theta^{2n}} \exp\left(-\frac{\sum_{i=1}^n x_i^2}{2\theta^2}\right)$$

O logaritmo é

$$\log L(\theta|x_1, \dots, x_n) = \log(\prod_{i=1}^n x_i) - 2n \log(\theta) - \frac{\sum_{i=1}^n x_i^2}{2\theta^2}$$

Calculando a derivada:

$$\frac{d \log L}{d\theta} = 0 - \frac{2n}{\theta} - \frac{1}{2} \frac{(-2\theta) \sum_{i=1}^n x_i^2}{\theta^4} = -\frac{2n}{\theta} + \frac{\sum_{i=1}^n x_i^2}{\theta^3}$$

e agora igualando a zero:

$$-\frac{2n}{\theta} + \frac{\sum_{i=1}^n x_i^2}{\theta^3} = 0 \Leftrightarrow -2n + \frac{\sum_{i=1}^n x_i^2}{\theta^2} = 0 \Rightarrow \frac{\sum_{i=1}^n x_i^2}{\theta^2} = 2n \Leftrightarrow \theta^2 = \frac{\sum_{i=1}^n x_i^2}{2n}$$

O estimador de máxima verosimilhança é  $\hat{\Theta} = \sqrt{\frac{\sum X_i^2}{2n}}$

- d) Usando os dois estimadores obtidos na alínea anterior podemos ter 2 estimativas de  $\theta$  com base na amostra observada.

$$\theta^* = \bar{x}\sqrt{2/\pi} = 2.2378 \quad \text{e} \quad \hat{\theta} = \sqrt{\frac{\sum x_i^2}{2n}} = 2.114496$$

- e)  $CV = \frac{\sigma}{\mu} \times 100\%$ . Para estimar o  $CV$  podemos usar directamente as estimativas de  $\sigma$  e  $\mu$ , que são  $s$  e  $\bar{x}$  ou então usar uma estimativa de  $\theta$  e depois substituir na expressão da variância (a raíz quadrada é o desvio padrão estimado) e do valor médio.

3. a) Uma estimativa para a diferença média entre os valores de pH da água à entrada e à saída do tanque, obtém-se facilmente do *output* em

```
sample estimates:
mean of the differences
-0.3466667
```

- b) Para averiguarmos se há alteração média diária do valor do pH, vamos realizar um teste de hipóteses à diferença de médias.

Como as observações são registadas dia a dia as amostras recolhidas devem ser tratadas como emparelhadas por dia.

Como temos uma amostra (emparelhada) de dimensão pequena ( $n = 15$ ), para a realização de um teste- $t$  necessitamos de primeiro testar a hipótese da normalidade, analisando o resultado de

```
>shapiro.test(entrada-saida)
      Shapiro-Wilk normality test
data:  entrada - saida
W = 0.9695, p-value = 0.8509
```

onde se obteve um  $p\text{-value} = 0.8509$ , levando portanto à não-rejeição da hipótese da normalidade. O teste  $t$  a considerar está no comando

```
> t.test(entrada,saida,paired=TRUE)
      Paired t-test
data:  entrada and saida
t = -3.6665, df = 14, p-value = 0.002540
alternative hypothesis: true difference in means is not equal to 0
95 percent confidence interval:
 -0.5494560 -0.1438773
sample estimates:
mean of the differences
 -0.3466667
```

para o qual se obteve  $p\text{-value} = 0.002540$ , conduzindo portanto à rejeição da hipótese nula ( $H_o : \mu_1 = \mu_2$ ) e a considerar-se existir diferença significativa entre as médias. Então há alteração média diária do valor do pH quando a água passa no tanque, mais concretamente o valor médio do pH aumenta.

4. Se  $X$  e  $Y$  são variáveis aleatórias **contínuas** com distribuição uniforme em  $[0, 1]$ :

- a) `x<-runif(1000)`  
`y<-runif(1000)`  
b) `z<-x+y`  
c) `hist(z)`  
d) Da leitura do comando

```
> ks.test(z,"punif",0,2)
One-sample Kolmogorov-Smirnov test
data: z
D = 0.1343, p-value = 4.441e-16
alternative hypothesis: two-sided
```

Aplicou-se o teste de ajustamento de Kolmogorov-Smirnov, com hipótese nula uniforme, à amostra resultante da soma de 2 variáveis uniformes, somos levados à rejeição da hipótese de que a soma é uniforme.

```
> ks.test(z,"pnorm",mean(z),sd(z))
One-sample Kolmogorov-Smirnov test
data: z
D = 0.0321, p-value = 0.2529
alternative hypothesis: two-sided
```

Aplicou-se o teste de ajustamento de Kolmogorov-Smirnov, com hipótese nula normal, à amostra resultante da soma de 2 variáveis uniformes, somos levados à não rejeição da hipótese de que a soma segue uma lei normal.

5. Se  $(X_1, X_2, \dots, X_n)$  tal que  $X \sim \mathcal{N}(\mu_1, \sigma) \implies \bar{X} \sim \mathcal{N}(\mu_1, \sigma/\sqrt{n})$   
 $(Y_1, Y_2, \dots, Y_n)$  tal que  $Y \sim \mathcal{N}(\mu_2, \sigma) \implies \bar{Y} \sim \mathcal{N}(\mu_2, \sigma/\sqrt{n})$ .  
 amostras independentes e  $\sigma$  conhecido.

- a) As hipóteses a testar são:  $H_0 : \mu_1 = \mu_2$  vs  $H_1 : \mu_1 \neq \mu_2$ , portanto a estatística de teste será:

$$\bar{X} - \bar{Y} \sim \mathcal{N}(\mu_1 - \mu_2, \sqrt{\sigma^2/n + \sigma^2/n}) \iff \bar{X} - \bar{Y} \sim \mathcal{N}(\mu_1 - \mu_2, \sigma\sqrt{2/n}).$$

Como um IC para  $\mu_1$  é da forma  $\bar{x}_1 \pm z_{\alpha/2} \frac{\sigma}{\sqrt{n}}$  e um IC para  $\mu_2$  é da forma  $\bar{x}_2 \pm z_{\alpha/2} \frac{\sigma}{\sqrt{n}}$ , tal como está na Nota, eles não se sobrepõem se a diferença entre as médias amostrais for superior à soma das semi-amplitudes de cada um dos intervalos (cada uma dada por  $z_{\alpha/2} \frac{\sigma}{\sqrt{n}}$ ).

Logo sobrepõem-se quando aquela diferença for inferior à soma das semi-amplitudes, ou seja for inferior a  $2 z_{\alpha/2} \frac{\sigma}{\sqrt{n}}$

$P[\text{os intervalos se sobrepõem} \mid H_0 \text{ verdadeira}] =$

$$P[|\bar{X} - \bar{Y}| < 2 z_{\alpha/2} \frac{\sigma}{\sqrt{n}}] = P[-2 z_{\alpha/2} \frac{\sigma}{\sqrt{n}} < \bar{X} - \bar{Y} < 2 z_{\alpha/2} \frac{\sigma}{\sqrt{n}}] =$$

$$= P\left[\frac{-2 z_{\alpha/2} \frac{\sigma}{\sqrt{n}}}{\sigma\sqrt{2/n}} < Z < \frac{2 z_{\alpha/2} \frac{\sigma}{\sqrt{n}}}{\sigma\sqrt{2/n}}\right] = P[-\sqrt{2} z_{\alpha/2} < Z < \sqrt{2} z_{\alpha/2}] = \Phi(\sqrt{2} z_{\alpha/2}) - \Phi(-\sqrt{2} z_{\alpha/2}) = 2\Phi(\sqrt{2} z_{\alpha/2}) - 1$$

- b) Basta substituir para  $\alpha = 0.05$ , dando  $2\Phi(\sqrt{2} \times 1.96) - 1 = 0.994$ .

- c)  $P[\text{erro tipo I}] = P[\text{rejeitar } H_0 \mid H_0 \text{ verdadeira}] =$   
 $P[\text{intervalos não se sobrepõem} \mid H_0 \text{ verdadeira}] = 0.05$   
 então tem-se

$$1 - 2\Phi(\sqrt{2} z_{\alpha/2}) + 1 = 0.05 \iff \Phi(\sqrt{2} z_{\alpha/2}) = 0.975 \iff \sqrt{2} z_{\alpha/2} = 1.96 \iff \alpha = 0.16577$$