

# Introdução à Inferência Estatística

- A Probabilidade e a Inferência Estatística.
- A amostragem. Principais Distribuições por Amostragem
- Tópicos de Estimação e de Inferência
  - ❖ estimação pontual
  - ❖ estimação por intervalos
  - ❖ testes de hipóteses

# A Probabilidade e a Inferência Estatística

Começámos esta unidade curricular pelo estudo descritivo de uma **amostra**. Passámos depois pela Introdução à Teoria da Probabilidade com o estudo de alguns dos modelos de probabilidade (discretos e contínuos).

Veremos agora como utilizar todo esse conhecimento na **Inferência Estatística**. A Inferência Estatística é ... *aquilo que permite o salto que vai da amostra para a população* (Pestana e Velosa, 2008).

Mas ... sem conhecimento da probabilidade não é possível avançar na inferência estatística. Apenas para breve “orientação” podemos dizer que:

- **na probabilidade temos o modelo da população** que nos permite calcular a probabilidade de certos acontecimentos;
- **na inferência estatística parte-se da amostra** e pretende-se obter informação sobre o modelo ou sobre características da população.

# Conceitos em Inferência Estatística

A **inferência estatística** tem como objectivos tirar conclusões sobre os parâmetros da população a partir da recolha, tratamento e análise dos dados de **uma amostra**, obtida nessa população.

## Conceitos básicos:

**População** → conjunto completo de todas os objectos (elementos) com uma (ou mais) característica(s) comuns;

**Unidade Estatística** → cada elemento da população;

**Amostra** → conjunto dos valores efectivamente observados;

**Parâmetro de uma população** → **constante** desconhecida, cujo verdadeiro valor se pretende “estimar” ou “validar”.

# Introdução à Teoria da Amostragem

**Amostragem** → procedimento de recolha de elementos da população para obter uma amostra.

De uma dada **população** podemos retirar muitas amostras:

- Amostra 1
- Amostra 2
- ...
- Amostra  $k$
- ...

**Mas** ... quase sempre recolhemos só **uma amostra** para estudarmos uma **característica  $X$**  da população.

Seja  $x_1, x_2, \dots, x_n$  uma amostra de  $n$  observações da característica, obtidas após um processo de amostragem.

# Introdução à Teoria da Amostragem

Vamos considerar a amostra  $x_1, x_2, \dots, x_n$  como uma realização de  $n$  variáveis  $X_1, X_2, \dots, X_n$  que são “cópias” da variável  $X$

## Recapitulando:

- **Antes** da amostragem ser realizada temos  $n$  variáveis aleatórias  $X_1, X_2, \dots, X_n$
- **Depois** de efectuada a amostragem temos um conjunto de dados que constituem a amostra observada  $x_1, \dots, x_n$ .

**Definição** Chama-se **amostra aleatória** de dimensão  $n$  a um conjunto de  $n$  variáveis aleatórias  $X_1, X_2, \dots, X_n$  **independentes** e **semelhantes**, i.e., tendo todas a mesma distribuição a da característica  $X$  em estudo na população.

# Tópicos de Estimação

Quais os **parâmetros desconhecidos** da população que nos vão interessar e que **procedimentos** usar para **os estimar**?

Os **procedimentos** são métodos adequados (queremos “os melhores” ...) para estimar os parâmetros desconhecidos. Em Estatística, esses métodos consistem na obtenção de variáveis aleatórias “especiais”, chamadas **estimadores**.

**Definição** Chama-se **estimador de um parâmetro** a uma função da amostra aleatória  $X_1, X_2, \dots, X_n$ , que “permite” obter um valor para o parâmetro desconhecido (esta função não possui quantidades desconhecidas).

**NOTA:** Não iremos referir procedimentos para obter estimadores

# Tópicos de Estimação

Um **estimador** é então **uma variável aleatória** que terá uma dada distribuição (pelo menos aproximadamente).

O valor que o estimador (variável aleatória) toma quando se observa a amostra chama-se **estimativa**.

**Definição Estimativa de um parâmetro** é um valor concreto assumido pelo estimador.

Dada a amostra aleatória,  $X_1, X_2, \dots, X_n$ , i.e., v.a. i.i.d. a  $X$ , vamos ver os **parâmetros** que nos vão interessar, os seus **estimadores** e **estimativas**

# Tópicos de Estimação

Parâmetro(s) a estimar

Estimador(es)

Estimativa(s)

$$\mu$$

$$\bar{X} = \frac{\sum_{i=1}^n X_i}{n}$$

$$\bar{x} = \frac{\sum_{i=1}^n x_i}{n}$$

$$\sigma^2$$

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

$$s^2 = \frac{\sum_{i=1}^n (x_i - \bar{x})^2}{n-1}$$

$$p$$

$$\hat{P} = \frac{X}{n} \text{ (a)}$$

$$\hat{p} = \frac{x}{n} \text{ (b)}$$

$$\mu_1 \text{ ?? } \mu_2$$

$$\bar{X}_1 \text{ ?? } \bar{X}_2$$

$$\bar{x}_1 \text{ ?? } \bar{x}_2$$

$$\sigma_1^2 \text{ ?? } \sigma_2^2$$

$$S_1^2 \text{ ?? } S_2^2$$

$$s_1^2 \text{ ?? } s_2^2$$

$$p_1 \text{ ?? } p_2$$

$$\hat{P}_1 \text{ ?? } \hat{P}_2$$

$$\hat{p}_1 \text{ ?? } \hat{p}_2$$

(a)  $X$  - v.a. que conta o número de sucessos na amostra de dimensão  $n$  ... e

(b)  $x$  - número observado de sucessos na amostra de dimensão  $n$ .

?? significa que teremos que escolher a melhor operação para fazer a comparação

# Tópicos de Estimação

**Temos uma amostra — como inferir para a população?**

- Estimação dos parâmetros
  - ❖ Estimação pontual
  - ❖ Estimação intervalar → intervalos de confiança
- Testes de hipóteses estatísticas.

**Estimação pontual** → indicar um único valor como estimativa → exemplos de estimativas:  $\bar{x}$ ,  $s^2$ ,  $\hat{p}$ ,  $\dots$ .

**Estimação por intervalos** → neste caso calcula-se um intervalo (aleatório) que com uma probabilidade elevada contenha o verdadeiro valor do parâmetro. Para a construção deste intervalo é necessário conhecer a distribuição - exacta ou aproximada - do **estimador** (ou qualquer expressão dele)

# Estimação por intervalos

**Definição** Chama-se **intervalo de confiança** ao intervalo que resulta da concretização do intervalo (aleatório) e é portanto um intervalo  $(a, b)$ , onde  $a$  e  $b$  são números reais e  $a < b$ .

**Relembre-se que** para obter o intervalo de confiança é então necessário conhecer **a lei do estimador** do parâmetro desconhecido.

Começemos então por ver como se construiria **um intervalo de confiança para  $\mu$** , (valor médio de uma característica  $X$ .)

Precisamos de procurar a distribuição do estimador de  $\mu \rightarrow \bar{X}$

- Seja  $X$  v.a. c/ dist. Normal , i.e.,  $X \sim N(\mu, \sigma)$   
Para uma amostra de dimensão  $n$  tem-se  $\bar{X}_n \sim N(\mu, \sigma/\sqrt{n})$

**Então . . .**

# Intervalo de confiança

## Intervalo de confiança a $(1 - \alpha) \times 100\%$ para $\mu$

- Seja  $X$  v.a. c/ dist. Normal, i.e.,  $X \sim N(\mu, \sigma)$

Se  $\sigma$  conhecido  $\rightarrow$  considera-se  $\frac{\bar{X} - \mu}{\sigma/\sqrt{n}} \sim N(0, 1)$

o intervalo a  $(1 - \alpha) \times 100\%$  de confiança para  $\mu$  é

$$\bar{x} - z_{\alpha/2} \frac{\sigma}{\sqrt{n}} < \mu < \bar{x} + z_{\alpha/2} \frac{\sigma}{\sqrt{n}}$$

( $z_{\alpha/2} \rightarrow$  valor da v.a.  $Z$  tal que  $P(Z > z_{\alpha/2}) = \alpha/2$ )

**Observações:** Chama-se **precisão da estimativa** à semi-amplitude do intervalo de confiança e **confiança** ou **grau de confiança** a  $(1 - \alpha) \times 100\%$

Quanto maior for o intervalo, maior é o grau de confiança, mas menor a precisão da estimativa.

# Exercício 1

Um método utilizado na determinação do pH de uma dada solução 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

- a) Indique uma estimativa do valor médio do pH da solução.
- b) Com base nestas 10 medições, determine um intervalo a 95% de confiança para o valor médio do pH da solução.
- c) Para um certo processo químico é muito importante que uma dada solução tenha um pH de exactamente 8.20. Com base no resultado da alínea anterior, o que pode concluir relativamente à utilização desta solução no referido processo químico?

# Distribuições por amostragem

A determinação de intervalos de confiança para os parâmetros  $\mu$ ,  $\sigma^2$ ,  $p$ ,  $\mu_1 - \mu_2$ ,  $\sigma_1^2/\sigma_2^2$  e  $p_1 - p_2$ , necessita do conhecimento da distribuição dos estimadores envolvidos  $\longleftrightarrow$  **distribuições por amostragem**



isto é, são distribuições de funções da amostra aleatória  $(X_1, X_2, \dots, X_n)$ , que vamos usar para obter **Intervalos de Confiança**

Já vimos

Se  $X \sim N(\mu, \sigma)$  e  $\sigma$  conhecido usamos  $\frac{\bar{X} - \mu}{\sigma/\sqrt{n}} \sim N(0, 1)$   
para construir um I.C. para o valor médio,  $\mu$ .

**Mas na maior parte das situações não conhecemos a variância.**


Então neste caso já não é possível obter um I.C. para  $\mu$ , pois os limites do intervalo dependem de  $\sigma$ , desconhecido.

# Resultados (distribuições) importantes


**Teorema** Sejam  $X_i$  ( $i = 1, \dots, n$ ) v.a. independentes com distribuição  $N(\mu, \sigma)$ . Então:

- $\left(\frac{X_i - \mu}{\sigma}\right)^2 \frown \chi_{(1)}^2$ , que se designa distribuição qui-quadrado com 1 grau de liberdade.
- $\sum_{i=1}^n \left(\frac{X_i - \mu}{\sigma}\right)^2 \frown \chi_{(n)}^2$ .


f. densidade da Qui-quadrado(n=4)



f. densidade da Qui-quadrado(n=10)




f. densidade da Qui-quadrado(n=20)



Gráficos da função densidade de uma v.a. com distribuição  $\chi_{(4)}^2$ ,  $\chi_{(10)}^2$  e  $\chi_{(20)}^2$ , da esquerda para a direita.

# Resultados importantes (cont.)

- $\frac{(n-1)S^2}{\sigma^2} \sim \chi_{(n-1)}^2$ , com  $S^2 = \frac{\sum_{i=1}^n (X_i - \bar{X})^2}{n-1}$
  - Sejam  $Z \sim N(0, 1)$  e  $Y \sim \chi_{(n)}^2$  v.a. independentes, então  $\frac{Z}{\sqrt{Y/n}} \sim t_{(n)}$ ,  $t_{(n)}$  diz-se distribuição *t* – Student com  $n$  g.l.
- Para mais informações ver quadro das distribuições contínuas.
- $\frac{\bar{X} - \mu}{S/\sqrt{n}} \sim t_{(n-1)}$ , com  $S^2 = \frac{\sum_{i=1}^n (X_i - \bar{X})^2}{n-1}$



Gráficos da função densidade de uma v.a. com distribuição  $N(0, 1)$ ,  $t_{(2)}$  e  $t_{(10)}$ .

# Intervalos de confiança (cont.)

O **Intervalo a  $(1 - \alpha) \times 100\%$  de confiança para  $\sigma^2$**  numa população normal, constrói-se usando a v.a.  $\frac{(n-1)S^2}{\sigma^2} \sim \chi^2_{(n-1)}$

$$\frac{(n-1)s^2}{\chi^2_{\alpha/2, (n-1)}} < \sigma^2 < \frac{(n-1)s^2}{\chi^2_{1-\alpha/2, (n-1)}}$$

O **Intervalo a  $(1 - \alpha) \times 100\%$  de confiança para  $\mu$**  com  $\sigma$  desconhecido, numa população normal, constrói-se usando a v.a.  $\frac{\bar{X} - \mu}{S/\sqrt{n}} \sim t_{(n-1)}$

$$\bar{x} - t_{\alpha/2, (n-1)} \frac{s}{\sqrt{n}} < \mu < \bar{x} + t_{\alpha/2, (n-1)} \frac{s}{\sqrt{n}}$$

# Intervalos de confiança (cont.)

**Intervalo de confiança a  $(1 - \alpha) \times 100\%$  para  $\mu$**

Se  $X$  tem **dist. qualquer não normal**

É necessário dispor de uma **amostra de dimensão elevada**, i.e.,  **$n$  grande**  
→ aplicação do Teorema Limite Central

$$\frac{\bar{X} - \mu}{\sigma/\sqrt{n}} \sim \mathcal{N}(0, 1) \quad \text{se } \underline{\sigma \text{ conhecido}}$$

Ou, que é o caso mais frequente,

$$\frac{\bar{X} - \mu}{s/\sqrt{n}} \sim \mathcal{N}(0, 1) \quad \text{se } \underline{\sigma \text{ desconhecido}}$$

$$\bar{x} - z_{\alpha/2} \frac{s}{\sqrt{n}} < \mu < \bar{x} + z_{\alpha/2} \frac{s}{\sqrt{n}}$$

# Intervalo de confiança para proporções

Dada  $X$  com **distribuição binomial** de parâmetros  $(n, p)$   
( $p$  parâmetro desconhecido).

Um **estimador** de  $p$  é  $\hat{P} = \frac{X}{n}$  ( $X$  é o número de sucessos em  $n$  provas)

Sendo a **estimativa**  $\hat{p} = \frac{x}{n}$  ( $x$  é o número observado de sucessos em  $n$  provas)

Se  $X \sim B(n, p)$  e  $n$  grande  
 $X \sim \mathcal{N}(np, \sqrt{npq})$

Intervalo de confiança  $(1 - \alpha) \times 100\%$  para  $p$

$$\hat{p} - z_{\alpha/2} \sqrt{\frac{\hat{p}(1-\hat{p})}{n}} < p < \hat{p} + z_{\alpha/2} \sqrt{\frac{\hat{p}(1-\hat{p})}{n}}$$

# Intervalos de confiança - duas populações

## Intervalos de confiança para $\mu_1 - \mu_2$ (amostras independentes)

Caso de duas populações normais i.e.,

$X_1 \sim \mathcal{N}(\mu_1, \sigma_1)$  e  $X_2 \sim \mathcal{N}(\mu_2, \sigma_2)$  com variâncias conhecidas

Retiram-se duas amostras aleatórias independentes com dimensões  $n_1$  e  $n_2$ , respectivamente.

Um estimador para  $\mu_1 - \mu_2$  é  $\bar{X}_1 - \bar{X}_2$  e

$$\bar{X}_1 - \bar{X}_2 \sim \mathcal{N}\left(\mu_1 - \mu_2, \sqrt{\frac{\sigma_1^2}{n_1} + \frac{\sigma_2^2}{n_2}}\right).$$

**Intervalo de confiança a  $(1 - \alpha) \times 100\%$  para  $\mu_1 - \mu_2$**

$$(\bar{x}_1 - \bar{x}_2) - z_{\alpha/2} \sqrt{\frac{\sigma_1^2}{n_1} + \frac{\sigma_2^2}{n_2}} < \mu_1 - \mu_2 < (\bar{x}_1 - \bar{x}_2) + z_{\alpha/2} \sqrt{\frac{\sigma_1^2}{n_1} + \frac{\sigma_2^2}{n_2}}$$

# Intervalos de confiança - duas populações

Caso de populações normais i.e.,  $X_1 \sim \mathcal{N}(\mu_1, \sigma_1)$  e  $X_2 \sim \mathcal{N}(\mu_2, \sigma_2)$  com variâncias desconhecidas.

## Amostras independentes:

- Se  $n_1, n_2$  grandes (e neste caso não é necessário ter-se normalidade) pode substituir-se no intervalo anterior  $\sigma_1^2$  por  $s_1^2$  e  $\sigma_2^2$  por  $s_2^2$ .
- Se  $n_1$  e  $n_2$  são pequenos, podemos contruir intervalos de confiança sob **certas hipóteses**
  - ❖ ambas as distribuições normais;
  - ❖ se for possível admitir variâncias populacionais iguais.

**Então ...**

# Intervalos de confiança - duas populações

A variável aleatória agora usada é

$$\frac{(\bar{X}_1 - \bar{X}_2) - (\mu_1 - \mu_2)}{S_p \sqrt{\left(\frac{1}{n_1} + \frac{1}{n_2}\right)}} \sim t_{(n_1+n_2-2)}$$

com  $S_p^2 = \frac{(n_1-1)S_1^2 + (n_2-1)S_2^2}{n_1+n_2-2}$

Intervalo de confiança a  $(1 - \alpha) \times 100\%$  para  $\mu_1 - \mu_2$  para duas populações normais, com variâncias desconhecidas mas supostas iguais

$$(\bar{x}_1 - \bar{x}_2) - t_{\alpha/2} s_p \sqrt{\frac{1}{n_1} + \frac{1}{n_2}} < \mu_1 - \mu_2 < (\bar{x}_1 - \bar{x}_2) + t_{\alpha/2} s_p \sqrt{\frac{1}{n_1} + \frac{1}{n_2}}$$

$$(t_{\alpha/2} \equiv t_{\alpha/2, (n_1+n_2-2)})$$

# Quociente de duas variâncias

O que pode fazer-se para averiguar a igualdade das variâncias populacionais?

Sejam duas populações normais  $X_1 \sim \mathcal{N}(\mu_1, \sigma_1)$  e  $X_2 \sim \mathcal{N}(\mu_2, \sigma_2)$  das quais retiramos duas amostras independentes de dimensões  $n_1$  e  $n_2$ , respectivamente.




O estimador para  $\frac{\sigma_1^2}{\sigma_2^2}$  é  $\frac{S_1^2}{S_2^2}$  e para construir o intervalo de confiança

a variável aleatória agora considerar é  $\frac{S_1^2/\sigma_1^2}{S_2^2/\sigma_2^2}$ . Surge aqui uma nova distribuição associada a esta variável aleatória, que se chama **distribuição  $F$**  (de Snedecor).

Vejamos a génese (a definição) desta distribuição:

# Distribuição $F$

**Teorema** Sejam  $U \sim \chi^2_{(m)}$  e  $V \sim \chi^2_{(n)}$  variáveis aleatórias independentes, então  $X = \frac{U/m}{V/n}$  diz-se ter distribuição  $F$  com  $(m, n)$  graus de liberdade e representa-se por  $X = \frac{U/m}{V/n} \sim F_{(m,n)}$ .



Gráficos da função densidade de uma v.a. com distribuição  $F_{(3,15)}$ ,  $F_{(10,10)}$  e  $F_{(15,3)}$ , da esquerda para a direita.

Prova-se que  $\frac{S_1^2/\sigma_1^2}{S_2^2/\sigma_2^2}$  tem distribuição  $F$  com  $(n_1 - 1, n_2 - 1)$  graus de liberdade.

# I.C. para o quociente de duas variâncias

Intervalo de confiança a  $(1 - \alpha) \times 100\%$  para  $\frac{\sigma_1^2}{\sigma_2^2}$

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

**Nota:** No caso de o intervalo de confiança para  $\frac{\sigma_1^2}{\sigma_2^2}$ , conduzir à conclusão que  $\sigma_1^2 \neq \sigma_2^2$ , Welch-Satterthwaite propõem o uso da variável aleatória

$$\frac{(\bar{X}_1 - \bar{X}_2) - (\mu_1 - \mu_2)}{\sqrt{\frac{S_1^2}{n_1} + \frac{S_2^2}{n_2}}} \approx t_{(\nu)},$$

sendo  $\nu$  calculado à custa das variâncias de cada uma da amostra — não mostraremos aqui a sua expressão. O uso deste estimador está já implementado no  - **ver a sua utilização nas aulas práticas.**

# Intervalos de confiança (amostras emparelhadas)

Consideremos que numa dada experiência as observações estão relacionadas, i.e, **emparelhadas** pelo indivíduo.

Seja  $(X_i, Y_i)$  ( $i = 1, \dots, n$ ) a **amostra emparelhada** e defina-se  $D_i = X_i - Y_i$ , isto é,  $(D_1, D_2, \dots, D_n)$  é a **amostra aleatória das diferenças**.

Se  $D_1, D_2, \dots, D_n$  são variáveis aleatórias provenientes de uma lei **normal** com valor médio  $\mu_D = \mu_X - \mu_Y$  e variância  $\sigma_D^2$ , **desconhecida** tem-se

$$\frac{\bar{D} - \mu_D}{S_D / \sqrt{n}} \sim t_{(n-1)}$$

## Intervalos de confiança (cont.)

Intervalo de confiança a  $(1 - \alpha) \times 100\%$  para  $\mu_D$

$$\bar{d} - t_{\alpha/2, (n-1)} \frac{s_D}{\sqrt{n}} < \mu_D < \bar{d} + t_{\alpha/2, (n-1)} \frac{s_D}{\sqrt{n}}$$

Se **não for possível admitir  $D_i$  normais**, mas se tenha **n “grande”** o intervalo de confiança  $(1 - \alpha) \times 100\%$  para  $\mu_D$  é

$$\bar{d} - z_{\alpha/2} \frac{s_D}{\sqrt{n}} < \mu_D < \bar{d} + z_{\alpha/2} \frac{s_D}{\sqrt{n}}$$

# Intervalos de confiança para proporções

## Consideremos agora o caso de duas proporções

Sejam  $X_1$  e  $X_2$  variáveis aleatórias tais que

$$X_1 \sim B(n_1, p_1) \quad \text{e} \quad X_2 \sim B(n_2, p_2).$$

$n_1$  e  $n_2$  dimensões de amostras aleatórias independentes

Os estimadores de  $p_1$  e  $p_2$  são  $\hat{P}_1 = X_1/n_1$  e  $\hat{P}_2 = X_2/n_2$

Se  $n_1$  e  $n_2$  “grandes” temos

$$\hat{P}_1 - \hat{P}_2 \sim \mathcal{N} \left( p_1 - p_2, \sqrt{\frac{p_1 q_1}{n_1} + \frac{p_2 q_2}{n_2}} \right)$$

**Intervalo de confiança a  $(1 - \alpha) \times 100\%$  para  $p_1 - p_2$  quando as dimensões das amostras são elevadas**

$$(\hat{p}_1 - \hat{p}_2) - z_{\alpha/2} \sqrt{\frac{\hat{p}_1 \hat{q}_1}{n_1} + \frac{\hat{p}_2 \hat{q}_2}{n_2}} < p_1 - p_2 < (\hat{p}_1 - \hat{p}_2) + z_{\alpha/2} \sqrt{\frac{\hat{p}_1 \hat{q}_1}{n_1} + \frac{\hat{p}_2 \hat{q}_2}{n_2}}$$

## Exercício 2

Um estudo pretende comparar um tipo de semente melhorada com o tipo de semente tradicional usado anteriormente. A semente melhorada passará a ser utilizada se, em média, o crescimento das plantas após 20 dias fôr superior ao verificado nas sementes tradicionais. 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 cms) 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

Poderá considerar-se haver diferença significativa entre os dois tipos de sementes? Responda justificando e explicitando quaisquer hipóteses adicionais que seja necessário impôr.

## Exercício 3

Pretende-se avaliar se um certo adubo  $A$  aumenta a produção de determinada cultivar do cereal  $T$ . Para tal efeito um experimentador plantou 2 talhões com a referida cultivar, tendo aplicado o adubo  $A$  só num deles. De cada talhão foram então amostradas 12 áreas de  $1\text{m}^2$ . Em cada uma destas áreas foram colhidas todas as plantas e pesado o grão. Os dados obtidos, expressos em gramas foram os seguintes:

Talhão c/ adubo	422	460	455	466	475	472	465	456	452	430	458	470
Talhão s/ adubo	470	437	429	447	432	457	422	425	432	474	452	442

O que decidiria quanto à utilização do adubo?

# Introdução aos Testes de Hipóteses

- Hipóteses estatísticas. Hipótese nula/Hipótese alternativa.
- Passos necessários à elaboração de um teste de hipóteses.
- Testes sobre parâmetros de uma ou de duas populações.
- Teste de normalidade e “teste do qui-quadrado” de ajustamento.

# Testes de Hipóteses

Até aqui estivemos a tratar de **Intervalos de Confiança**, isto é, a construir intervalos de valores que, com uma confiança elevada, contêm o verdadeiro valor do parâmetro desconhecido.

**Mas ...** vamos agora ver uma outra forma de decidir se uma dada suposição (relativa ao(s) parâmetro(s) desconhecido(s) ou outros aspectos da característica em estudo) **é** ou **não** suportada pela informação fornecida pelos dados de uma amostra.

Vamos então **formular Testes de Hipóteses** e indicar como, **com base numa amostra observada**, se pode tomar decisões relativamente às hipóteses formuladas.

**Note-se que** os quadros com Intervalos de confiança e os quadros dos Testes de Hipóteses seguem a mesma estrutura, portanto as variáveis usadas na construção dos intervalos de confiança são as que iremos também aqui usar.

# Testes de Hipóteses

**Uma hipótese estatística** é qualquer conjectura sobre aspectos desconhecidos da população (que podem ser parâmetros ou mesmo a forma da distribuição).

Se a hipótese diz respeito a:

- **um parâmetro**, supondo conhecida a forma da distribuição, a hipótese diz-se **paramétrica**.
- **investigar a forma da distribuição**, ou **um parâmetro** sem admitir o conhecimento da forma da distribuição, a hipótese diz-se **não paramétrica**.

**Um teste de hipóteses** é então um procedimento que permite decidir se uma dada hipótese **é** ou **não** suportada pela informação fornecida pelos dados de uma amostra.

# Testes de Hipóteses

Um teste diz-se **paramétrico** se as **hipóteses** envolvidas são **paramétricas**, isto é, dizem respeito ao(s) parâmetro(s), supondo conhecida, pelo menos aproximadamente, a forma da distribuição.

## Metodologia a seguir num teste de hipóteses:

- Como uma dada afirmação pode ser verdadeira ou falsa, formulam-se duas hipóteses alternativas:

**Hipótese nula** -  $H_0$  - corresponde ao *statu quo*, i.e., é a hipótese que especifica o valor “actual” do(s) parâmetro(s) (é considerada verdadeira até haver evidência estatística para a sua rejeição) e

**Hipótese alternativa** -  $H_1$  - onde se especificam o(s) valor(es) a “aceitar” quando se rejeita a hipóteses nula.

# Testes de Hipóteses- Exemplos

1.  $H_0 : \mu = 1$  v.s.  $H_1 : \mu \neq 1$
2.  $H_0 : \mu = 3$  v.s.  $H_1 : \mu < 3$
3.  $H_0 : \mu = 1$  v.s.  $H_1 : \mu > 1$
4.  $H_0 : \mu \geq \mu_0$  v.s.  $H_1 : \mu < \mu_0$
5.  $H_0 : X \sim \text{Normal}$  v.s.  $H_1 : X$  segue outra distribuição

O último exemplo é um teste para verificar se uma dada característica segue uma distribuição (neste caso a normal).

Designa-se habitualmente por **teste de normalidade**.

# Exemplo 1

Numa linha de engarrafamento de azeite a quantidade deitada em cada garrafa é uma variável aleatória que se admite ter distribuição normal. O processo de enchimento considera-se regulado se  $\mu = 1$  *litro*, não sendo de admitir grandes desvios. Para controlar o processo de enchimento escolheram-se ao acaso 20 garrafas da produção diária. Suponha que se obteve uma média de 0.965 litros com um desvio padrão de 0.08 *litros*. Poder-se-á dizer que o processo não está regulado? Justifique convenientemente a resposta.

**Resolução:** Para averiguar se o processo não está regulado, podemos formular um teste das hipóteses:

$$\mathbf{H}_0 : \mu = 1 \quad \text{v.s.} \quad \mathbf{H}_1 : \mu \neq 1$$

# Testes de Hipóteses

- A resposta num teste de hipóteses é dada na forma
  - ❖ **Rejeitar  $H_0$**  - significa que os dados observados testemunham fortemente **contra  $H_0$**  - neste caso será **adoptada a hipótese  $H_1$**  ou
  - ❖ **Não rejeitar  $H_0$**  - significa que **não há evidência suficiente para rejeitar  $H_0$** .

Tomar decisões para a população com base numa amostra possui riscos (i.e. podem cometer-se erros). Vejamos o quadro:

	<b>Decisões</b>	
<b>Realidade</b>	<b>Rejeitar <math>H_0</math></b>	<b>Não rejeitar <math>H_0</math></b>
<b><math>H_0</math> verdadeira</b>	<b>ERRO de tipo I</b>	não há erro
<b><math>H_0</math> falsa</b>	não há erro	<b>ERRO de tipo II</b>

# Testes de Hipóteses Paramétricos

$P(\text{erro de tipo I ou } 1^{\text{a}} \text{ espécie}) = P(\text{Rejeitar } H_0 \mid H_0 \text{ verdadeira}) = \alpha$   
 $\alpha$  - nível de significância

$P(\text{erro de tipo II ou } 2^{\text{a}} \text{ espécie}) = P(\text{Não rejeitar } H_0 \mid H_0 \text{ falsa}) = \beta$

Costuma atribuir-se um valor muito baixo à probabilidade do erro de 1<sup>a</sup> espécie, i.e., habitualmente considera-se

$\alpha = P(\text{Rejeitar } H_0 \mid H_0 \text{ verdadeira}) = 0.05$  ou  $0.01$

**Rejeitar  $H_0$**  significa que os dados testemunham fortemente contra  $H_0$

# Testes de Hipóteses

**Passos a seguir** na construção de um **teste estatístico**:

1. Identificar o(s) parâmetro(s); especificar  $H_0$  e  $H_1$  e o nível de significância  $\alpha$ .
2. Escolher uma variável aleatória – **estatística de teste**, que sob  $H_0$  terá distribuição conhecida (pelo menos aproximadamente).
3. Definir a **região de rejeição** ou **região crítica – RC** (conjunto de valores da estatística que são menos “plausíveis” caso  $H_0$  seja verdadeira, portanto levam a rejeitar  $H_0$ ).
4. Calcular **o valor** da estatística de teste, para a amostra observada.
5. **Se o valor calculado  $\in RC \rightarrow$  rejeita-se  $H_0$**   
**Se o valor calculado  $\notin RC \rightarrow$  não se rejeita  $H_0$**

# Testes de Hipóteses

Iremos considerar testes para os parâmetros: valor médio, variância, diferença de valores médios no caso de amostras independentes e emparelhadas, quociente de variâncias e proporções.

**Para todos estes testes os passos indicados no slide anterior encontram-se explicitados no quadro “Testes a Médias, Variâncias e Proporções”.**

Exemplo: de formulação de hipóteses para o valor médio:

$H_0 : \mu = \mu_0$	v.s.	$H_1 : \mu \neq \mu_0$	teste bilateral
$H_0 : \mu \leq \mu_0$	v.s.	$H_1 : \mu > \mu_0$	teste unilateral (à direita)
$H_0 : \mu \geq \mu_0$	v.s.	$H_1 : \mu < \mu_0$	teste unilateral (à esquerda)

# Regras de decisão em Testes de Hipóteses

A indicação do valor observado da estatística de teste, por exemplo  $Z_{cal}$ , e a indicação de um valor crítico  $z_\alpha$  para decidir, por exemplo,

Rejeitar  $H_0$  se  $Z_{cal} > z_\alpha$  (num teste unilateral à direita)  
tem sido recentemente “substituído” pelo cálculo de

– a probabilidade de se observar um valor igual ou mais extremo do que o observado, se a hipótese nula é verdadeira – a que se chama **valor de prova; valor-p ( *p-value* )**

**Nota:** é esta quantidade que hoje em dia qualquer *software* está preparado para calcular quando se manda realizar um teste.

# Regras de decisão em Testes de Hipóteses

Podemos interpretar o **valor de prova** ou **valor- $p$**  ou  **$p$ -value** como a **medida do grau de concordância entre os dados e  $H_0$**

**Assim:**

- **Quanto menor for o  $p$ -value, menor é a consistência entre os dados e a hipótese nula**

Habitualmente adopta-se como regra de decisão:

**rejeitar  $H_0$  se  $p$ -value  $\leq \alpha$**

# Testes de Hipóteses ... outros

Nesta breve introdução à Teoria dos Testes de Hipóteses vimos como formular testes a parâmetros desconhecidos da população, em particular:

- ao valor médio, variância e a uma proporção;
- diferença de dois valores médios em amostras independentes e em amostras emparelhadas;
- quociente de variâncias e diferença de duas proporções.

**Mas ...** outros testes de hipóteses podem ser necessários nas mais variadas situações.

Note-se, todavia, que os passos a seguir serão sempre os indicados no slide 168.

# Testes de Hipóteses ... outros

Como ilustração podemos referir três testes:

- **Teste de normalidade de Shapiro-Wilk;**
- **Teste do Qui-quadrado de ajustamento;**
- **Teste à igualdade de três ou mais valores médios em amostras independentes** (este é o procedimento estatístico conhecido como **Análise de Variância** que na sua ideia mais básica corresponde à generalização do problema da comparação de duas médias populacionais.) **Não será tratado neste curso.**

# Um teste de Normalidade

Consideremos agora **o caso** de se pretender testar a forma da distribuição.

Os testes a considerar agora são testes não paramétricos que se designam por **testes de ajustamento**.

Começemos com um teste muito importante nas nossas aplicações - **um teste de ajustamento à distribuição normal** - para averiguar se um dado conjunto de observações se pode considerar proveniente de uma população com distribuição normal – é um **teste de normalidade**,

## O Teste de Shapiro Wilk

que se tem revelado ser um dos mais potentes. Vejamos em síntese como se processa.

# O teste de Shapiro-Wilk

Seja  $X$  a característica em estudo na população.

Formulam-se as hipóteses:

$H_0$  :  $X$  tem distribuição Normal

$H_1$ :  $X$  não tem distribuição Normal

Calcula-se o valor da estatística de teste  $W_{cal} = \frac{b^2}{\sum_{i=1}^n (x_i - \bar{x})^2}$

com  $b$  constante a determinar a partir dos dados e com recurso a uma tabela (que não será aqui dada).

# O teste de Shapiro-Wilk

Valores pequenos de  $W_{cal}$  indicam não normalidade, i.e.

$$\text{RC: } W_{cal} < W_{\alpha}$$

Com  $W_{\alpha}$  – **valor crítico** a consultar numa Tabela.

Alternativamente pode usar-se o **valor- $p$** ,

- Rejeita-se  $H_0$  se **valor- $p \leq \alpha$** , significando que não se pode admitir que  $X$  tem distribuição normal;
- Se **valor- $p > \alpha$**  **não se rejeita  $H_0$** , o que significa que a distribuição normal é uma distribuição possível para  $X$ .

## Exercício 2 (reescrito)

Um estudo pretende comparar um tipo de semente melhorada com o tipo de semente tradicional. A semente melhorada passará a ser utilizada se, em média, o crescimento das plantas após 20 dias for superior ao das obtidas das sementes tradicionais. 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
Semente melhorada	3.46	3.48	2.74	2.83	4.00	4.95	2.24	6.92
Semente tradicional	3.18	3.67	2.92	3.10	4.10	4.86	2.21	6.91

Situação	9	10	11	12	13	14	15
Semente melhorada	6.57	6.18	8.30	3.44	4.47	7.59	3.87
Semente tradicional	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 impor.

# Resolução - Exercício 2

Trata-se de um problema de **amostras emparelhadas** e como se pretende averiguar se as sementes melhoradas apresentam melhor desempenho, o teste a realizar é o teste unilateral

$$H_0 : \mu_D = 0 \quad vs. \quad H_1 : \mu_D > 0$$

$D$  designa a diferença entre o comprimento das plantas das sementes melhoradas e das tradicionais.

O comando do  para realizar este teste (e da execução do qual se obtém tb o intervalo de confiança unilateral, que não fez parte do programa) é o seguinte:

```
> t.test(nsem,vsem,alternative='greater'),  
paired=TRUE)
```

## Resolução - Exercício 2 (cont.)

**Mas** ... para utilizar aquele teste é necessário verificar previamente se pode admitir-se que a **diferença entre alturas das plantas provenientes das sementes melhoradas e das tradicionais segue uma distribuição normal**.

Começamos pelo teste de normalidade de Shapiro-Wilk para analisar a hipótese de normalidade:

```
> shapiro.test(nsem-vsem)
Shapiro-Wilk normality test
data:  nsem-vsem
W = 0.9428, p-value = 0.4184
```

**Conclusão:** Dado que o *p-value* é **0.4184**, conclui-se que **não se rejeita a hipótese da normalidade**, pelo que pode realizar-se o teste *t*.

## Resolução - Exercício 2 (cont.)

```
> t.test(nsem,vsem,alternative='greater',  
paired=TRUE)
```

Paired t-test

data: nsem and vsem

t = 0.1396, df = 14, p-value = 0.4455

alternative hypothesis: true difference in means is greater than 0

95 percent confidence interval:

-0.07744645 Inf

sample estimates: mean of the differences

0.006666667

Como o *p-value*= 0.4455 é superior a 0.05, não se rejeita  $H_0$ .

**Conclusão:** Não se pode afirmar que  $\mu_D$  seja superior a 0, portanto não se pode aconselhar o uso das sementes melhoradas face às tradicionais.

# Teste de ajustamento do qui-quadrado

Falámos já num teste de ajustamento - o teste Shapiro - Wilk - **teste de normalidade**.

Mas, ... a necessidade de considerar **o ajustamento a outras distribuições** (contínuas ou discretas) pode surgir nas mais variadas aplicações.

O “teste do qui-quadrado” foi desenvolvido por Pearson (1900) como **teste de ajustamento** para **dados nominais** ou **dados classificados em classes**, i.e., é um teste que usa **a contagem do número de valores que se observam em classes** ou **categorias**.

Vamos introduzir o **teste do qui-quadrado** com um **Exemplo**, relembrando as etapas necessárias à realização de um teste de hipóteses - slide 168.

# Teste de ajustamento do qui-quadrado

## Exemplo

A descendência originada pelo cruzamento de dois dados tipos de plantas pode ser qualquer um dos três génotipos que representaremos por  $c$ ,  $cC$  e  $C$ . Um modelo teórico de sucessão genética indica que os tipos  $c$ ,  $cC$  e  $C$  devem aparecer na razão 1 : 2 : 1. Efectuou-se o cruzamento daqueles dois tipos tendo-se classificado 90 plantas. A sua classificação genética foi registada na tabela:

Genótipos	$c$	$cC$	$C$
	18	44	28

Estão estes dados de acordo com o modelo genético?

O que se pretende aqui averiguar é se **X segue uma dada distribuição** ou **não**

... no caso do exemplo, aquela averiguação inicia-se pela formulação das seguintes hipóteses:

# Teste de ajustamento do qui-quadrado

$H_0 : p_1 = 0.25, \quad p_2 = 0.5, \quad p_3 = 0.25$

$H_1$ : pelo menos uma das probabilidades é diferente do formulado.

O teste sugerido por Karl Pearson (para o caso de as observações se encontrarem classificadas em  $k$  classes) consiste em considerar a estatística de teste:

$$X^2 = \sum_{i=1}^k \frac{(O_i - E_i)^2}{E_i}$$

$k$ — nº de classes;  $O_i$ — frequência observada, é a frequência absoluta em cada classe;  $E_i$ — frequência esperada, dada por  $E_i = n p_i$  com  $p_i$  a probabilidade da classe  $i$ , se a hipótese  $H_0$  verdadeira;  $n$  é o número (total) de observações independentes.

O valor de  $X^2$  em cada classe é uma medida da proximidade entre os dados e a Hipótese nula. Quanto menor for o valor de  $X^2$  mais plausível é a hipótese  $H_0$ .

# Teste de ajustamento do qui-quadrado

Pearson mostrou que  $X^2$  tem distribuição assintótica

$X^2 \sim \chi^2_{(k-1)}$  onde  $k$  é o número de classes em que as observações foram agrupadas.

A região crítica, para um nível de significância  $\alpha$ , é definida como:

$$\text{RC: } X_{cal}^2 > \chi_{\alpha, (k-1)}^2$$

**Resolução:**

	$c$	$cC$	$C$
$O_i$	18	44	28
$p_i$	0.25	0.5	0.25
$E_i = np_i$	22.5	45	22.5

$$X_{cal}^2 = \frac{(18-22.5)^2}{22.5} + \frac{(44-45)^2}{45} + \frac{(28-22.5)^2}{22.5} = 2.27 \quad \text{e} \quad \chi_{0.05, 2}^2 = 5.99.$$

Então  $X_{cal}^2 < \chi_{0.05, 2}^2$ , logo não se rejeita  $H_0$  a um nível de significância de 5%, portanto não há razões para duvidar que os dados estejam de acordo com o modelo genético.

# Teste do qui-quadrado - Observações

- A variável  $X^2$ , tem distribuição assintótica. Qual a dimensão que a amostra deverá ter para que a aproximação à distribuição  $\chi^2_{(k-1)}$  seja válida?
  - ❖ Alguns autores consideram que a aproximação só é válida se **a frequência esperada,  $E_i$ , verifica  $E_i \geq 5$**  ;
  - ❖ Cochran (1954) sugeriu que se podia considerar classes com  $E_i = 1$ , desde que **80% das classes apresente  $E_i > 5$** . Sempre que as frequências esperadas de algumas classes forem inferiores a 1 essas classes devem agrupar-se com as adjacentes por forma a atingir a frequência mínima desejada.
- Sempre que para determinar a probabilidade  $p_i$  for necessário estimar parâmetros, a distribuição  $\chi^2$  virá  $\chi^2_{(k-1-n^\circ \text{ de parâmetros estimados})}$