

Capítulo 3 Introdução à Inferência Estatística

Exercícios de Distribuições de Amostragem e Estimadores

- 3.1.** De uma população normal de média 8 e desvio padrão 4, extraíu-se uma amostra aleatória de dimensão 100.
- Qual a probabilidade de a diferença, em valor absoluto, entre a média da amostra e a média da população ser superior a 0.5?
 - Se a população não fosse normal, qual seria essa probabilidade? Justifique.
- 3.2.** O peso médio dos indivíduos duma certa espécie de bivalves é 31g e o respectivo desvio padrão é 2.4g. Recolhe-se uma amostra aleatória de 100 indivíduos desta espécie.
- Qual a probabilidade, aproximada, de a média da amostra ser inferior a 30g?
 - Qual a probabilidade, aproximada, de o peso total da amostra ser superior a 3150g?
- 3.3.** Mediu-se o comprimento (em cm) de 25 coelhos adultos de uma dada raça escolhidos aleatoriamente. A média da amostra foi 56.2 cm e o desvio padrão 4 cm. Admita que a população dos comprimentos dos coelhos adultos daquela raça é bem modelada por uma distribuição normal.
- Indique estimativas para a média e o desvio padrão da população.
 - Usando as estimativas da alínea anterior como os parâmetros da população, determine a probabilidade de o comprimento de um coelho adulto daquela raça, escolhido ao acaso, ser superior a 57 cm.
 - Chama-se erro padrão da média amostral a uma estimativa do desvio padrão da v.a. média da amostra. Com base nos resultados obtidos, determine o erro padrão da média amostral?
- 3.4.** Seja X uma variável aleatória com distribuição de Bernoulli de parâmetro p desconhecido e (X_1, X_2, X_3) uma amostra aleatória associada a esta variável.
- Quais as propriedades da amostra aleatória (X_1, X_2, X_3) ?

- b) Sugere-se os dois estimadores para p , $\hat{P}_1 = \bar{X}$ e $\hat{P}_2 = (X_1 + 2X_2 + X_3)/4$. Determine o valor esperado de cada um dos estimadores? Interprete.
- c) Analise os estimadores quanto à sua variância. Qual dos dois estimadores considera que deve ser escolhido para estimar p ? Justifique.
- d) Procedeu-se à recolha de uma amostra, nas condições do enunciado, tendo-se obtido os valores $(0, 1, 0)$. Obtenha duas estimativas para p .
- 3.5.** Depois de fabricado e embalado, a actividade de um certo adubo segue aproximadamente uma distribuição normal com $\mu = 120$ dias e $\sigma = 40$ dias. Pretende-se enviar um lote de embalagens do referido adubo de modo que a actividade média amostral (\bar{X}) seja superior a 118 dias com probabilidade de 0.95. Qual o tamanho do lote a enviar?
- 3.6.** Seja (X_1, \dots, X_n) uma amostra aleatória de tamanho n proveniente d uma população X com distribuição $U(0, 1)$. Calcule a probabilidade, aproximada, de \bar{X} ser superior 0.9.
- 3.7.** Uma amostra aleatória de dimensão 50, (X_1, \dots, X_{50}) , é extraída de uma população de Poisson com $\lambda = 10$. Recorra à distribuição normal para calcular um valor aproximado de $P(\bar{X} > 11)$.
- 3.8.** Seja X_1, X_2, \dots, X_n uma amostra de variáveis aleatórias independentes e com a mesma distribuição, de valor médio μ e variância σ^2 . Considere os seguintes estimadores de μ e σ^2 , respectivamente,

$$\bar{X} = \frac{1}{n} \sum_{i=1}^n X_i \quad \text{e} \quad S^2 = \frac{1}{n-1} \sum_{i=1}^n (X_i - \bar{X})^2.$$

- a) Prove que $E[\bar{X}] = \mu$ e $Var[\bar{X}] = \sigma^2/n$.
- b) Prove que
- $$\sum_{i=1}^n (X_i - \mu)^2 = \sum_{i=1}^n (X_i - \bar{X})^2 + n(\bar{X} - \mu)^2$$
- c) Usando os resultados das alíneas anteriores, mostre que $E[S^2] = \sigma^2$.
- 3.9.** Considere a amostra aleatória X_1, X_2, \dots, X_{100} , retirada de uma população X para a qual se tem $E[X] = 0.5$ e $Var[X] = 0.0625$. Considere a variável aleatória $S = \sum_{i=1}^{100} X_i$.
- a) Defina “amostra aleatória”.
- b) Determine o valor esperado e a variância de S . Justifique convenientemente.
- c) Determine, aproximadamente, $P[S < 45]$.

Exercícios de Intervalos de Confiança e Testes de Hipóteses

3.10. Seja X uma população com distribuição normal, de média μ e desvio padrão $\sigma=2$. Uma amostra aleatória de dimensão 25 foi extraída desta população, tendo-se obtido $\bar{x} = 78.3$.

- Calcule o intervalo de confiança a 99% para μ .
- Qual o erro máximo cometido (a 99% de confiança) ao estimar μ por $\bar{x} = 78.3$?
- Qual deverá ser a dimensão da amostra para que o erro máximo cometido, a 99% de confiança, ao estimar μ por \bar{x} , não exceda 0.1?

3.11. Para avaliar a tensão máxima suportada por uma barra de aço testaram-se n barras tendo-se obtido $\bar{x}_n = 20$ e para extremo superior do intervalo de confiança a 95% para o verdadeiro médio da tensão obteve-se 21.7. Sabendo que se admite que a tensão suportada por uma barra de aço é uma v.a. normal com desvio padrão $\sigma = 3$, determine o extremo inferior do intervalo de confiança e a dimensão n da amostra.

3.12. Uma empresa de peixe congelado está a ser investigada com o objectivo de se verificar se cada embalagem pesa de facto 1 Kg em média. Numa amostra aleatória de 100 embalagens de peixe registou-se o peso (Kg) de cada embalagem, x_i ($i = 1, \dots, 100$), tendo-se obtido os seguintes valores:

$$\sum_{i=1}^{100} x_i = 95.9 \text{ Kg} \quad \sum_{i=1}^{100} x_i^2 = 93.12 \text{ Kg}^2$$

- Indique uma estimativa para a média e para a variância do peso de uma embalagem de peixe.
 - O que pode dizer sobre o resultado da investigação? Justifique convenientemente, especificando as hipóteses que necessitou de considerar.
 - Determine, explicitando as hipóteses necessárias, um intervalo a 95% de confiança para a variância do peso de uma embalagem de peixe.
- 3.13.** O grau de acidez do azeite produzido em certa região supõe-se ter distribuição normal. Uma amostra da produção de dimensão 25 conduziu a uma acidez média de 1 grau e a um desvio padrão de 0.33 graus.
- Face a estes valores, alguém sugeriu o intervalo $]0.815, 1.185[$ para o valor esperado da acidez. Qual o nível de confiança associado a este intervalo?

b) Para o nível de confiança determinado na alínea anterior, qual o erro máximo cometido ao estimar o verdadeiro valor médio da acidez por 1 grau?

3.14. Numa amostra de 16 elementos, que se supõe ter sido retirada de uma população com distribuição normal, o desvio padrão obtido foi de 5.2

a) Foi calculado um intervalo de confiança para a média populacional tendo-se obtido $]24.2297; 29.7703[$. Indique justificando:

i) Qual a média da amostra;

ii) Qual o grau de confiança do intervalo calculado.

b) Qual o intervalo de confiança a 95% para a variância populacional?

3.15. Num laboratório foi recentemente desenvolvido um método de análise mais rápido e barato do que o método convencional. Realizaram-se testes com o objectivo de comparar a precisão do novo método com a do convencional, repetindo-se sucessivamente a mesma análise. No seguinte quadro encontram-se cálculos efectuados com os resultados dos testes, em unidades adequadas (x designa o resultado do teste pela aplicação de cada um dos métodos):

	nº de observações	$\sum_i (x_i - \bar{x})^2$
Método convencional	24	30.5
Método novo	30	55.7

Sendo a precisão de um método medida pela variância dos resultados da aplicação desse método, poder-se-á concluir que os dois métodos têm precisões distintas? Que hipóteses é necessário admitir para responder a esta questão?

3.16. Cada um de dois fabricantes de máquinas de lavar tem uma rede de vendas nacional, COM UM REPRESENTANTE POR CIDADE. Seleccionaram-se aleatoriamente dez representantes de cada fabricante. A média de máquinas vendidas pelos 10 representantes do fabricante A (durante um ano) foi $\bar{x}_1 = 84$ com um desvio padrão $s_1 = 8$. A média de máquinas vendidas pelos 10 representantes do fabricante B foi $\bar{x}_2 = 77$, com um desvio padrão $s_2 = 10$ (no mesmo ano). Responda às seguintes alíneas, explicitando em cada caso qualquer hipótese adicional que seja necessária.

a) Será que a variância das vendas dos representantes de cada fabricante é igual?

b) Comente a veracidade da seguinte afirmação: "os representantes do fabricante A vendem em média tantas máquinas de lavar como os representantes do fabricante B".

c) Suponha agora que foram seleccionadas aleatoriamente 10 cidades do país onde os resultados das vendas (durante o mesmo ano) foram as seguintes:

Fab. A	76	60	85	58	91	75	82	64	79	90
Fab. B	81	52	87	70	86	77	90	63	85	85

Comente neste caso a afirmação da alínea b).

- d) Independentemente dos resultados concretos obtidos nas alíneas b) e c), se tivesse que decidir qual o processo estatístico a utilizar para aferir da validade da afirmação da alínea b), qual escolheria: a selecção aleatória de 10 representantes de cada fabricante ou a selecção aleatória de dez cidades? Justifique a sua resposta.

- 3.17.** Numa experiência agronómica pretende-se avaliar o crescimento total de uma certa espécie de plantas (expresso em peso seco) relativamente a dois regimes de fertilização A e B.

Ao fim de determinado tempo procedeu-se a medições, tendo-se obtido os seguintes resultados:


A	5.44	5.36	5.60	6.46	6.75	6.03	4.15	4.44
B	5.12	3.80	4.96	6.43	5.03	5.08	3.22	4.42

- a) Numa experiência anterior (com um elevado número de plantas da mesma cultivar) relativa ao tratamento A, obteve-se uma variância de 0.42. Verifique se os dados actuais são consistentes com esse valor. Diga, justificando, se haveria alguma(s) hipótese(s) necessária(s) à resolução do problema.
- b) Verifique se os dois regimes de fertilização A e B evidenciam diferenças significativas no que respeita ao crescimento das plantas. Explícite as hipóteses necessárias à resolução do problema.

- 3.18.** Num estudo sobre o número de folhas por planta de tabaco, obtiveram-se os seguintes dados:

n.º de folhas	17	18	19	20	21	22	23	24
n.º de plantas	3	22	44	42	22	10	6	1

- a) Indique a unidade estatística e a variável em estudo.
- b) Determine a média e a mediana da amostra. Compare-as e comente.
- c) Com base nesta amostra poder-se-á afirmar que 90% das plantas de tabaco têm 21 ou menos folhas? Justifique.

- 3.19.** Duas marcas de chocolate (A e B) produzem chocolate rotulado “70% de cacau”. Seleccionaram-se aleatoriamente 15 chocolates de cada uma das marcas, que foram analisados quanto ao teor de cacau. Os resultados foram introduzidos no *software* . Utilize, sempre que possível, os resultados apresentados abaixo para responder às seguintes questões (alguns cálculos apresentados são desnecessários ou inadequados).

- Conjectura-se que as variabilidades do teor de cacau dos chocolates das duas marcas são diferentes. Será esta conjectura compatível com os dados obtidos? Explícite e valide os pressupostos necessários à resolução do problema.
- Indique estimativas para o valor esperado do teor de cacau dos chocolates de cada uma das marcas.
- Os dados recolhidos evidenciam que o teor médio de cacau do chocolate da marca A é significativamente superior ao da marca B? Explícite e valide os pressupostos necessários à resolução do problema.
- O produtor de chocolate da marca A afirma que o teor médio de cacau do seu chocolate é superior a 70%. O que pode dizer sobre a afirmação do produtor? Justifique convenientemente.

Especifique as hipóteses nula e alternativa de um teste de hipóteses que permita averiguar a validade desta afirmação.

```

> A
[1] 72.8 69.6 70.0 73.3 69.8 71.1 71.0 71.0 71.0 76.3 71.3 75.4 72.1 70.4 68.6
> B
[1] 69.8 71.3 67.3 69.4 67.7 67.9 70.7 70.5 70.2 71.4 71.6 73.1 70.6 68.5 70.2

> var(A)           > var(B)           > var(A-B)
[1] 4.483143       [1] 2.616952       [1] 3.643810

> shapiro.test(A)           > shapiro.test(B)
      Shapiro-Wilk normality test           Shapiro-Wilk normality test
data:  A                                   data:  B
W = 0.9066, p-value = 0.1199             W = 0.9613, p-value = 0.7144

> shapiro.test(A-B)
      Shapiro-Wilk normality test
data:  A - B
W = 0.9754, p-value = 0.9283

> var.test(A,B)
      F test to compare two variances
data:  A and B
F = 1.7131, num df = 14, denom df = 14, p-value = 0.3254
alternative hypothesis: true ratio of variances is not equal to 1
95 percent confidence interval:
 0.5751437 5.1026658
sample estimates:
ratio of variances

```

1.713116

```
> t.test(A,B,paired=T,alternative="less")
```

```
Paired t-test
```

```
data: A and B
```

```
t = 3.1787, df = 14, p-value = 0.9967
```

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

```
95 percent confidence interval:
```

```
-Inf 2.434763
```

```
sample estimates:
```

```
mean of the differences
```

```
1.566667
```

```
> t.test(A,B,paired=T,alternative="greater")
```

```
Paired t-test
```

```
data: A and B
```

```
t = 3.1787, df = 14, p-value = 0.003349
```

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

```
95 percent confidence interval:
```

```
0.6985701      Inf
```

```
sample estimates:
```

```
mean of the differences
```

```
1.566667
```

```
> t.test(A,B,paired=F,var.equal=T,alternative="less")
```

```
Two Sample t-test
```

```
data: A and B
```

```
t = 2.2771, df = 28, p-value = 0.9847
```

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

```
95 percent confidence interval:
```

```
-Inf 2.737039
```

```
sample estimates:
```

```
mean of x mean of y
```

```
71.58000 70.01333
```

```
> t.test(A,B,paired=F,var.equal=T,alternative="greater")
```

```
Two Sample t-test
```

```
data: A and B
```

```
t = 2.2771, df = 28, p-value = 0.01531
```

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

```
95 percent confidence interval:
```

```

0.3962939      Inf
sample estimates:
mean of x mean of y
71.58000  70.01333

```

3.20. Para decidir se deveria ou não lançar um novo produto no mercado, uma empresa de bens alimentares fez um inquérito em 10 supermercados do Sul e 20 do Norte do país, acerca do número de unidades X do referido produto que estes esperam poder vender semanalmente. Obtiveram-se os seguintes resultados:

	$\sum x_i$	$\sum x_i^2$
Sul	1000	102550
Norte	1200	75950

- Determine estimativas para o número médio e para a variância das unidades que os supermercados do Sul e do Norte esperam vender.
- “Embora a média de vendas difira significativamente no Norte e Sul, a variabilidade das vendas é praticamente igual”. Critique fundamentadamente a afirmação anterior, justificando.

3.21. A fim de investigar os efeitos de ambientes nitrosos e de ambientes fosfatados no desenvolvimento de colónias de bactérias, contaminam-se 10 plaquetas envolvidas em cada um daqueles ambientes com as bactérias em estudo, e deixa-se incubar durante 24 horas. Após esse tempo, procede-se à contagem do número de colónias de bactérias em cada plaqueta, tendo-se obtido os seguintes resultados:

Ambiente nitroso	60	47	12	29	51	46	49	74	63	101
Ambiente fosfatado	8	46	21	13	58	33	20	46	31	38

- Investigue a hipótese de o tipo de ambiente não influir no desenvolvimento das colónias de bactérias.
- Que hipótese(s) foi necessário considerar para poder resolver a alínea a)?

3.22. Numa Estação Florestal estudam-se problemas de intercepção de precipitação. Nesse sentido em 12 dias de chuva (suponha que se trata de uma amostra aleatória de dias com precipitação) são colocados dois udómetros para medir a quantidade de precipitação: um numa zona desarborizada e outro sob as copas das árvores. As leituras da quantidade de água em cada udómetro (medidas em cm de altura) deram os seguintes valores (cada coluna corresponde a um dia):

zona descoberta	5.87	1.30	2.34	2.82	5.89	9.09	1.93	9.27	4.65	4.35	5.00	8.43
sob coberto	4.96	1.14	2.24	2.26	4.75	7.83	1.86	8.85	4.17	3.65	4.08	7.99

- a) Estime a precipitação média na zona desarborizada e na zona sob coberto.
- b) Será admissível supor que a 95% de confiança as precipitações médias nos dois casos são iguais? Explícite as hipóteses necessárias à resolução desta questão.
- c) Tendo em conta que, pela própria natureza do problema, o nível de precipitação sob coberto não deverá ser superior ao nível da correspondente precipitação a descoberto, indique um procedimento estatístico mais adequado para avaliar se existem diferenças significativas nos dois casos.
- 3.23.** Pretende-se testar se a proporção de ulmeiros afectados pela grafiose é idêntica em duas zonas A e B. Na zona A foi recolhida uma amostra aleatória de 30 ulmeiros e verificou-se que 20 estavam afectados pela grafiose. Na zona B recolheu-se uma amostra de 35 ulmeiros e verificou-se que 27 estavam afectados pela grafiose. Que conclusão se pode tirar ao nível de significância de 0.05?
- 3.24.** Diga, justificando, se cada uma das afirmações seguintes é verdadeira ou falsa:
- a) Num teste de hipóteses $H_0 : \mu = 0$ vs. $H_1 : \mu \neq 0$ em que se obteve um $p\text{-value} = 0.034$, não se rejeita a hipótese de a média populacional ser nula com um nível de significância de 0.01.
- b) Se $]2.15, 3.24[$ é um intervalo de confiança a 95% para σ^2 então a probabilidade de σ^2 pertencer a este intervalo é igual a 0.95.
- 3.25.** Suponha que o rendimento de um pé de tomateiro expresso em kg é uma variável aleatória com distribuição normal de valor médio 1 kg. Numa parte da produção foi utilizado um novo fertilizante. Observada uma amostra de 10 pés de tomateiro da parte da produção em que foi utilizado o novo fertilizante obtiveram-se os seguintes resultados:
- 1.375 1.223 1.773 1.752 0.779 1.407 1.068 1.633 1.201 1.042
- expressos em kg. Que decisão se deverá tomar perante estes resultados, face ao novo fertilizante?
- 3.26.** Um processo de determinação do conteúdo de enxofre de um determinado produto forneceu os seguintes resultados:
- 1.12 1.10 1.08 1.06 1.08 1.14 1.10 1.11 1.14
- a) Encontre um intervalo de confiança a 95% para o verdadeiro conteúdo médio de enxofre, apresentando as hipóteses a fazer sobre a população que achar convenientes.
- b) De acordo com certas normas, o conteúdo de enxofre não deve ter um desvio padrão superior a 0.02. Acha que a amostra recolhida permite afirmar que o produto está dentro das normas? Justifique convenientemente a resposta.

- c) De uma outra fábrica que produz idêntico produto recolheu-se uma mostra de 20 elementos que proporcionou um desvio padrão de 0.085. Pode concluir que a variabilidade do conteúdo de enxofre é, nesta fábrica, três vezes superior à da outra?

3.27. É desencadeado um programa de controlo da poluição de um rio em que são efectuadas medições, antes de lançar a campanha antipoluição e um ano após. As medições são combinações de vários índices; quanto maior for o valor resultante maior é a poluição. Obtiveram-se os seguintes resultados:

Ponto de controlo	1	2	3	4	5	6	7	8	9	10
Antes da campanha	68	88	101	82	96	74	65	74	52	99
Um ano após	67	87	90	76	98	69	68	65	59	70

Será que a campanha antipoluição reduziu de facto a poluição? Explícite e verifique todas as hipóteses necessárias à resolução do problema, justificando.

3.28. Para comparar dois tipos de máquina de ceifar (segadeiras) quanto à sua eficiência, foram seleccionadas ao acaso 9 searas tendo sido cada uma dividida em dois lotes. Em cada seara uma das segadeiras foi atribuída ao acaso a um dos lotes, ficando a outra para o outro lote.

A eficiência é avaliada num intervalo de valores de 0 (eficiência mínima) a 10 (eficiência máxima). Os valores registados relativos à eficiência de cada segadeira foram introduzidos no *software* R. Responda às seguintes questões utilizando os resultados de alguns dos comandos apresentados abaixo.

- Indique uma estimativa da eficiência média de cada uma das segadeiras.
- Calculou-se um intervalo a 95% de confiança para a variância da eficiência da segadeira 1, tendo-se obtido $[0.5144; 4.1381]$. Qual o valor observado para a variância da segadeira 1?
- Será que a segadeira 1 é mais eficiente do que a segadeira 2? Justifique convenientemente indicando e validando as condições necessárias à resolução.

```
> # seg1 designa os valores observados de eficiência da segadeira 1
> # seg2 designa os valores observados de eficiência da segadeira 2

> mean(seg1)      > mean(seg2)      > var(seg2)      > var(seg1-seg2)
[1] 7.4           [1] 6.488889      [1] 0.5861111    [1] 0.6761111

> shapiro.test(seg1)                               > shapiro.test(seg2)
      Shapiro-Wilk normality test                               Shapiro-Wilk normality test
data:  seg1                                                  data:  seg2
W = 0.8848, p-value = 0.1762                                W = 0.9105, p-value = 0.3193
```

```

> shapiro.test(seg1-seg2)
      Shapiro-Wilk normality test
data:  seg1 - seg2
W = 0.9648, p-value = 0.8472

> t.test(seg1,seg2,paired=T,alternative="two.sided")
      Paired t-test
data:  seg1 and seg2
t = 3.3242, df = 8, p-value = 0.01047
alternative hypothesis: true difference in means is not equal to 0
95 percent confidence interval:
 0.2790663 1.5431559
sample estimates:
mean of the differences
      0.9111111

> t.test(seg1,seg2,paired=T,alternative="greater")
      Paired t-test
data:  seg1 and seg2
t = 3.3242, df = 8, p-value = 0.005237
alternative hypothesis: true difference in means is greater than 0
95 percent confidence interval:
 0.4014339      Inf
sample estimates:
mean of the differences
      0.9111111

> t.test(seg1,seg2,paired=T,alternative="less")
      Paired t-test
data:  seg1 and seg2
t = 3.3242, df = 8, p-value = 0.9948
alternative hypothesis: true difference in means is less than 0
95 percent confidence interval:
 -Inf 1.420788
sample estimates:
mean of the differences
      0.9111111

> t.test(seg1,seg2,paired=F,alternative="two.sided")
      Welch Two Sample t-test

```

```

data: seg1 and seg2
t = 2.088, df = 14.548, p-value = 0.05482
alternative hypothesis: true difference in means is not equal to 0
95 percent confidence interval:
 -0.02147036  1.84369258
sample estimates:
mean of x mean of y
 7.400000  6.488889

```

```


> t.test(seg1,seg2,paired=F,alternative="greater")
      Welch Two Sample t-test
data: seg1 and seg2
t = 2.088, df = 14.548, p-value = 0.02741
alternative hypothesis: true difference in means is greater than 0
95 percent confidence interval:
 0.1446037      Inf
sample estimates:
mean of x mean of y
 7.400000  6.488889

```

```

> t.test(seg1,seg2,paired=F,alternative="less")
      Welch Two Sample t-test
data: seg1 and seg2
t = 2.088, df = 14.548, p-value = 0.9726
alternative hypothesis: true difference in means is less than 0
95 percent confidence interval:
 -Inf 1.677619
sample estimates:
mean of x mean of y
 7.400000  6.488889

```

3.29. Uma máquina de ensacar está regulada para encher sacos com 16 *kg* de açúcar. Para controlar o seu funcionamento escolheram-se, aleatoriamente, 15 sacos, que foram pesados. Os valores obtidos foram introduzidos no *software* . Responda às seguintes questões utilizando, sempre que possível, os resultados dos comandos apresentados.

- a) Indique uma estimativa para o peso médio e para a variância do peso de cada saco.
- b) Foi calculado um intervalo de confiança para a variância do peso de cada saco, σ^2 , tendo-se obtido]0.01368 ; 0.04931[.
 - i) Qual o estimador que foi utilizado na construção do intervalo?

- ii) Determine o nível de confiança do intervalo dado.
- c) Que conclusão pode tirar quanto à regulação da máquina? Justifique convenientemente, indicando e validando os pressupostos necessários à sua resposta.

```
> peso
[1] 16.1 15.8 15.9 16.1 15.8 16.2 16.0 15.9 16.0 15.7 15.8 15.7 16.0 16.0 15.8

> mean(peso)
[1] 15.92

> var(peso)
[1] 0.02314286

> shapiro.test(peso)
Shapiro-Wilk normality test
data: peso
W = 0.9377, p-value = 0.3544
```

3.30. Um enólogo pretende avaliar a acidez total de um vinho. Para isso selecciona aleatoriamente 20 garrafas de vinho na adega e analisa o seu conteúdo através do método clássico e de um dispositivo de titulação automática. Alguns resultados das análises, em g/l, foram:

garrafa	1	2	3	...	18	19	20
método clássico	4.8	3.4	2.5	...	2.9	5.4	2.1
titulação automática	6.1	5.1	2.1	...	4.5	3.9	1.5

Os dados foram introduzidos no *software* R. Abaixo apresentam-se resultados de comandos, alguns inadequados. Responda às seguintes questões utilizando os resultados apresentados abaixo.

- a) De acordo com a legislação em vigor um vinho de mesa deverá ter uma acidez total superior a 3.5 g/l. Com base nos resultados das análises efectuadas pelo método clássico, o enólogo poderá concluir que o seu vinho cumpre os requisitos de acidez impostos pela legislação? Explícite e valide os pressupostos necessários à resolução do problema.
- b) Com base nos valores obtidos poder-se-á concluir que os dois métodos de análise da acidez total do vinho têm resultados significativamente diferentes? Explícite e valide os pressupostos necessários à resolução do problema.

```
> classico
[1] 4.8 3.4 2.5 3.8 4.3 3.6 3.5 3.5 4.0 3.6 6.3 3.0 3.1 3.7 2.8 5.1 4.0 2.9 5.4 2.1

> automatico
[1] 6.1 5.1 2.1 4.9 6.6 4.0 4.5 1.0 4.7 3.5 8.2 3.9 3.6 4.5 3.5 6.3 4.7 4.5 3.9 1.5

> var(classico)
[1] 1.040105

> var automatico
[1] 2.887868

> var(classico-automatico)
[1] 1.326605
```

```

> shapiro.test(classico)
      Shapiro-Wilk normality test
data:  classico
W = 0.951, p-value = 0.3827

> shapiro.test(classico-automatico)
      Shapiro-Wilk normality test
data:  classico - automatico
W = 0.9163, p-value = 0.08413

> shapiro.test(automatico)
      Shapiro-Wilk normality test
data:  automatico
W = 0.9625, p-value = 0.5959

> t.test(classico,mu=3.5)
      One Sample t-test
data:  classico
t = 1.184, df = 19, p-value = 0.2510
alternative hypothesis: true mean is not equal to 3.5
95 percent confidence interval:
 3.292693 4.247307
sample estimates:
mean of x
 3.77

> t.test(classico,mu=3.5,alternative="greater")
      One Sample t-test
data:  classico
t = 1.184, df = 19, p-value = 0.1255
alternative hypothesis: true mean is greater than 3.5
95 percent confidence interval:
 3.375677      Inf
sample estimates:
mean of x
 3.77

> t.test(classico,mu=3.5,alternative="less")
      One Sample t-test
data:  classico
t = 1.184, df = 19, p-value = 0.8745
alternative hypothesis: true mean is less than 3.5
95 percent confidence interval:
 -Inf 4.164323
sample estimates:
mean of x
 3.77

```

```

> t.test(classico,automatico,paired=FALSE, var.equal=TRUE)
      Two Sample t-test
data:  classico and automatico
t = -1.32, df = 38, p-value = 0.1947
alternative hypothesis: true difference in means is not equal to 0
95 percent confidence interval:
 -1.4821486  0.3121486
sample estimates:
mean of x mean of y
   3.770    4.355

> t.test(classico,automatico,paired=TRUE)
      Paired t-test
data:  classico and automatico
t = -2.2714, df = 19, p-value = 0.03493
alternative hypothesis: true difference in means is not equal to 0
95 percent confidence interval:
 -1.12405128 -0.04594872
sample estimates:
mean of the differences
          -0.585

```

3.31. Uma associação de defesa de consumidores pretende publicar um estudo comparativo dos preços de dois supermercados. Para isso seleccionou 20 produtos e registou os preços de cada um nos supermercados A e B (em cêntimos):

Produto	1	2	3	4	5	6	...	15	16	17	18	19	20
Super. A	202	201	560	253	384	332	...	624	851	742	501	476	765
Super. B	185	187	516	239	349	295	...	613	851	731	546	490	762

Utilize os resultados apresentados abaixo para responder às seguintes questões.

- Determine uma estimativa para a diferença dos preços médios nos dois supermercados.
- Com base nos dados recolhidos, o que pode afirmar relativamente aos preços médios praticados pelos dois supermercados? Explícite e valide as hipóteses necessárias à resolução do problema.

```

> A
[1] 202 201 560 253 384 332 549 722 153 676 804 535 472 335 624 851 742 501 476 765
> B
[1] 185 187 516 239 349 295 552 667 132 676 745 529 460 316 613 851 731 546 490 762

> mean(A)      > mean(B)      > var(A)      > var(B)      > var(A-B)
[1] 506.85      [1] 492.05      [1] 46116.77   [1] 46454.68   [1] 568.379

> shapiro.test(A)
Shapiro-Wilk normality test
data:  A
W = 0.957, p-value = 0.4864

> shapiro.test(B)
Shapiro-Wilk normality test
data:  B
W = 0.9552, p-value = 0.4521

> shapiro.test(A-B)
Shapiro-Wilk normality test
data:  A - B
W = 0.9514, p-value = 0.3889

```

Exercícios de Revisão de Inferência Estatística

R3.1. Recolheu-se uma amostra aleatória de dimensão 5 de uma população normal. Determine a probabilidade de o desvio padrão da amostra ser inferior ao desvio padrão da população.

R3.2. Seja X uma variável aleatória com distribuição binomial, $X \sim B(n, p)$. Considere os estimadores para p assim definidos $\widehat{P}_1 = \frac{X+1}{n+1}$ e $\widehat{P}_2 = \frac{X}{n+1}$

- Determine, em função dos parâmetros da distribuição de X , o valor médio e a variância dos estimadores \widehat{P}_1 e \widehat{P}_2 . Qual deles preferiria? Justifique.
- Suponha que numa amostra de dimensão 20, se observou a ocorrência de 5 sucessos. Determine uma estimativa para p .

R3.3. A quantidade (em *ppm*) de um poluente no solo de uma certa região é uma v.a. X que se admite ter distribuição normal com valor médio μ e variância σ^2 , desconhecidos.

Recolheu-se uma amostra de dimensão 10 tendo-se obtido o desvio padrão de 1.3943 *ppm*. Com base na amostra construiu-se o seguinte intervalo de confiança para μ

$$]22.447 ; 25.313[$$

- Indique estimativas do valor médio e da variância da quantidade daquele poluente no solo.
 - Qual o grau de confiança daquele intervalo?
 - Construa um intervalo a 95% de confiança para σ^2 .
- R3.4.** Num certo processo químico é muito importante que uma dada solução tenha um pH de exactamente 8.20. O método utilizado na determinação do pH fornece medições que se admite terem distribuição normal de valor médio igual ao verdadeiro valor do pH da solução e desvio padrão de 0.02.

Para avaliar o pH de uma solução, efectuaram-se 10 medições independentes tendo-se obtido os seguintes valores:

8.18 8.16 8.17 8.22 8.19 8.17 8.15 8.21 8.16 8.18

- Indique uma estimativa do valor médio do pH da solução.
- Com base nestas 10 medições, o que pode concluir relativamente à utilização desta solução no referido processo químico?
- Pretende-se efectuar um novo conjunto de medições para diminuir o erro máximo cometido na estimativa do verdadeiro valor do pH da solução. Mantendo-se todas as condições referidas acima, qual deverá ser o tamanho da amostra para que aquele erro máximo não exceda 0.01, a 95% de confiança?

R3.5. Faz-se uma experiência para saber se dois regimes alimentares A e B produzem o mesmo aumento de peso nos animais, durante um período de tempo fixado. Tomam-se 20 animais e de entre eles 10 ao acaso aos quais é dado o alimento A. Aos outros 10 é dado o alimento B. Os aumentos de peso (expressos em kg) no mesmo intervalo de tempo são os seguintes:

Regime A	-2.0	0.0	4.2	6.3	9.6	4.3	10.2	11.0	12.4	13.1
Regime B	4.0	6.0	8.0	11.3	12.3	14.4	14.5	14.7	14.7	16.0

Diga se existe diferença significativa entre os dois regimes alimentares, justificando convenientemente todas as hipóteses necessárias à resolução do problema.

R3.6. Um estudo pretende comparar um tipo de semente melhorada com o tipo de semente usado anteriormente. A nova semente passará a ser utilizada se, em média, o crescimento das plantas após 20 dias fôr superior ao das obtidas das ‘velhas’ sementes. São criadas 15 diferentes situações laboratoriais, variando temperatura e humidade. Em cada situação semeia-se uma semente de cada tipo e obtêm-se os seguintes resultados para o crescimento (em cm) das plantas após 20 dias :

Situação	1	2	3	4	5	6	7	8
Sementes melhoradas	3.46	3.48	2.74	2.83	4.00	4.95	2.24	6.92
sementes tradicionais	3.18	3.67	2.92	3.10	4.10	4.86	2.21	6.91

Situação	9	10	11	12	13	14	15
sementes melhoradas	6.57	6.18	8.30	3.44	4.47	7.59	3.87
sementes tradicionais	6.83	6.19	8.05	3.46	4.18	7.43	3.85

Deverá passar a usar-se as sementes melhoradas? Responda justificando e explicitando quaisquer hipóteses adicionais que seja necessário impôr.

R3.7. Num estudo sobre a incidência de certa doença numa população de insectos, um grupo de biólogos registou ao longo de um ano o número de insectos contaminados em cada amostra de 5 insectos, tendo para tal recolhido 100 amostras. Os resultados obtidos foram:

Num. de insectos contaminados	0	1	2	3	4	5
Num. de amostras	9	26	34	22	8	1

- Construa uma tabela de frequências absolutas, relativas e relativas acumuladas para o número de insectos contaminados por amostra.
- Determine a média e a mediana do número de insectos contaminados por amostra.
- Considerando agora a totalidade de insectos observados como uma amostra aleatória da população de insectos:
 - Determine uma estimativa da verdadeira proporção de insectos contaminados.

- ii) Qual é o erro máximo associado à estimativa obtida na alínea anterior, com uma confiança de 95% ?


R3.8. O dono de uma ervanária produz um chá relativamente ao qual afirma que é 90% eficaz para curar dores de cabeça. Num inquérito feito a 250 pessoas, 198 concordaram que o chá cura as dores de cabeça. Acha que o resultado do inquérito é compatível com a pretensão do produtor ?

R3.9. Um investigador pretende estudar a incidência a nível nacional, de uma doença que ataca os pinheiros. Observações efectuadas através do país resultaram em 1233 casos de pinheiros afectados (a nível nacional) num total de 4250 observações.

- a) Estime a percentagem de pinheiros afectados a nível nacional.
- b) Determine um intervalo a 95% de confiança para a verdadeira proporção de pinheiros afectados.

R3.10. Um agricultor pretende experimentar dois tipos (I e II) de semeador de milho para comparar a produtividade das duas máquinas.

Para isso, num campo agrícola marcaram-se aleatoriamente 10 parcelas de igual área sendo cada uma delas dividida em duas secções iguais. Em cada parcela sorteou-se a atribuição de um dos tipos de semeador a uma das secções.

A produtividade (em unidades adequadas) de cada um dos semeadores foi registada, e os dados foram introduzidos no *software* . Utilizando os resultados apresentados abaixo (alguns desnecessários), poderá o agricultor admitir que a produtividade esperada das duas máquinas é igual? Justifique convenientemente a sua resposta.

```
>x<-c(5.6, 8.4, 8.0, 8.6, 6.4, 7.8, 6.2, 7.7, 8.0, 7.7)
observações para o semeador tipo I.
>y<-c(6.0, 7.4, 7.3, 7.5, 6.4, 6.0, 5.5, 6.6, 5.6, 6.1)
observações para o semeador tipo II.
```

```
>mean(x)      >mean(y)      >mean(x-y)
[1] 7.44      [1] 6.44      [1] 1
```

```
>var(x)      >var(y)      >var(x-y)
[1] 1.018222  [1] 0.5448889  [1] 0.68
```

```
> shapiro.test(x)
```

Shapiro-Wilk normality test

```
data: x  
W = 0.8731, p-value = 0.1087
```

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

```
Shapiro-Wilk normality test
```

```
data: y  
W = 0.9026, p-value = 0.2341
```

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

```
Shapiro-Wilk normality test
```

```
data: x - y  
W = 0.9765, p-value = 0.9435
```

Soluções de alguns Exercícios

3.1. a) 0.2112

b) $\simeq 0.2112$

3.2. a) Como $n = 100$ é “grande”, pelo Teorema Limite Central, verifica-se para a média amostral, $\bar{X} = \sum_{i=1}^{100} X_i/n$, $\frac{\bar{X}-\mu}{\sigma/\sqrt{n}} \sim N(0, 1) \implies \frac{\bar{X}-31}{0.24} \sim N(0, 1)$. Logo, $P[\bar{X} < 30] \simeq \Phi\left(\frac{30-31}{0.24}\right) = \Phi(-4.17) = 1 - \Phi(4.17) = 1 - 1 = 0$

b) Seja $S_{100} = \sum_{i=1}^{100} X_i$ o peso total da amostra aleatória. Pelo Teorema Limite Central tem-se

$$\frac{S_{100} - 100\mu}{\sigma\sqrt{100}} \sim N(0, 1) \implies \frac{S_{100} - 3100}{24} \sim N(0, 1).$$

Então, $P[S_{100} > 3150] = 1 - P[S_{100} \leq 3150] \simeq 1 - \Phi\left(\frac{3150-3100}{24}\right) = 1 - \Phi(2.08) = 1 - 0.9812 = 0.0188$.

3.3. a) $\bar{x} = 56.2$ cm e $s = 4$ cm

b) 0.42074

c) $4/5=0.8$ cm.

3.4. b) p

d) $\hat{p}_1 = 1/3$ e $\hat{p}_2 = 1/2$

3.5. 1082

3.6. $\approx 1 - \Phi(0.4\sqrt{12n})$, para n elevado

3.7. ≈ 0.01267

3.10. a)]77.27, 79.33[

b) 1.03

c) 2654

3.11. 18.3 e $n = 12$

3.12. a) $\bar{x} = 0.959$ Kg e $s^2 = 0.0116$ Kg²

c)]0.00886, 0.0155[

3.13. a) 99%

b) 0.185

3.14. a) i) 27 ii) 0.95

b)]14.76, 64.77[

3.18. a) Unidade estatística: planta de tabaco; variável: nº de folhas por planta

b) $\bar{x} = 2967/150 = 19.78$ e $\tilde{x} = 20$

3.20. a) $\bar{x}_S = 100$, $\bar{x}_N = 60$, $s_S^2 = 288.33$ e $s_N^2 = 207.89$

3.24. a) Verdadeira

b) Falsa

R3.1. 0.7127

R3.2. a) $E[\widehat{P}_1] = \frac{np+1}{n+1}$; $E[\widehat{P}_2] = \frac{np}{n+1}$;

$Var[\widehat{P}_1] = Var[\widehat{P}_2] = \frac{npq}{(n+1)^2}$.

\widehat{P}_2 é o que apresenta menor EQM portanto é o melhor.

b) Usando o melhor estimador, \widehat{P}_2 , temos uma estimativa para p , $\hat{p}_2 = 5/21$.

R3.3. a) Estimativa do valor médio é $\bar{x} = 23.88$ ppm e de σ^2 é $s^2 = 1.9441$ ppm²

b) O grau de confiança é 99%.

R3.4. a) $\bar{x} = 8.179$

c) $n \geq 16$

R3.7. a)

x_i	Freq. Abs. n_i	Freq. Rel. f_i	Freq. Rel Acum. F_i
0	9	0.09	0.09
1	26	0.26	0.35
2	34	0.34	0.69
3	22	0.22	0.91
4	8	0.08	0.99
5	1	0.01	1.00

b) $\bar{x} = 197/100$ e $\tilde{x} = 2$

c) i) $\hat{p} = 197/500 = 0.394$ ii) 0.0428

R3.9. a) 29.01%

b)]0.2765, 0.3037[