


1. Considere os dados `diet` contidos na biblioteca `Epi` do `R`, referentes a um estudo que tinha como objectivo analisar a existência de associação entre a dieta e o aparecimento de doença coronária. A *data frame* `diet` tem 337 linhas e 15 colunas. Vamos considerar apenas as seguintes variáveis:

`fat`: fat intake (g/day), um vector numérico  
`weight`: (kg), um vector numérico  
`chd`: CHD event, um vector tomando valores (1=CHD event, 0=no event)  
`job`: ocupação, um factor com os níveis `Driver(D)`, `Conductor(C)` e `Bank worker(BW)`

Foram efectuados alguns comandos no `R`, tendo-se obtido o *output* que se encontra no Anexo e que deve utilizar para responder às seguintes questões:

- Complete os valores referidos por **A**, **B**, **C** e **D**, em falta no *output*.
- Esboce o **Histograma**, que aparece identificado no *output*, mas não foi desenhado.
- Faça o esboço de um *boxplot* para a variável `fat`. Indique claramente os limites do *boxplot*.
- Comente, comparando, os 2 grupos de *boxplots* apresentados abaixo.
- Obtenha um intervalo de confiança a 95% para a proporção de indivíduos em que **não terá havido ocorrência de doença coronária**. Comente.
- Face aos resultados apresentados no *output* compare o valor médio da variável `fat` entre cada um dos grupos de classificação de ocorrência ou não de doença coronária. Justifique.



2. Um agrónomo está a desenvolver uma variedade melhorada de pimenta verde. Os supermercados indicaram que os clientes geralmente não compram a vagem de pimenta verde que pesam menos de 45 g. A actual variedade de planta produz pimentas verdes que pesam 48 gramas em média, mas 13% pesam menos de 45 gramas. Suponha que o peso da vagem da variedade actual de pimentas verdes segue uma distribuição normal.
- Qual é o desvio padrão do peso da variedade actual de pimentas verdes?
  - O agrónomo pretende reduzir a frequência de vagens de pimenta verde que pesam menos de 45 gramas para 5% no máximo. Uma maneira de reduzir a frequência de pimentas verdes com baixo peso é tentar aumentar o peso das pimentas verdes. Se o desvio padrão permanecer o mesmo, qual o valor médio que deve ser procurado atingir? (se não resolveu a) considere  $\sigma = 2.6$ ).
  - O agrónomo produziu a nova variedade de pimentas verdes, por forma a garantir um peso médio de 50 gramas com um desvio padrão de 2.5 gramas. Um cliente do supermercado compra 25. Qual a probabilidade de a média do peso dessas pimentas ser inferior a 49 gramas?

3. Suponha que o número de tentativas que um jogador de basquetebol faz até acertar no cesto é uma variável aleatória,  $X$ , com a seguinte função massa de probabilidade:

$$P[X = x|\theta] = \frac{1}{\theta} \left(1 - \frac{1}{\theta}\right)^{x-1}, \quad \text{para } x = 1, 2, 3, \dots \quad (\theta > 1)$$

**Nota:** Sabe-se que  $E[X] = \theta$  e  $Var[X] = \theta(\theta - 1)$ .

Considere que se tem uma amostra aleatória de dimensão  $n$ ,  $(X_1, X_2, \dots, X_n)$ , associada a  $X$ .


- Obtenha o estimador de  $\theta$  pelo método dos momentos.
- Diga se o estimador dos momentos obtido na alínea a) é um estimador centrado de  $\theta$  e indique o seu Erro Quadrático Médio.
- Obtenha o estimador de máxima verosimilhança para  $\theta$ .
- Considere os valores observados da seguinte amostra, de dimensão 20, extraída daquela população, com a qual se realizaram os cálculos apresentados:

```
> amostra
[1] 2 7 1 1 1 3 5 6 4 5 3 2 4 6 6 6 1 7 5 1
> sum(amostra)
[1] 76
> sum(amostra*amostra)
[1] 380
```

- Determine uma estimativa para  $\theta$ .
- Determine uma estimativa de  $P[X = 2]$ , i.e., da probabilidade de o jogador acertar à segunda tentativa.

**Nota:** o estimador de máxima verosimilhança goza de uma propriedade, dita da invariância, que estabelece que *–O estimador de máxima verosimilhança de  $g(\theta)$  é  $g(\hat{\theta})$ , se  $g(\cdot)$  é função biunívoca de  $\theta$ .*

4. Indique, justificando se as seguintes afirmações são **Verdadeiras** ou **Falsas**. **Corrija as falsas**.

- Se  $X \sim \text{Poisson}(10)$  então pode calcular-se  $P[X > 8]$ , com recurso ao  fazendo `dpois(8,10)`.
- Suponha que  $Y \sim \text{Binomial}(n, p)$ . Então  $P[0 \leq Y \leq n] = 1$ .
- Seja  $X \sim N(1, 2)$  e  $Y \sim N(1, 1)$ , com  $X$  e  $Y$  independentes. Então  $2X - Y \sim N(1, 3)$ .
- Seja  $(X_1, \dots, X_n)$  uma amostra aleatória de tamanho  $n$ , proveniente de uma população com valor médio  $\mu$  e variância  $\sigma^2 < +\infty$ . Então para  $n$  suficientemente elevado tem-se  $P[S_n \leq n\mu] \approx 1/2$ , onde  $S_n = \sum_{i=1}^n X_i$ .

5. Admite-se que a concentração,  $X$ , de dióxido de enxofre ( $\text{SO}_2$ ) (em partes por milhão, ou ppm) numa determinada cidade segue uma distribuição gama, que vimos poder ter dois parâmetros  $\alpha$  e  $\beta$ , ( $\alpha > 0$ ,  $\beta > 0$ ). Vamos considerar, para simplificar, que  $\alpha = 1/2$ , permanecendo apenas  $\beta$  desconhecido. A função densidade é então assim dada:

$$f(x|\beta) = \begin{cases} \frac{1}{\sqrt{\beta\pi x}} e^{-x/\beta} & x > 0 \\ 0 & x \leq 0 \end{cases}$$

Seja  $(X_1, \dots, X_n)$  uma amostra aleatória de tamanho  $n$ , proveniente daquela lei, sendo  $(x_1, \dots, x_n)$  a correspondente amostra observada.

- Usando o Teorema Limite Central obtenha uma distribuição aproximada para  $\bar{X}$ .
- Recordando que se uma v.a.  $V$  é tal que  $V \sim \text{Normal}(0, 1)$ , se pode escrever

$$P[-1.96 < V < 1.96] \approx 0.95,$$

obtenha um intervalo assintótico a 95% de confiança para o parâmetro  $\beta$ .

## ANEXO I

##### Pergunta 1 #####

```
> library(Epi)
> data(diet)
> dim(diet)
[1] 337 15

> names(diet)
[1] "id"      "doe"      "dox"      "dob"      "y"
[6] "fail"    "job"      "month"    "energy"   "height"
[11] "weight"  "fat"      "fibre"    "energy.grp" "chd"

> hist(diet$fat,breaks=c(5,10,12,15,18,22),plot=F) #Histograma
$breaks
[1] 5 10 12 15 18 22

$counts
[1] 34 106 146 41 10

$density
[1] 0.020178042 0.157270030 0.144411474 0.040553907 0.007418398

$mids
[1] A 11.0 13.5 16.5 20.0

>
> sort(diet$fat)
[1] 7.260000 7.272000 7.578000 8.302000 8.348001 8.536000 8.577000
. . .
[323] 17.388000 17.409000 17.445000 17.639000 17.769000 18.389000 18.391000
[330] 18.558000 18.588000 18.628000 19.032000 20.112000 20.132000 20.763000
[337] 21.629000

> summary(diet$fat)
  Min.   1st Qu.   Median     Mean   3rd Qu.    Max.
    B      11.12    12.59    12.75    14.01    21.63

> par(mfrow=c(1,2))
> boxplot(fat~job,data=diet,main="fat vs job",names=c("D","C","BW"))
> boxplot(weight~job,data=diet,main="weight vs job",names=c("D","C","BW"))

> diet$fat[diet$chd==0] # C - escreva, brevemente, o que resulta deste comando
> length(diet$fat[diet$chd==0])
[1] 291
> length(diet$fat[diet$chd==1])
[1] D
```

```

> shapiro.test(diet$fat[diet$chd==0])

      Shapiro-Wilk normality test

data:  diet$fat[diet$chd == 0]
W = 0.9757, p-value = 7.604e-05

> shapiro.test(diet$fat[diet$chd==1])

      Shapiro-Wilk normality test

data:  diet$fat[diet$chd == 1]
W = 0.9743, p-value = 0.3947

> t.test(fat~chd,data=diet)

      Welch Two Sample t-test

data:  fat by chd
t = 2.9536, df = 62.484, p-value = 0.004423
alternative hypothesis: true difference in means is not equal to 0
95 percent confidence interval:
 0.337497    1.750317
sample estimates:
mean in group 0 mean in group 1
    12.88791      11.84400

> t.test(fat~chd,data=diet,alternative="greater")

      Welch Two Sample t-test

data:  fat by chd
t = 2.9536, df = 62.484, p-value = 0.002211
alternative hypothesis: true difference in means is greater than 0
95 percent confidence interval:
 0.4537988      Inf
sample estimates:
mean in group 0 mean in group 1
    12.88791      11.84400

> t.test(fat~chd,data=diet,alternative="less")

      Welch Two Sample t-test

data:  fat by chd
t = 2.9536, df = 62.484, p-value = 0.9978
alternative hypothesis: true difference in means is less than 0
95 percent confidence interval:
 -Inf 1.634016
sample estimates:
mean in group 0 mean in group 1
    12.88791      11.84400

>

```