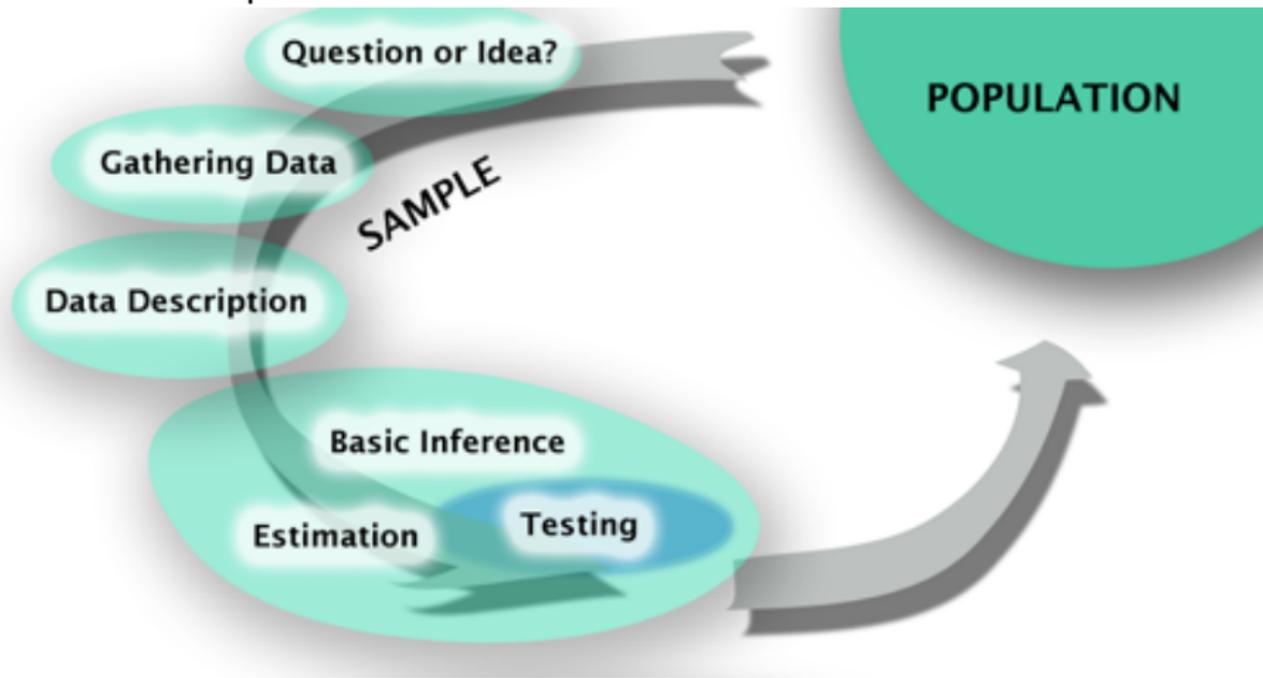


# Parte C

## Introdução à Inferência Estatística

# Inferência Estatística

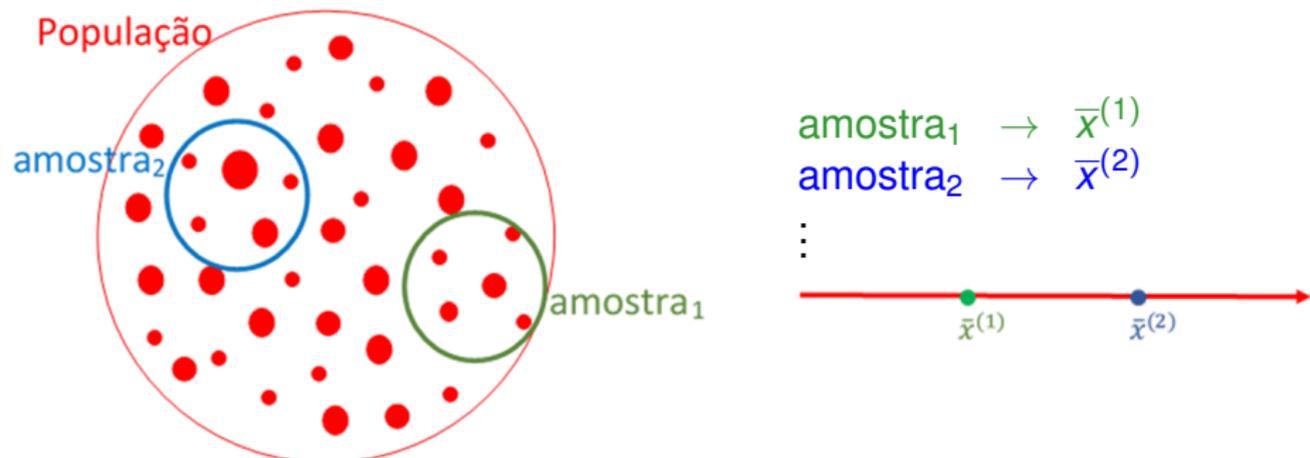
É o processo de tirar conclusões sobre uma **população** com base no conhecimento parcial de **uma amostra**.



(<https://onlinecourses.science.psu.edu/stat200/book/export/html/51>)

# Inferência Estatística

Para estimar o valor médio (valor esperado)  $\mu$  de uma população:



- $\bar{x}$  têm variabilidade resultante da amostragem
- como quantificar esta variabilidade com base numa única amostra?
- onde está o  $\mu$ ?

Para uma apresentação informal da Inferência Estatística sugere-se a visualização deste vídeo

<https://www.youtube.com/watch?v=tFWsu09f74o>

- A inferência estatística é baseada em modelos de probabilidade.
- As amostras devem ser obtidas com intervenção do acaso e ser representativas da população.
- Compreende três tipos de ferramentas:
  - **estimação pontual**
  - **intervalos de confiança**
  - **testes de hipóteses**

## Exemplo 11

Numa linha de engarrafamento de azeite, supõe-se que a quantidade despejada em cada garrafa (em litro) é uma variável aleatória  $X$  que segue uma distribuição normal,  $X \sim \mathcal{N}(\mu, \sigma)$ , com  $\mu$  e  $\sigma$  desconhecidos. Considera-se que o processo está regulado quando  $\mu = 1$  e  $\sigma^2 < 0.005$ . **Como avaliar a concordância dos dados com a suposição  $\mu = 1$ ?**

Escolhe-se ao acaso uma amostra de  $n = 20$  garrafas e mede-se a quantidade (litro) de azeite contida em cada uma:



# Exemplo 11

Com base nestes 20 valores pode-se:

- **estimar** o valor de  $\mu$  e afirmar: **uma estimativa para  $\mu$  é  $\bar{x} = 0.9647$** ; (será este valor “muito” diferente de 1?)
- determinar um **intervalo de confiança** para  $\mu$  e afirmar:  **$\mu \in ]0.92140, 1.00807[$  com 95% de confiança; como este intervalo contém o valor 1, não há razão para desconfiar que  $\mu$  seja diferente de 1;**
- **testar as hipóteses**  $\mu = 1$  contra  $\mu \neq 1$  e afirmar: **com um nível de significância de 5%, rejeita-se a hipótese  $\mu = 1$  se  $\frac{\bar{x} - 1}{s/\sqrt{20}} > 2.093$ . Ou ainda, este teste de hipóteses tem um  $p$ -value de 0.1048; ao nível de significância de 0.05 não se rejeita a hipótese de  $\mu = 1$ .**

# Conceitos em Inferência Estatística

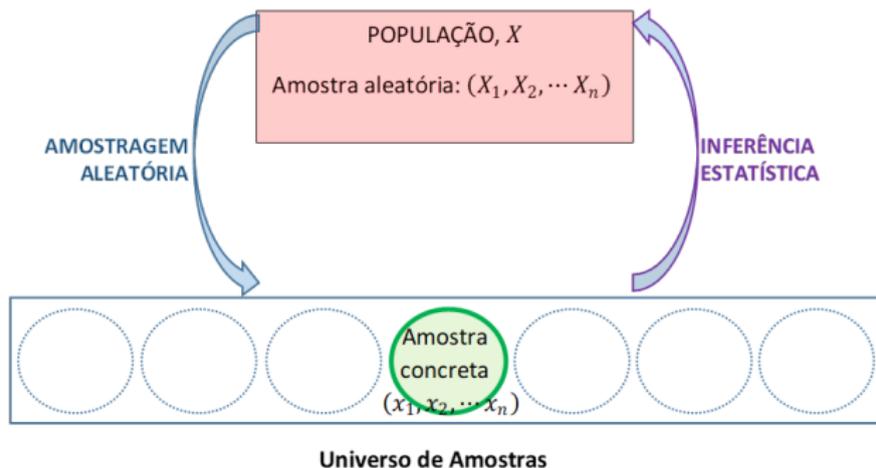
**População** → conjunto completo de todas os elementos com uma característica comum; a característica que se pretende estudar é considerada uma variável aleatória  $X$ . É frequente designar a própria população por  $X$ .

## Amostra aleatória

**Amostra aleatória** de dimensão  $n$ , é uma coleção  $(X_1, X_2, \dots, X_n)$  de  $n$  variáveis aleatórias **independentes** e **semelhantes**, i.e., tendo todas a mesma distribuição que é a distribuição da população  $X$  em estudo.

**Amostra concreta** → coleção dos valores efetivamente observados. É considerada uma concretização (de entre as muitas possíveis) da amostra aleatória.

# Conceitos em Inferência Estatística



**Parâmetro de uma população** → **constante desconhecida**, cujo verdadeiro valor se pretende “estimar” ou “validar”. Por exemplo  $\mu$ , o valor esperado de  $X$ .

# Conceitos em Inferência Estatística

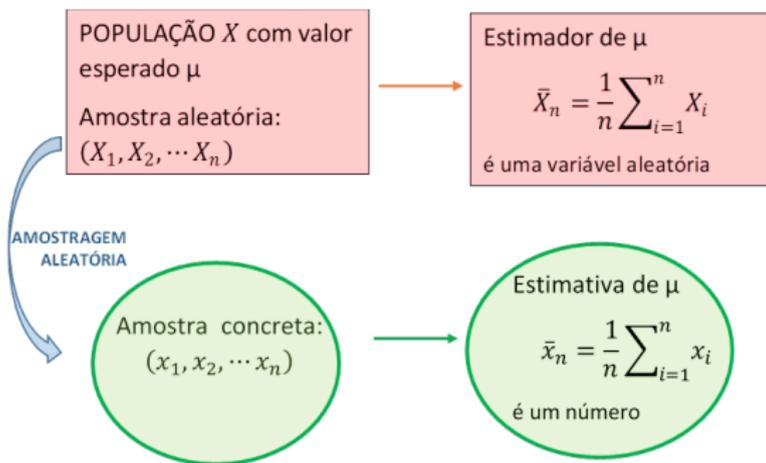
Para obter estimativas dos parâmetros desconhecidos, aceder a informação sobre o erro associado a essas estimativas e validar hipóteses sobre os valores dos parâmetros, utilizam-se **estimadores**.

## Estimador e estimativa

Um **estimador de um parâmetro** é uma função da amostra aleatória  $(X_1, X_2, \dots, X_n)$ , que serve para obter “valores aproximados” de um parâmetro populacional desconhecido. Quando se aplica essa função (ou procedimento) à amostra concreta, o valor resultante designa-se **uma estimativa**.

Por exemplo, o estimador usual do valor esperado  $\mu$  de uma população é a média amostral definida por  $\bar{X}_n = \frac{1}{n} \sum_{i=1}^n X_i$ . Então, para obter uma estimativa de  $\mu$ , recolhe-se uma amostra de dimensão  $n$  e aplica-se a expressão do estimador à amostra concreta:

# Conceitos em Inferência Estatística



Cada amostra concreta dá origem a uma nova estimativa  $\bar{x}$ , mas em geral apenas se dispõe de **uma única** amostra com a informação:

- $n$ , a dimensão
- $\bar{x}$ , a média
- $s$ , o desvio padrão

# Conceitos em Inferência Estatística

Um **estimador** é uma **variável aleatória**, que se caracteriza através da sua função densidade de probabilidade. A Inferência Estatística utiliza a teoria da Probabilidade para determinar a distribuição de probabilidades do estimador, designada **distribuição de amostragem**.

Por exemplo, a distribuição de amostragem de  $\bar{X}_n$  modela a distribuição dos valores das médias  $\bar{x}$  de cada amostra concreta, ao longo do universo de possíveis amostras.

Sabe-se que se  $(X_1, X_2, \dots, X_n)$  é uma amostra aleatória extraída de uma população normal,  $X \sim \mathcal{N}(\mu, \sigma)$ , então

$$\bar{X}_n \sim \mathcal{N}(\mu, \sigma/\sqrt{n}) \Leftrightarrow \frac{\bar{X}_n - \mu}{\sigma/\sqrt{n}} \sim \mathcal{N}(0, 1)$$

# Conceitos em Inferência Estatística

Se a amostragem for feita numa população com distribuição desconhecida com valor médio  $\mu$  e variância  $\sigma^2$ , a distribuição de amostragem de  $\bar{X}_n$  é ainda aproximadamente normal, desde que a dimensão da amostra seja suficientemente grande (Teorema Limite Central)

$$\frac{\bar{X}_n - \mu}{\sigma/\sqrt{n}} \sim \mathcal{N}(0, 1), \quad n > 30$$

Dada a amostra aleatória,  $(X_1, X_2, \dots, X_n)$  extraída de uma população  $X$ , os **parâmetros** que vão ser considerados, seus **estimadores** e **estimativas** associadas são:

# Parâmetros, estimadores e estimativas

Parâmetro a estimar

Estimador

Estimativa

$\mu$

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

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

$\sigma^2$

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

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

$p$

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

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

$\mu_1 - \mu_2$

$$\bar{X}_1 - \bar{X}_2$$

$$\bar{x}_1 - \bar{x}_2$$

$\sigma_1^2 / \sigma_2^2$

$$S_1^2 / S_2^2$$

$$s_1^2 / s_2^2$$

$p_1 - p_2$

$$\hat{P}_1 - \hat{P}_2$$

$$\hat{p}_1 - \hat{p}_2$$

<sup>(a)</sup> $X$  - v.a. que conta o número de sucessos na amostra de dimensão  $n$

<sup>(b)</sup> $x$  - número observado de sucessos na amostra de dimensão  $n$ .

Conhecer a **distribuição de um estimador** permite:

- associar a uma estimativa um intervalo de valores acompanhado de uma indicação do grau de confiança em que o verdadeiro valor do parâmetro pertença a esse intervalo → **construir intervalos de confiança para o parâmetro**;
- tomar decisões sobre hipóteses colocadas sobre o valor do parâmetro, controlando o erro associado a essa decisão → **fazer testes de hipóteses ao parâmetro**.

Seguem-se as distribuições de alguns estimadores.

# Estimador do valor esperado de uma população, $\mu$

Seja  $(X_1, X_2, \dots, X_n)$  uma amostra aleatória (a.a.) extraída de uma população  $X$ , com valor esperado  $\mu$  e variância  $\sigma^2$ .

Estimador de  $\mu$

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

Caso A: População normal com  $\sigma$  conhecido (slide 161)

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

Caso B: População com qualquer distribuição e amostra grande  
( $n > 30$ ) (slide 162)

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

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

$s$  é o desvio padrão da amostra.

# Estimador da variância de uma população, $\sigma^2$

Seja  $(X_1, X_2, \dots, X_n)$  uma a.a. extraída de uma população com distribuição normal,  $X \sim \mathcal{N}(\mu, \sigma)$ .

## Estimador de $\sigma^2$

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

Distribuição de amostragem:

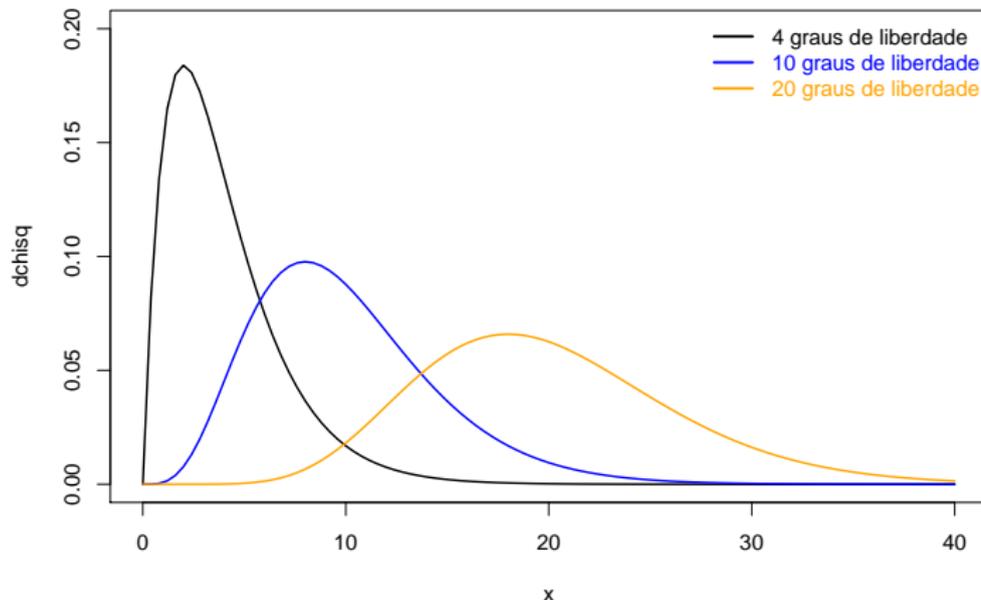
$$\frac{(n-1)S^2}{\sigma^2} \sim \chi^2_{(n-1)}$$

a v.a.  $\frac{(n-1)S^2}{\sigma^2}$  tem **distribuição qui-quadrado com  $n - 1$  graus de liberdade**.

**Atenção:** Em populações em que não se verifica a normalidade, esta distribuição não é válida.

# Estimador da variância de uma população, $\sigma^2$

Função densidade da distribuição  $\chi^2_{(n)}$ :



$$Y \sim \chi^2_{(n)} \Rightarrow E[Y] = n \text{ e } \text{Var}[Y] = 2n$$

# Estimador da variância de uma população, $\sigma^2$

Note-se que o estimador  $S^2$  verifica:

$$E \left[ \frac{(n-1)S^2}{\sigma^2} \right] = n-1 \Leftrightarrow \frac{(n-1)}{\sigma^2} E[S^2] = n-1 \Leftrightarrow E[S^2] = \sigma^2$$

Um estimador cujo valor esperado coincide com o parâmetro a estimar diz-se **estimador centrado**.

Esta é uma propriedade desejável a um bom estimador.

Conclui-se assim que

$$S^2 = \frac{1}{n-1} \sum_{i=1}^n (X_i - \bar{X})^2 \text{ é um estimador centrado de } \sigma^2.$$

É esta propriedade que justifica o denominador de  $S^2$  ser  $(n-1)$  e não, por exemplo,  $n$ .

**Exercício:** mostrar que  $\bar{X}$  é um estimador centrado de  $\mu$ .

# Estimador do valor esperado de uma população, $\mu$

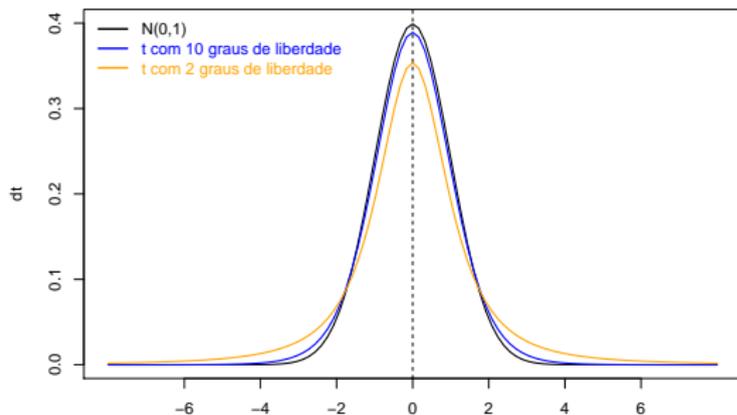
Caso C: População normal com  $\sigma$  desconhecido

$$\frac{\bar{X} - \mu}{S/\sqrt{n}} \sim t_{(n-1)}$$

em que  $S$  é a raiz quadrada do estimador de  $\sigma^2$ ,  $S = \sqrt{S^2}$ .

A v.a.  $\frac{\bar{X} - \mu}{S/\sqrt{n}}$  tem **distribuição t-Student com  $n - 1$  graus de liberdade**.

Função densidade da distribuição  $t_{(n)}$ :



A curva é mais achatada do que a  $\mathcal{N}(0,1)$  e aproxima-se desta à medida que aumenta o nº de graus de liberdade.

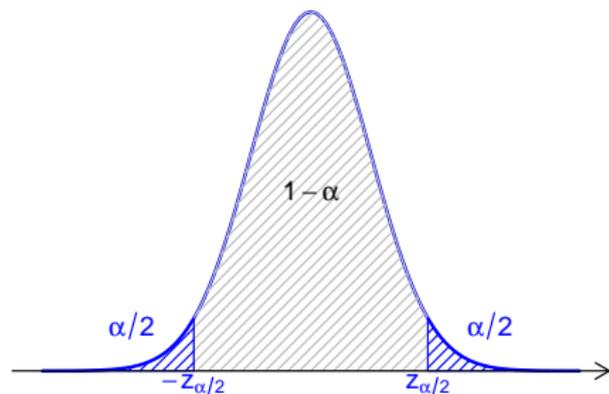
$$Y \sim t_{(n)} \Rightarrow E[Y] = 0 \text{ e } \text{Var}[Y] = \frac{n}{n-2}$$

# Intervalo de confiança para o valor esperado $\mu$ de população normal com $\sigma$ conhecido

Sabe-se que

$$\bar{X} \sim \mathcal{N}(\mu, \sigma) \Leftrightarrow Z = \frac{\bar{X} - \mu}{\sigma/\sqrt{n}} \sim \mathcal{N}(0, 1)$$

F. densidade de  $Z \sim \mathcal{N}(0, 1)$ :



**Confiança** =  $(1 - \alpha) \times 100\%$

$$P[-z_{\alpha/2} < Z < z_{\alpha/2}] = 1 - \alpha$$

Valores usuais de confiança:  
90%, 95%, 99%

95% de confiança:

$$\Leftrightarrow \alpha = 0.05 \rightarrow z_{\alpha/2} = z_{0.025} = 1.96$$

# Intervalo de confiança para o valor esperado $\mu$ de população normal com $\sigma$ conhecido

## Construção do IC:

$$P \left[ -z_{\alpha/2} < \frac{\bar{X} - \mu}{\sigma/\sqrt{n}} < z_{\alpha/2} \right] = 1 - \alpha$$

$$\Leftrightarrow P \left[ -z_{\alpha/2} \frac{\sigma}{\sqrt{n}} < \bar{X} - \mu < z_{\alpha/2} \frac{\sigma}{\sqrt{n}} \right] = 1 - \alpha$$

$$\Leftrightarrow P \left[ -\bar{X} - z_{\alpha/2} \frac{\sigma}{\sqrt{n}} < -\mu < -\bar{X} + z_{\alpha/2} \frac{\sigma}{\sqrt{n}} \right] = 1 - \alpha$$

$$\Leftrightarrow P \left[ \bar{X} - z_{\alpha/2} \frac{\sigma}{\sqrt{n}} < \mu < \bar{X} + z_{\alpha/2} \frac{\sigma}{\sqrt{n}} \right] = 1 - \alpha$$

# Intervalo de confiança para o valor esperado $\mu$ de população normal com $\sigma$ conhecido

## Construção do IC (continuação):

$$\mu \in \left[ \bar{X} - z_{\alpha/2} \frac{\sigma}{\sqrt{n}}, \bar{X} + z_{\alpha/2} \frac{\sigma}{\sqrt{n}} \right] \text{ com probabilidade } (1 - \alpha)$$

quando se substitui o estimador  $\bar{X}$  pela estimativa  $\bar{x}$

↓

$$\mu \in \left[ \bar{x} - z_{\alpha/2} \frac{\sigma}{\sqrt{n}}, \bar{x} + z_{\alpha/2} \frac{\sigma}{\sqrt{n}} \right] \text{ com } (1 - \alpha) \times 100\% \text{ de confiança}$$

# Intervalo de confiança para o valor esperado $\mu$ de população normal com $\sigma$ conhecido

Intervalo a  $(1 - \alpha) \times 100\%$  de confiança para  $\mu$ , numa população normal com  $\sigma$  conhecido

$$\left[ \bar{x} - z_{\alpha/2} \frac{\sigma}{\sqrt{n}}, \bar{x} + z_{\alpha/2} \frac{\sigma}{\sqrt{n}} \right]$$

Significa que se se recolhesse muitas amostras de dimensão  $n$  e para cada uma delas se calculasse o IC,  $(1 - \alpha) \times 100\%$  desses intervalos conteriam o verdadeiro (e desconhecido) valor de  $\mu$ .

# Intervalo de confiança para o valor esperado $\mu$ de população normal com $\sigma$ conhecido

$$X \sim \mathcal{N}(2, 1)$$

$(X_1, X_2, \dots, X_{20})$  amostra aleatória de  $X$

Confiança = 95%  $\rightarrow 1 - \alpha = 0.95$   $\alpha = 0.05$

$$z_{\alpha/2} = z_{0.025} = 1.96 \text{ (tabela)}$$

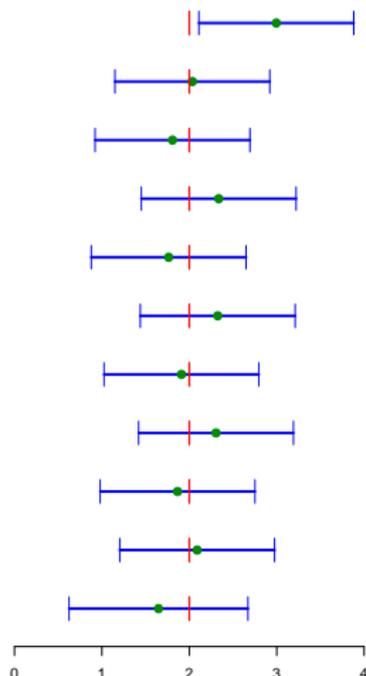
IC a 95% para  $\mu$ :

$$\left[ \bar{x} - 1.96 \frac{1}{\sqrt{20}}, \bar{x} + 1.96 \frac{1}{\sqrt{20}} \right]$$

$(x_1, x_2, \dots, x_{20})$  amostra concreta  $\rightarrow \bar{x}$

IC's para 11

amostras concretas:



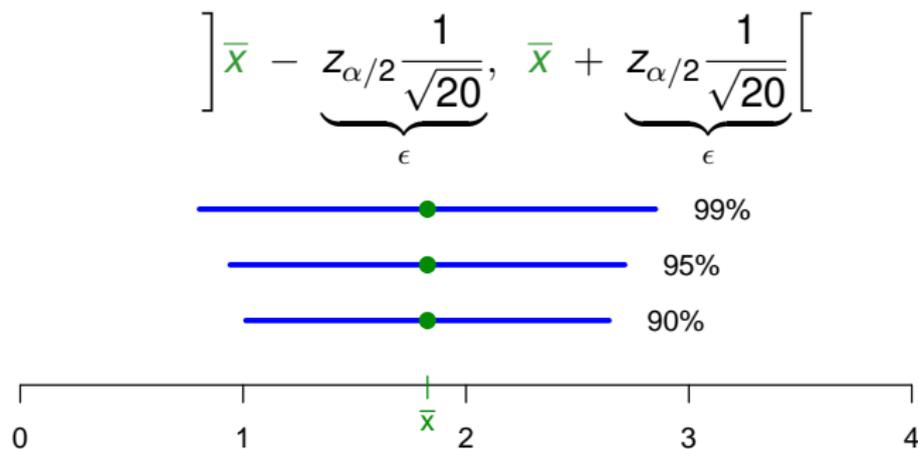
# Intervalo de confiança para o valor esperado $\mu$ de população normal com $\sigma$ conhecido

## Observações:

- o IC para  $\mu$  é centrado na estimativa  $\bar{x}$
- a amplitude do IC é  $2z_{\alpha/2} \frac{\sigma}{\sqrt{n}}$
- com  $(1 - \alpha) \times 100\%$  de confiança, o **erro máximo** cometido ao estimar  $\mu$  por  $\bar{x}$ , também designado **precisão** da estimativa, é a semi-amplitude do IC,  $\epsilon = z_{\alpha/2} \frac{\sigma}{\sqrt{n}}$
- em populações com maior variabilidade (maior  $\sigma$ ), os intervalos de confiança são mais imprecisos (têm maior amplitude)
- amostras de maior dimensão têm mais informação da população e dão origem a intervalos mais precisos (de menor amplitude)

# Intervalo de confiança para o valor esperado $\mu$ de população normal com $\sigma$ conhecido

- mantendo a dimensão da amostra, o **aumento da confiança** é acompanhado da **diminuição da precisão** do IC
- para amostras de dimensão 20, de uma população normal com  $\sigma = 1$ , os intervalos a  $(1 - \alpha) \times 100\%$  de confiança são



No limite, o intervalo com 100% de confiança seria a reta real.

# Intervalo de confiança para $\mu$ , amostras grandes ( $n > 30$ )

Para o caso B,

$\frac{\bar{X} - \mu}{\sigma/\sqrt{n}} \sim \mathcal{N}(0, 1)$ ,  $\sigma$  conhecido ou  $\frac{\bar{X} - \mu}{s/\sqrt{n}} \sim \mathcal{N}(0, 1)$ ,  $\sigma$  desconhecido  
em que  $s$  é o desvio padrão da amostra,

Intervalo a  $(1 - \alpha) \times 100\%$  de confiança para  $\mu$ , em amostras grandes

$$\left] \bar{x} - z_{\alpha/2} \frac{\sigma}{\sqrt{n}}, \bar{x} + z_{\alpha/2} \frac{\sigma}{\sqrt{n}} \right[ \text{ se } \sigma \text{ conhecido}$$

$$\left] \bar{x} - z_{\alpha/2} \frac{s}{\sqrt{n}}, \bar{x} + z_{\alpha/2} \frac{s}{\sqrt{n}} \right[ \text{ se } \sigma \text{ desconhecido}$$

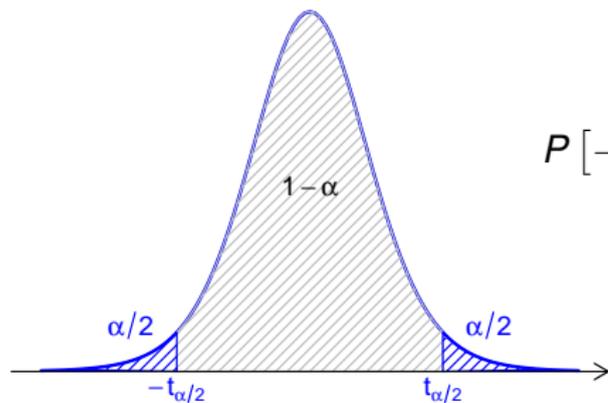
# Intervalo de confiança para $\mu$ , população normal com $\sigma$ desconhecido

Para o caso C:

$$T = \frac{\bar{X} - \mu}{S/\sqrt{n}} \sim t_{(n-1)}$$

em que  $S$  é o estimador usual de  $\sigma$ .

Função densidade de  $T \sim t_{(n-1)}$



$$P[-t_{\alpha/2(n-1)} < T < t_{\alpha/2(n-1)}] = 1 - \alpha$$

# Intervalo de confiança para $\mu$ , população normal com $\sigma$ desconhecido

A construção do IC para  $\mu$  é idêntica à dos casos A e B, substituindo a distribuição  $\mathcal{N}(0, 1)$  pela  $t_{(n-1)}$ .

Intervalo a  $(1 - \alpha) \times 100\%$  de confiança para  $\mu$ , numa população normal com  $\sigma$  desconhecido

$$\left] \bar{x} - t_{\alpha/2(n-1)} \frac{s}{\sqrt{n}}, \bar{x} + t_{\alpha/2(n-1)} \frac{s}{\sqrt{n}} \right[$$

em que  $s$  é o desvio padrão da amostra.

**Note-se** que este resultado **não abrange o caso de amostras grandes** se as populações não forem normais. O caso de populações não normais é o B (caso as amostras sejam grandes). Em amostras pequenas de populações não normais é necessário utilizar testes não paramétricos, assunto que não é abordado nesta UC.

## Exemplo 11 (continuação)

Para averiguar se  $\mu = 1$  pode-se calcular o **intervalo de confiança a 95% para  $\mu$** . Como o desvio padrão da população ( $\sigma$ ) é desconhecido e a amostra não é grande ( $n = 20$ ), usa-se o intervalo  $\left[ \bar{x} - t_{\alpha/2(n-1)} \frac{s}{\sqrt{n}}, \bar{x} + t_{\alpha/2(n-1)} \frac{s}{\sqrt{n}} \right]$ . Note-se que é necessário pressupor que a população tem distribuição normal; o histograma parece estar de acordo com este pressuposto, mas será necessário validar esta hipótese com um teste estatístico (mais à frente).

Informação com base na amostra:

$$n = 20$$

$$\bar{x} = 0.9647 \text{ litro}$$

$$s^2 = 0.0085729 \text{ litro}^2$$

$$\text{Confiança}=95\% \Leftrightarrow 1 - \alpha = 0.95 \Leftrightarrow \alpha/2 = 0.025 \rightarrow t_{0.025(19)} = \underbrace{2.093}_{\text{tabela}}$$

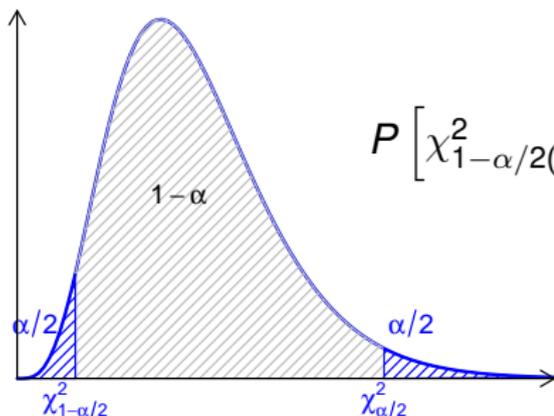
O IC tem semi-amplitude  $\epsilon = t_{\alpha/2(n-1)} \frac{s}{\sqrt{n}} = 0.04333$ , portanto pode-se afirmar, com 95% de confiança, que  $\mu \in ]0.9214041, 1.0080711[$ . Como o valor 1 está incluído no intervalo, este é um valor possível para  $\mu$ .

# Intervalo de confiança para $\sigma^2$

Sabe-se que para amostras aleatórias de populações normais se tem (slide 167)

$$\chi^2 = \frac{(n-1)S^2}{\sigma^2} \sim \chi^2_{(n-1)}$$

Função densidade de  $\chi^2_{(n-1)}$



$$P \left[ \chi^2_{1-\alpha/2(n-1)} < \chi^2 < \chi^2_{\alpha/2(n-1)} \right] = 1 - \alpha$$

# Intervalo de confiança para $\sigma^2$

A construção do IC para  $\sigma^2$  segue os passos:

$$P \left[ \chi_{1-\alpha/2(n-1)}^2 < \frac{(n-1)S^2}{\sigma^2} < \chi_{\alpha/2(n-1)}^2 \right] = 1 - \alpha$$

$$\Leftrightarrow P \left[ \frac{1}{\chi_{1-\alpha/2(n-1)}^2} > \frac{\sigma^2}{(n-1)S^2} > \frac{1}{\chi_{\alpha/2(n-1)}^2} \right] = 1 - \alpha$$

$$\Leftrightarrow P \left[ \frac{(n-1)S^2}{\chi_{1-\alpha/2(n-1)}^2} > \sigma^2 > \frac{(n-1)S^2}{\chi_{\alpha/2(n-1)}^2} \right] = 1 - \alpha$$

O intervalo aleatório  $\left[ \frac{(n-1)S^2}{\chi_{\alpha/2(n-1)}^2}, \frac{(n-1)S^2}{\chi_{1-\alpha/2(n-1)}^2} \right]$  contém  $\sigma^2$  com probabilidade  $1 - \alpha$ .

# Intervalo de confiança para $\sigma^2$

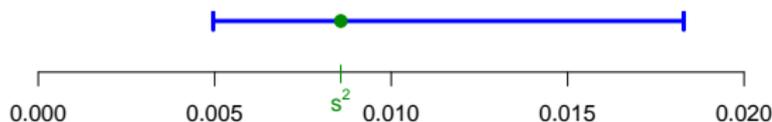
Quando se substitui o **estimador**  $S^2$  pela **estimativa**  $s^2$  calculada a partir de uma amostra concreta, obtém-se o

Intervalo de confiança a  $(1 - \alpha) \times 100\%$  para  $\sigma^2$

$$\left] \frac{(n-1)s^2}{\chi_{\alpha/2}^2(n-1)}, \frac{(n-1)s^2}{\chi_{1-\alpha/2}^2(n-1)} \right[$$

Note-se que este intervalo não é centrado na estimativa.

Para o Exemplo 11, tem-se  $\sigma^2 \in ]0.004958, 0.018288[$  com 95% de confiança.



$\chi_{0.025}^2(19) = 32.8523$  e  $\chi_{0.975}^2(19) = 8.90655$  (ver tabela).

Este IC pressupõe a normalidade da população.

# Intervalo de confiança para uma proporção

Pretende-se estimar a **proporção  $p$**  de “sucessos” numa população.

Por exemplo, a proporção de pinheiros infetados com uma doença em Portugal ou a proporção de artigos defeituosos numa linha de produção.

Considera-se uma amostra aleatória de dimensão  $n$ ,  $(X_1, X_2, \dots, X_n)$  em que cada  $X_i$ ,  $i = 1, 2, \dots, n$ , toma os valores 1 (sucesso) com probabilidade  $p$  e 0 (insucesso) com probabilidade  $1 - p$ .

$X = \sum_{i=1}^n X_i$  representa o número de sucessos na amostra aleatória.

## Estimador de $p$

$$\hat{p} = \frac{X}{n}$$

Uma estimativa para  $p$  é  $\hat{p} = \frac{x}{n}$ , em que  $x$  é o número de sucessos observados na amostra.

# Intervalo de confiança para uma proporção

Sabe-se que a v.a.  $X$  tem distribuição binomial com parâmetros  $n$  e  $p$ .

Se  $n$  grande,

$$X \sim B(n, p) \longrightarrow X \sim \mathcal{N}(np, \sqrt{npq}) \Leftrightarrow \hat{P} = \frac{X}{n} \sim \mathcal{N}\left(p, \sqrt{\frac{pq}{n}}\right)$$

Distribuição de amostragem:  $Z = \frac{\hat{P} - p}{\sqrt{\frac{\hat{p}(1-\hat{p})}{n}}} \sim \mathcal{N}(0, 1)$

Intervalo de confiança a  $(1 - \alpha) \times 100\%$  para  $p$ , em amostras grandes

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

# Testes de hipóteses

Uma **hipótese estatística** é qualquer conjectura sobre aspetos 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 um procedimento que permite decidir se uma dada hipótese formulada sobre a população **é** ou **não** suportada pela informação fornecida pelos dados de uma amostra.

# Testes de hipóteses

Em primeiro lugar irão ser estudados testes de hipóteses para parâmetros de populações:

- valor esperado  $\mu$  de uma população
- variância  $\sigma^2$  de uma população
- proporção de sucessos  $p$  numa população

Num teste de hipóteses há **5 passos** a seguir.

Exemplificam-se estes 5 passos no contexto de um teste a uma média populacional  $\mu$ .

O objetivo é **testar alguma afirmação sobre o valor esperado  $\mu$**  de uma variável numérica  $X$  numa população; por exemplo, saber se é admissível que  $\mu = E[X] = 2$ .

## Passo 1: Especificar as hipóteses e o nível de significância do teste

As hipóteses em confronto são:

**$H_0$  - Hipótese nula** é a hipótese que tem o **benefício da dúvida** (é considerada verdadeira até haver evidência estatística para a sua rejeição, ou seja até os dados testemunharem fortemente contra essa hipótese)

**$H_1$  - Hipótese alternativa** é a hipótese que tem o **ónus da prova** onde se especificam o(s) valor(es) a “aceitar” quando se rejeita a hipótese nula.

Se os dados não contradizem a hipótese nula, a conclusão é fraca: os dados não fornecem evidência suficiente contra  $H_0$ , o que pode acontecer com amostras pequenas e/ou em populações com muita variabilidade. Nesse caso não se aceita a hipótese alternativa.

Se a hipótese nula é rejeitada, aceita-se  $H_1$ .

# Testes de hipóteses | Passo 1 de 5

A resposta a um teste de hipóteses é dada na forma

- **Rejeitar  $H_0$**  - significa que os dados observados testemunham fortemente contra  $H_0$ ; neste caso é **adotada a hipótese  $H_1$**  ou
- **Não rejeitar  $H_0$**  - significa que não há evidência suficiente para rejeitar  $H_0$ .

Ao tomar decisões sobre a população com base numa amostra corre-se riscos, i.e. cometem-se erros:

Realidade	Decisão	
	Rejeitar $H_0$	Não rejeitar $H_0$
$H_0$ verdadeira	ERRO de tipo I	não há erro
$H_0$ falsa	não há erro	ERRO de tipo II

O **erro do tipo I** é considerado o mais gravoso, por isso é-lhe atribuída uma baixa probabilidade. Define-se **nível de significância** do teste como

$$\alpha = P[\text{erro do tipo I}] = P[\text{rejeitar } H_0 \mid H_0 \text{ verdadeira}].$$

Habitualmente considera-se  $\alpha = 0.05$  ou  $0.01$ .

Note-se que ao diminuir a probabilidade do erro do tipo I, rejeita-se menos vezes  $H_0$  e por isso aumenta-se a probabilidade do erro do tipo II.

## Passo 2: Definir a Estatística do Teste

- Uma **estatística de teste** é uma variável aleatória, função da amostra aleatória e de  $H_0$ , cujo comportamento permite definir as condições que levam à rejeição de  $H_0$ .
- É necessário conhecer a distribuição de probabilidades da estatística de teste quando  $H_0$  é verdadeira.

Por exemplo, num teste ao valor esperado  $\mu$  de uma população normal com desvio padrão  $\sigma$  desconhecido, a estatística de teste é

$$T = \frac{\bar{X} - \mu_0}{S/\sqrt{n}} \sim t_{(n-1)}$$

em que  $\mu_0$  é o valor de  $\mu$  ao abrigo de  $H_0$ .

## Passo 3: Definir a Região Crítica (ou Região de Rejeição)

- é o conjunto de valores da estatística de teste ao qual se associa a rejeição de  $H_0$ ;
- é constituída pelos valores da estatística de teste “menos plausíveis” caso  $H_0$  seja verdade ;
- a probabilidade de a estatística de teste pertencer à RC é o nível de significância  $\alpha$ ;
- a RC pode ser **bilateral** ou **unilateral**, dependendo da hipótese alternativa,  $H_1$ .

# Testes de hipóteses | Passo 3 de 5

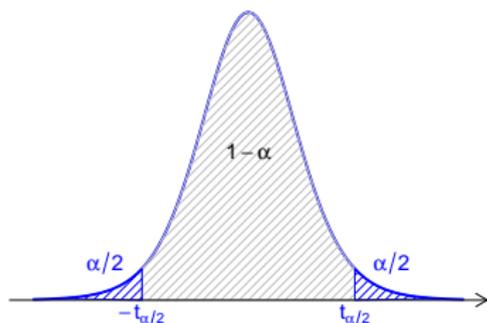
Por exemplo, num teste ao valor esperado  $\mu$  de uma população normal com desvio padrão  $\sigma$  desconhecido, em que a estatística de teste é  $T = \frac{\bar{X} - \mu_0}{S/\sqrt{n}} \sim t_{(n-1)}$ , poderá ter-se:

- **Teste bilateral**

$$H_0 : \mu = \mu_0$$

$$H_1 : \mu \neq \mu_0$$

Função densidade de  $T$  sob  $H_0$



Região Crítica:

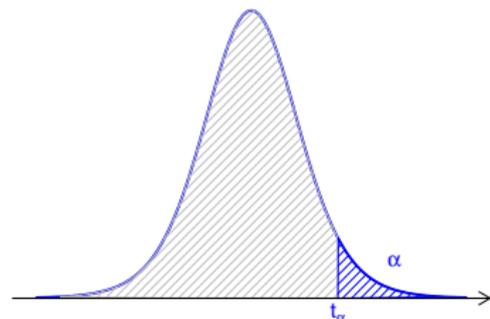
$$T < -t_{\alpha/2} \quad \text{ou} \quad T > t_{\alpha/2}$$

- **Teste unilateral direito**

$$H_0 : \mu \leq \mu_0$$

$$H_1 : \mu > \mu_0$$

Função densidade de  $T$  sob  $H_0$



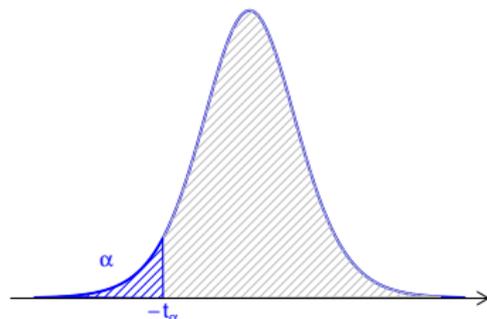
**Região Crítica:  $T > t_\alpha$**

- **Teste unilateral esquerdo**

$$H_0 : \mu \geq \mu_0$$

$$H_1 : \mu < \mu_0$$

Função densidade de  $T$  sob  $H_0$



**Região Crítica:  $T < -t_\alpha$**

## Passo 4: Calcular o valor da Estatística de Teste

- Escolhe-se uma **amostra concreta** (só neste passo intervêm os dados) e
- calcula-se o valor da estatística de teste para essa amostra

No exemplo,

$$T_{\text{calc}} = \frac{\bar{x} - \mu_0}{s/\sqrt{n}}$$

## Passo 5: Conclusão

- Toma-se a decisão de **rejeitar  $H_0$**  ou de **não rejeitar  $H_0$** , consoante o valor da estatística de teste, calculado para a amostra observada, recaia ou não na Região Crítica.

No exemplo:

- se  $T_{\text{calc}} \in RC \rightarrow$  Rejeita-se  $H_0$  e “aceita-se”  $H_1$
- se  $T_{\text{calc}} \notin RC \rightarrow$  Não se Rejeita  $H_0$

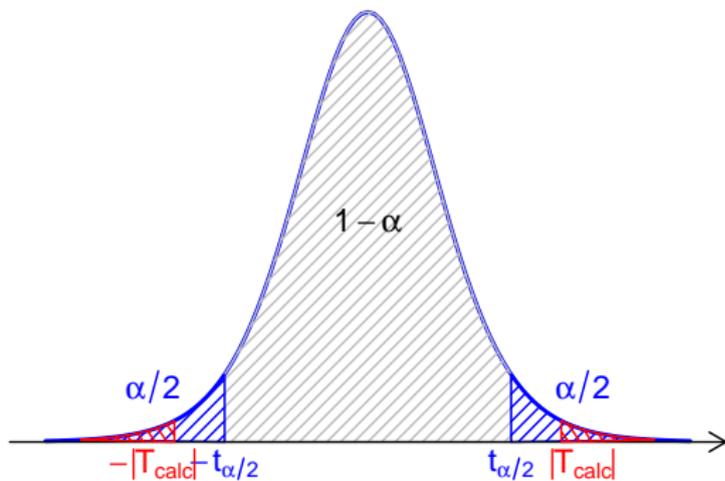
Os passos 3 a 5 podem ser substituídos pela indicação de uma medida de plausibilidade de  $H_0$ , designada **valor de prova** ou ***p-value***, definido como a **probabilidade de obter um valor tão ou mais extremo quanto o observado na estatística do teste, caso  $H_0$  seja verdade**. O ***p-value*** mede a concordância dos dados com  $H_0$ . Quando um ***p-value*** é muito pequeno, considera-se  $H_0$  irrealista, optando-se pela sua rejeição.

# $p$ -value e nível de significância

Note-se que:

- $p\text{-value} < \alpha \Leftrightarrow T_{\text{calc}} \in \text{RC} \rightarrow$  Rejeita-se  $H_0$  ao nível de significância  $\alpha$

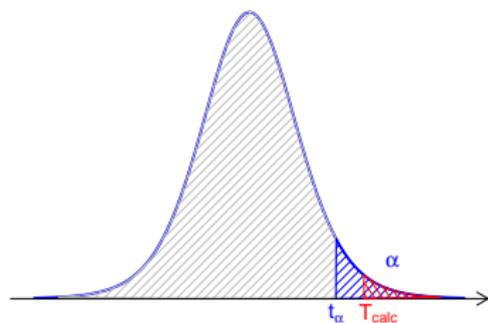
Teste bilateral



$$p\text{-value} = 2P [T > |T_{\text{calc}}|]$$

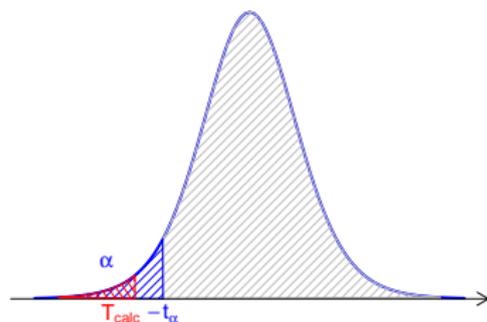
# $p$ -value e nível de significância

Teste unilateral direito



$$p\text{-value} = P [T > T_{\text{calc}}]$$

Teste unilateral esquerdo



$$p\text{-value} = P [T < T_{\text{calc}}]$$

## Exemplo 11 (continuação)

Para averiguar se  $\mu = 1$ , uma alternativa ao IC obtido no slide 181 é a realização de um teste de hipóteses bilateral.

1. As hipóteses em confronto são  $H_0: \mu = 1$  vs  $H_1: \mu \neq 1$ .  
Nível de significância:  $\alpha = P[\text{rejeitar } H_0 \mid H_0 \text{ verdade}] = 0.05$ .
2. Estatística de teste:  $T = \frac{\bar{X} - 1}{S/\sqrt{n}} \sim t_{(19)}$  sob  $H_0$
3. Para  $\alpha = 0.05$ ,  $t_{0.025(19)} = 2.093$ . Região crítica:  $T < -2.093$   
ou  $T > 2.093$ .
4. O valor da estatística de teste é  $T_{\text{calc}} = \frac{\bar{x} - 1}{s/\sqrt{20}} = -1.7032$ .
5. Como  $T_{\text{calc}} \notin RC$ , não se rejeita  $H_0$  ao nível de significância de 5%.

## Exemplo 11 (continuação)

O  $p$ -value obtém-se facilmente quando se utiliza o  para realizar o teste:

```
> t.test(azeite, mu=1)
```

```
One Sample t-test
```

```
data: azeite
```

```
t = -1.7032, df = 19, p-value = 0.1048
```

```
alternative hypothesis: true mean is not equal to 1
```

```
95 percent confidence interval:
```

```
0.9214041 1.0080711
```

```
sample estimates:
```

```
mean of x
```

```
0.9647376
```

## Exemplo 11 (continuação)

Se se pretendesse averiguar se  $\mu < 1$ , as hipóteses seriam  $H_0: \mu \geq 1$  vs  $H_1: \mu < 1$ . A região crítica seria (para o mesmo nível de significância)  $T_{\text{calc}} < -t_{0.05(19)} = -1.729$ .

$T_{\text{calc}} = -1.7032 \notin \text{RC}$ ,  $\bar{x}$  não é significativamente inferior a 1. No :

```
> t.test(azeite, mu=1, alternative="less")
```

```
One Sample t-test
```

```
data: azeite
t = -1.7032, df = 19, p-value = 0.05242
alternative hypothesis: true mean is less than 1
95 percent confidence interval:
 -Inf 1.000537
sample estimates:
mean of x
0.9647376
```

## Exemplo 11 (continuação)

Para averiguar se  $\sigma^2 > 0.005$ , é preferível realizar um teste de hipóteses unilateral a calcular o IC (slide 184). O IC é equivalente a um TH bilateral, como se viu no exemplo acima.

1. As hipóteses em confronto são  $H_0: \sigma^2 \leq 0.005$  vs  $H_1: \sigma^2 > 0.005$ .  
Nível de significância:  $\alpha = P[\text{rejeitar } H_0 \mid H_0 \text{ verdade}] = 0.05$ .
2. Estatística de teste:  $\chi^2 = \frac{(n-1)S^2}{0.005} \sim \chi^2_{(19)}$  sob  $H_0$ .
3. Para  $\alpha = 0.05$ ,  $\chi^2_{0.05(19)} = 30.14$ . Região crítica:  $\chi^2 > 30.14$ .
4. O valor da estatística de teste é  $\chi^2_{\text{calc}} = \frac{19 \times s^2}{0.005} = 32.577$ .
5. Como  $\chi^2_{\text{calc}} \in \text{RC}$ , rejeita-se  $H_0$  ao nível de significância de 5%, e conclui-se que  $s^2$  é significativamente superior a 0.005.

# Teste de normalidade de Shapiro-Wilk

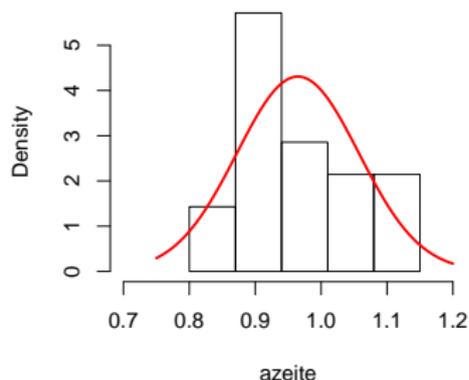
É um teste de hipóteses não paramétrico, para averiguar se uma população  $X$  segue a distribuição normal.

$H_0$ :  $X$  tem distribuição normal

$H_1$ :  $X$  não segue a distribuição normal

Para os dados do Exemplo 11 (slide 155), tem-se

Histogram of azeite



No :

```
> shapiro.test(azeite)
```

Shapiro-Wilk normality test

data: azeite

W = 0.92427, p-value = 0.1197

Como o  $p$ -value é superior a 0.05, a este nível de significância não se rejeita a hipótese da normalidade da quantidade de azeite despejada numa garrafa.

# Comparação de parâmetros de duas populações

Sejam  $X$  e  $Y$  duas populações. Pretende-se, a partir de amostras recolhidas destas populações, comparar os dois valores médios e/ou as duas variâncias populacionais.

As duas **amostras são independentes** quando não há relação entre os elementos de cada uma das amostras

- amostra aleatória de dimensão  $n$  extraída da população  $X$ :  
 $(X_1, X_2, \dots, X_n)$
- amostra aleatória de dimensão  $m$  extraída da população  $Y$ :  
 $(Y_1, Y_2, \dots, Y_m)$
- não há relação entre  $X_i$  e  $Y_j$
- pode-se alterar a ordem em cada amostra

# Amostras independentes e amostras emparelhadas

Um caso particular de amostras **não independentes** é o de **amostras emparelhadas**.

Duas amostras, **necessariamente com a mesma dimensão**, estão emparelhadas quando

- amostra aleatória de dimensão  $n$  extraída da população  $X$ :  
 $(X_1, X_2, \dots, X_n)$
- amostra aleatória de dimensão  $n$ extraída da população  $Y$ :  
 $(Y_1, Y_2, \dots, Y_n)$
- $X_i$  e  $Y_i$  estão associadas, formam um par  $(X_i, Y_i)$
- não se pode alterar a ordem em cada amostra

Aqui está um vídeo <https://www.youtube.com/watch?v=-6vDjGR41YM> que pode ajudar a visualizar a diferença entre amostras independentes e amostras emparelhadas.

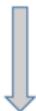
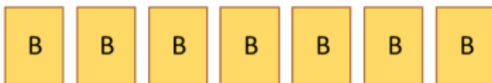
# Amostras independentes e amostras emparelhadas

**Exemplo:** Pretende-se comparar o rendimento médio de duas variedades de milho. A experiência pode ser delineada das duas formas seguintes

Terreno semeado com variedade A

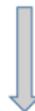
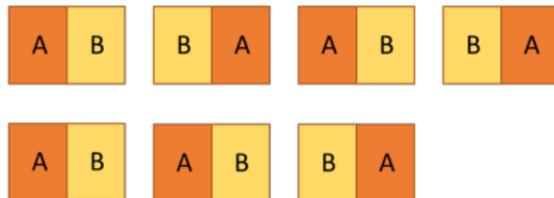


Terreno semeado com variedade B



Amostras independentes

Terreno semeado com as duas variedades



Amostras emparelhadas por talhão

# Amostras independentes e amostras emparelhadas

O emparelhamento permite eliminar o efeito de fatores exteriores ao objetivo do estudo.

Neste caso, eventuais diferenças na composição do solo e nas condições de humidade e temperatura, poderiam afetar o rendimento do milho.

O emparelhamento, ao tornar as unidades experimentais mais homogéneas, permite que diferenças que se observem nos rendimentos sejam exclusivamente atribuídas à diferença entre as variedades do milho e não a outros fatores externos.

# Comparação dos valores esperados de duas populações quando as amostras são independentes

Duas populações,  $X$  e  $Y$  tais que

$$E[X] = \mu_X, E[Y] = \mu_Y, \text{Var}[X] = \sigma_X^2, \text{Var}[Y] = \sigma_Y^2.$$

Para comparar  $\mu_X$  com  $\mu_Y$ , pode fazer-se

- intervalo de confiança para  $\mu_X - \mu_Y$
- teste de hipóteses a  $\mu_X - \mu_Y$

## Estimador de $\mu_X - \mu_Y$ em amostras independentes

$(X_1, X_2, \dots, X_{n_X})$  amostra aleatória da população  $X$  com média  $\bar{X}$   
 $(Y_1, Y_2, \dots, Y_{n_Y})$  amostra aleatória da população  $Y$  com média  $\bar{Y}$

$$\bar{X} - \bar{Y}$$

# Comparação dos valores esperados de duas populações em amostras independentes

Para a distribuição de amostragem do estimador  $\bar{X} - \bar{Y}$ , será necessário considerar três casos.

Caso A: Populações normais com variâncias conhecidas

$$\bar{X} - \bar{Y} \sim \mathcal{N} \left( \mu_X - \mu_Y, \sqrt{\frac{\sigma_X^2}{n_X} + \frac{\sigma_Y^2}{n_Y}} \right)$$
$$\Leftrightarrow \frac{(\bar{X} - \bar{Y}) - (\mu_X - \mu_Y)}{\sqrt{\frac{\sigma_X^2}{n_X} + \frac{\sigma_Y^2}{n_Y}}} \sim \mathcal{N}(0, 1)$$

# Comparação dos valores esperados de duas populações em amostras independentes

## Caso B: Amostras grandes

$$\frac{(\bar{X} - \bar{Y}) - (\mu_X - \mu_Y)}{\sqrt{\frac{\sigma_X^2}{n_X} + \frac{\sigma_Y^2}{n_Y}}} \sim \mathcal{N}(0, 1) \quad \text{se } \sigma_X \text{ e } \sigma_Y \text{ conhecidos}$$

$$\frac{(\bar{X} - \bar{Y}) - (\mu_X - \mu_Y)}{\sqrt{\frac{s_X^2}{n_X} + \frac{s_Y^2}{n_Y}}} \sim \mathcal{N}(0, 1) \quad \text{se } \sigma_X \text{ e } \sigma_Y \text{ desconhecidos}$$

## Caso C: Populações normais com variâncias desconhecidas mas supostas iguais

$$\frac{(\bar{X} - \bar{Y}) - (\mu_X - \mu_Y)}{S_p \sqrt{\frac{1}{n_X} + \frac{1}{n_Y}}} \sim t_{(n_X+n_Y-2)} \quad \text{em que } S_p^2 = \frac{(n_X-1)S_X^2 + (n_Y-1)S_Y^2}{(n_X+n_Y-2)}$$

# Comparação das variâncias de duas populações em amostras independentes

Sejam  $X$  e  $Y$  duas populações normais:

$X \sim \mathcal{N}(\mu_X, \sigma_X)$  e  $Y \sim \mathcal{N}(\mu_Y, \sigma_Y)$ ;

$(X_1, X_2, \dots, X_{n_X})$  amostra aleatória extraída da população  $X$  e

$(Y_1, Y_2, \dots, Y_{n_Y})$  amostra aleatória extraída da população  $Y$   
duas amostras independentes.

Estimador de  $\sigma_X^2/\sigma_Y^2$  em amostras independentes de populações normais

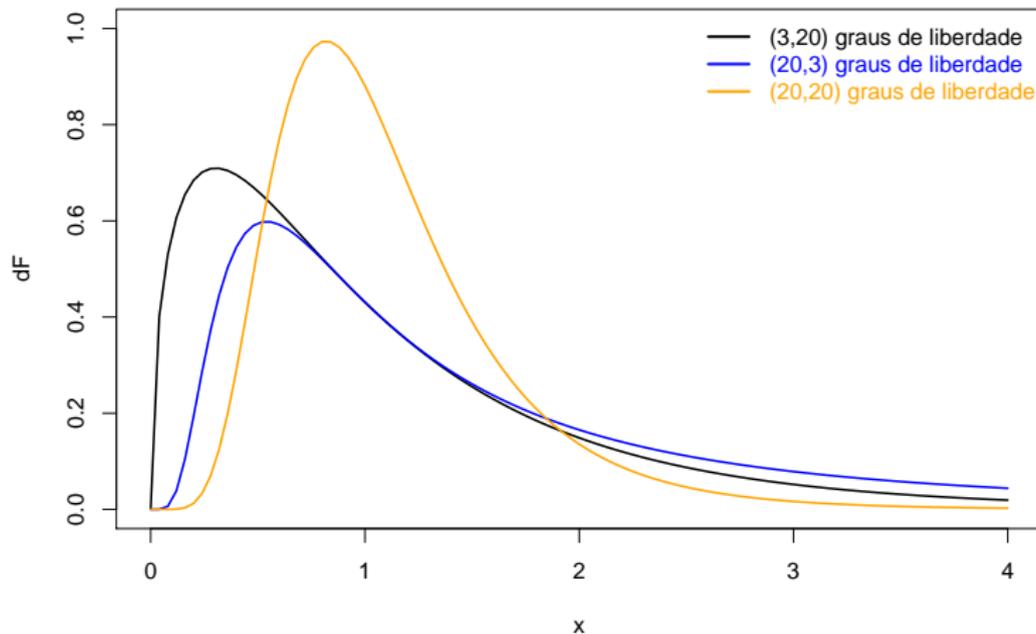
$$\frac{S_X^2}{S_Y^2}$$

A distribuição de amostragem é

$$\frac{S_X^2/\sigma_X^2}{S_Y^2/\sigma_Y^2} \sim F_{(n_X-1, n_Y-1)}$$

# Comparação das variâncias de duas populações em amostras independentes

Função densidade da distribuição  $F$  com  $(m, n)$  graus de liberdade,  $F_{(m,n)}$



# Comparação dos valores esperados de duas populações quando as amostras são emparelhadas

- Duas populações,  $X$  e  $Y$  tais que  $E[X] = \mu_X$ ,  $E[Y] = \mu_Y$
- $(X_1, X_2, \dots, X_n)$  amostra aleatória da população  $X$
- $(Y_1, Y_2, \dots, Y_n)$  amostra aleatória da população  $Y$
- $(D_1, D_2, \dots, D_n)$  amostra das diferenças,  $D_i = X_i - Y_i$   
( $i = 1, \dots, n$ )

$(D_1, D_2, \dots, D_n)$  é uma amostra da população das diferenças,  $D = X - Y$ , com  $E[D] = \mu_D = \mu_X - \mu_Y$  e  $Var[D] = \sigma_D^2$ .

O estimador de  $\mu_D$  é  $\bar{D}$ . Os resultados referentes à estimação de  $\mu$  numa população, podem ser utilizados para a estimação de  $\mu_D$  na população das diferenças.

# Comparação dos valores esperados de duas populações quando as amostras são emparelhadas

Caso A: População  $D$  normal com  $\sigma_D$  conhecido

$$\frac{\bar{D} - \mu_D}{\sigma_D/\sqrt{n}} \sim \mathcal{N}(0, 1)$$

Caso B: População  $D$  com qualquer distribuição e amostra grande

$$\frac{\bar{D} - \mu_D}{\sigma_D/\sqrt{n}} \sim \mathcal{N}(0, 1) \text{ se } \sigma_D \text{ conhecido}$$

$$\frac{\bar{D} - \mu_D}{s_D/\sqrt{n}} \sim \mathcal{N}(0, 1) \text{ se } \sigma_D \text{ desconhecido}$$

$s_D$  é o desvio padrão da amostra das diferenças.

Caso C: População  $D$  normal com  $\sigma_D$  desconhecido

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

em que  $s_D^2$  é o estimador de  $\sigma_D^2$ .

# Comparação dos valores esperados de duas populações quando as amostras são emparelhadas

Note-se que, sendo as amostras emparelhadas (não independentes),

- $X_i \sim \mathcal{N}$  e  $Y_i \sim \mathcal{N} \not\Rightarrow D_i = X_i - Y_i \sim \mathcal{N}$
- $Var[D_i] = Var[X_i] + Var[Y_i] - 2Cov[X_i, Y_i]$

# Comparação dos parâmetros de duas populações no R

Comparação dos valores esperados em duas amostras independentes de populações normais com variâncias supostas iguais

- Teste bilateral ou intervalo de confiança:

$$H_0: \mu_X - \mu_Y = 0 \text{ vs } H_1: \mu_X - \mu_Y \neq 0$$

`t.test(x, y, alternative="two.sided", mu=0, paired=FALSE, var.equal=TRUE)`

- Teste unilateral esquerdo:

$$H_0: \mu_X - \mu_Y \geq 0 \text{ vs } H_1: \mu_X - \mu_Y < 0$$

`t.test(x, y, alternative="less", mu=0, paired=FALSE, var.equal=TRUE)`

- Teste unilateral direito:

$$H_0: \mu_X - \mu_Y \leq 0 \text{ vs } H_1: \mu_X - \mu_Y > 0$$

`t.test(x, y, alternative="greater", mu=0, paired=FALSE, var.equal=TRUE)`

# Comparação dos parâmetros de duas populações no R

Comparação dos valores esperados em duas amostras emparelhadas, supondo que a população das diferenças tem distribuição normal

- Teste bilateral ou intervalo de confiança:

$$H_0: \mu_X - \mu_Y = 0 \text{ vs } H_1: \mu_X - \mu_Y \neq 0$$

t.test(x, y, alternative="two.sided", mu=0, paired=TRUE)

- Teste unilateral esquerdo:

$$H_0: \mu_X - \mu_Y \geq 0 \text{ vs } H_1: \mu_X - \mu_Y < 0$$

t.test(x, y, alternative="less", mu=0, paired=TRUE)

- Teste unilateral direito:

$$H_0: \mu_X - \mu_Y \leq 0 \text{ vs } H_1: \mu_X - \mu_Y > 0$$

t.test(x, y, alternative="greater", mu=0, paired=TRUE)

# Comparação dos parâmetros de duas populações no R

**Comparação das variâncias** em duas amostras independentes de populações normais

- Teste bilateral ou intervalo de confiança:

$$H_0: \sigma_X^2/\sigma_Y^2 = 1 \text{ vs } H_1: \sigma_X^2/\sigma_Y^2 \neq 1$$

`var.test(x, y, ratio=1, alternative="two.sided")`

- Teste unilateral esquerdo:

$$H_0: \sigma_X^2/\sigma_Y^2 \geq 1 \text{ vs } H_1: \sigma_X^2/\sigma_Y^2 < 1$$

`var.test(x, y, ratio=1, alternative="less")`

- Teste unilateral direito:

$$H_0: \sigma_X^2/\sigma_Y^2 \leq 1 \text{ vs } H_1: \sigma_X^2/\sigma_Y^2 > 1$$

`var.test(x, y, ratio=1, alternative="greater")`

# Comparação de proporções

Pretende-se comparar as proporções de “sucessos” em duas populações com base em duas amostras independentes.

$X_1$  representa o número de sucessos numa amostra de dimensão  $n_1$  de uma população em que a proporção de sucessos é  $p_1$ ,  
 $X_1 \sim \mathcal{B}(n_1, p_1)$

$X_2$  representa o número de sucessos numa amostra de dimensão  $n_2$  de outra população em que a proporção de sucesso é  $p_2$ ,  
 $X_2 \sim \mathcal{B}(n_2, p_2)$

O estimador da diferença entre as duas proporções é

$$\hat{P}_1 - \hat{P}_2 = \frac{X_1}{n_1} - \frac{X_2}{n_2}$$

Se  $n_1$  e  $n_2$  grandes,

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

# Testes $\chi^2$ de Pearson

Os slides desta Secção são também baseados em material pedagógico disponibilizado pelo Prof. Jorge Cadima no âmbito da UC Estatística e Delineamento.

Os testes de qui-quadrado de Pearson são testes de ajustamento para dados nominais ou dados classificados em categorias ou classes.

Trata-se de testes de hipóteses não paramétricos, baseados em contagens, que partilham a mesma estatística de teste, a estatística de Pearson. São também designados testes  $\chi^2$ , uma vez que a estatística de teste segue, *assintoticamente*, uma distribuição qui-quadrado.

Vão ser abordados os casos:

- Testes  $\chi^2$  em dados de contagem unidimensionais
- Testes  $\chi^2$  em tabelas de contingência (bidimensionais)
  - Probabilidades especificadas por uma teoria (genética, por exemplo)
  - Testes de Independência
  - Testes de Homogeneidade

# Teste $\chi^2$ em dados de contagem unidimensionais

Suponha-se que uma população é caracterizada por um atributo qualitativo que pode assumir as categorias  $A_1, A_2, \dots, A_k$  com probabilidades desconhecidas.

Considerando um conjunto de valores  $\pi_i > 0$  ( $i = 1, 2, \dots, k$ ) tais que  $\sum_{i=1}^k \pi_i = 1$ , pretende-se testar as hipóteses:

$H_0: P(A_i) = \pi_i, \forall i = 1, \dots, k$  versus  $H_1: P(A_i) \neq \pi_i$  para algum  $i$

Recolhe-se uma amostra de dimensão  $N$  e conta-se o número de elementos da amostra que pertencem a cada categoria. Para a categoria  $A_i$ , seja

$O_i$  : a frequência (absoluta) observada na amostra;

$E_i = N\pi_i$  : a frequência esperada ao abrigo da hipótese nula.

# Teste $\chi^2$ em dados de contagem unidimensionais

Pearson sugeriu, no início do século XX, a

## Estatística de teste

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

que é uma medida do afastamento entre os dados e a hipótese nula. Quanto maior for o valor observado de  $X^2$ , menos plausível é a hipótese nula. Por isso a região crítica é unilateral direita. Para definir a região crítica ou de rejeição (ou o p-value) é necessário conhecer a distribuição por amostragem de  $X^2$ , no caso de  $H_0$  ser válida.

## Distribuição por amostragem

$$X^2 = \sum_{i=1}^k \frac{(O_i - E_i)^2}{E_i} \sim \chi^2_{(k-1)} \quad \text{sob } H_0$$

# Teste $\chi^2$ em dados de contagem unidimensionais

A distribuição  $\chi^2$  é **assintótica**, isto é, é uma distribuição aproximada, válida apenas para amostras “grandes”. De acordo com Cochran, o critério de validade da distribuição  $\chi^2$  é:

## Critério de Cochran

- nenhum  $E_j$  inferior a 1
- não mais de 20% dos  $E_j$ 's inferiores a 5.

Note-se que o critério se aplica às **frequências esperadas** e não às observadas. Quando o critério não se verifica, agrupam-se categorias de forma a atingir as frequências mínimas requeridas.

# Teste $\chi^2$ em dados de contagem unidimensionais

O teste  $\chi^2$  em dados de contagem unidimensionais pode resumir-se na seguinte tabela:

categoria	$A_1$	$A_2$	$\dots$	$A_k$	Total
Probabilidades sob $H_0$	$\pi_1$	$\pi_2$	$\dots$	$\pi_k$	1
Frequências esperadas	$E_1$	$E_2$	$\dots$	$E_k$	$N$
Frequências observadas	$O_1$	$O_2$	$\dots$	$O_k$	$N$
Contribuição para a E.T.	$\frac{(O_1 - E_1)^2}{E_1}$	$\frac{(O_2 - E_2)^2}{E_2}$	$\dots$	$\frac{(O_k - E_k)^2}{E_k}$	$\chi^2_{\text{calc}}$

## Exemplo 12 | hipótese genética

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

Genótipos	$cc$	$cC$	$CC$
Num. plantas	18	44	28

**Questão:** Estão estes dados de acordo com o modelo genético?

## Exemplo 12 | hipótese genética

Teste  $\chi^2$  de Pearson considerando as  $k = 3$  categorias para os genótipos:

- $H_0: \pi_1 = 0.25, \pi_2 = 0.5, \pi_3 = 0.25$  vs  $H_1$ : probab. diferentes
- Estatística de teste:

$$\chi^2 = \sum_{i=1}^3 \frac{(\mathcal{O}_i - E_i)^2}{E_i} \sim \chi_{(2)}^2 \quad \text{sob } H_0$$

em que  $\mathcal{O}_i$  é a frequência observada da  $i$ -ésima categoria e  $E_i = N\pi_i = 90\pi_i$  é a frequência esperada. A distribuição  $\chi_{(2)}^2$  só é válida para amostras grandes.

- Região crítica: ao nível de significância  $\alpha = P[\text{rejeitar } H_0 \mid H_0 \text{ verdadeira}] = 0.05$ , rejeita-se  $H_0$  se  $X_{\text{calc}}^2 > \chi_{0.05(2)}^2 = 5.991$ .
- Tabela resumo:

genótipo	cc	cC	CC	Total
$\pi_i$	0.25	0.5	0.25	1
$E_i$	22.5	45	22.5	90
$\mathcal{O}_i$	18	44	28	90
$\frac{(\mathcal{O}_i - E_i)^2}{E_i}$	0.9000	0.0222	1.3444	$X_{\text{calc}}^2 = 2.2667$

## Exemplo 12 | hipótese genética

- Todas as frequências esperadas são superiores a 5, o que garante a validade da distribuição assintótica ao abrigo do critério de Cochran.
- Como  $X^2_{\text{calc}} \notin \text{RC}$ , não se rejeita  $H_0$  ao nível de significância de 5%, não havendo razões para duvidar da hipótese genética que prevê aquelas proporções para os genótipos.

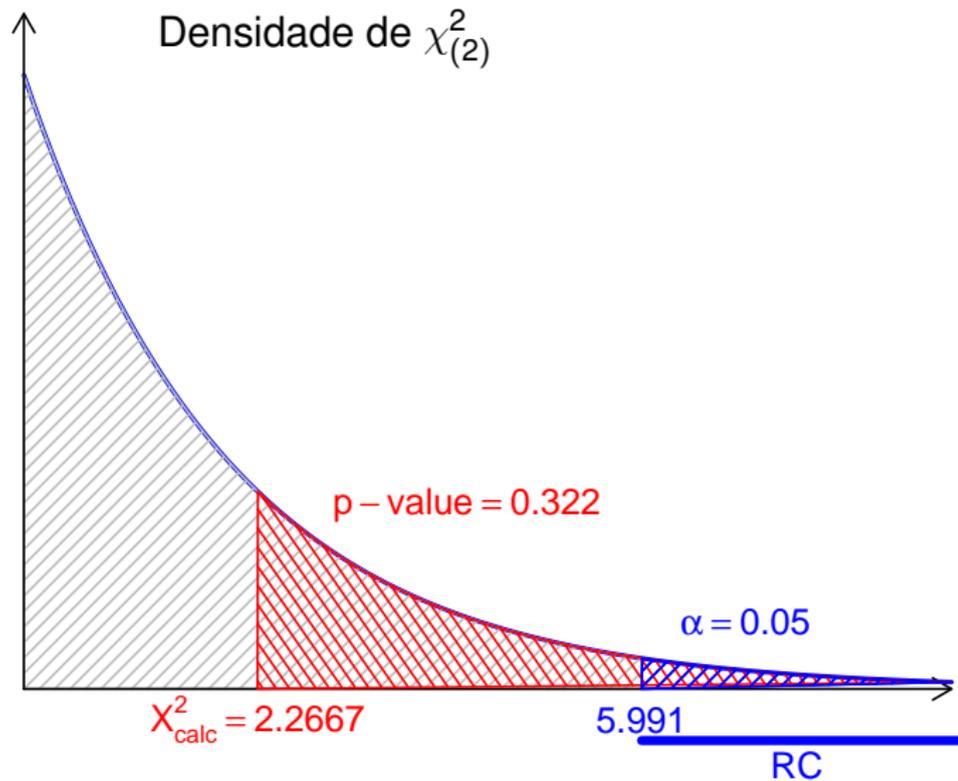
No  :

```
> Oi <- c(18,44,28)
> pi <- c(0.25,0.5,0.25)
> chisq.test(Oi,p=pi)
```

Chi-squared test for given probabilities

```
data: Oi
X-squared = 2.2667, df = 2, p-value = 0.322
```

# Exemplo 12 | hipótese genética



## Exemplo 13 | ajustamento à Binomial

No controlo de qualidade de uma linha de produção de latas de cerveja, contou-se o número de latas impróprias em cada um de 200 *packs* de 6 latas. Os resultados foram:

Núm. latas impróprias	0	1	2	3	4	5	6
Núm. <i>packs</i>	141	48	9	2	0	0	0

**Questão:** É admissível que o número de latas impróprias por *pack* siga uma lei Binomial com probabilidade de sucesso  $p = 0.04$ ?

Note-se que cada uma das 200 contagens corresponde ao resultado de repetir 6 vezes uma experiência que resulta no resultado “lata imprópria” (êxito) ou “lata aceite” (fracasso). A distribuição Binomial será válida se os controlos de cada lata são independentes e com probabilidade constante de êxito.

## Exemplo 13 | ajustamento à Binomial

Poderá realizar-se um teste de  $\chi^2$  de Pearson tomando como “categorias” os valores possíveis para a variável. Neste caso trata-se de um teste de ajustamento a uma distribuição discreta.

Teste  $\chi^2$  de Pearson :

- $H_0: X \sim \mathcal{B}(6, 0.04)$  vs  $H_1: X \not\sim \mathcal{B}(6, 0.04)$

- Estatística de teste:

$$\chi^2 = \sum_{i=1}^7 \frac{(\mathcal{O}_i - E_i)^2}{E_i} \sim \chi_{(6)}^2 \quad \text{sob } H_0$$

em que  $\mathcal{O}_i$  é a frequência observada do  $i$ -ésimo valor da v.a.  $X$  e  $E_i = N\pi_i = 200\pi_i$  é a frequência esperada. As probabilidades sob  $H_0$  são  $P[X = x] = \binom{6}{x} p^x (1-p)^{6-x}$ ,  $x = 0, 1, \dots, 6$ . A validade da distribuição  $\chi_{(6)}^2$  pode ser apreciada através do critério de Cochran.

## Exemplo 13 | ajustamento à Binomial

- Tabela resumo:

$x_j$	0	1	2	3	4	5	6	Total
$\pi_j$	0.7828	0.1957	0.0204	0.0011	0.0000	0	0	1
$E_j$	156.552	39.138	4.077	0.226	0.007	0	0	200
$O_j$	141	48	9	2	0	0	0	200

O critério de Cochran não é válido pois há classes com a frequência esperada inferior a 1. **Agrupando as 4 últimas classes**, o critério é aproximadamente válido:

$x_j$	0	1	$\geq 2$	Total
$\pi_j$	0.7828	0.1957	0.0216	1
$E_j$	156.5516	39.1379	4.3106	200
$O_j$	141	48	11	200

## Exemplo 13 | ajustamento à Binomial

Será necessário redefinir a estatística de teste:

- Estatística de teste:

$$X^2 = \sum_{i=1}^3 \frac{(O_i - E_i)^2}{E_i} \sim \chi_{(2)}^2 \quad \text{sob } H_0$$

- Região crítica: ao nível de significância  $\alpha = 0.05$ , rejeita-se  $H_0$  se  $X_{\text{calc}}^2 > \chi_{0.05(2)}^2 = 5.991$ .
- Tabela resumo:

$x_i$	0	1	$\geq 2$	Total
$\pi_i$	0.7828	0.1957	0.0216	1
$E_i$	156.5516	39.1379	4.3106	200
$O_i$	141	48	11	200
$\frac{(O_i - E_i)^2}{E_i}$	1.5449	2.0067	10.3812	$X_{\text{calc}}^2 = 13.9328$

## Exemplo 13 | ajustamento à Binomial

- Como  $X_{\text{calc}}^2 = 13.9328 > 5.991$ , rejeita-se  $H_0$ , optando-se por  $H_1$ :  $X \not\sim B(6, 0.04)$ , ou seja pela hipótese de  $X$  não ter distribuição binomial ou ter distribuição binomial com outro valor de  $p$ . A categoria “ $\geq 2$ ” contribui para a estatística de teste com uma parcela com um valor muito elevado que, por si só, levaria à rejeição de  $H_0$ .

No :

```
> Oi <- c(141,48,11)
> pi <- c(dbinom(0:1,6,0.04), 1-pbinom(1,6,0.04))
> chisq.test(Oi,p=pi)
```

Chi-squared test for given probabilities

```
data: Oi
X-squared = 13.933, df = 2, p-value = 0.0009431
```

Warning message:

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

## Exemplo 14 | ajustamento à Poisson

Num ensaio sobre pereiras Rocha, foi testado o sistema de condução Tatura. Foi observado o número de gomos florais em 80 pereiras, tendo-se obtido as contagens abaixo indicadas. Pretende-se saber se é possível considerar que o número de gomos por árvore segue uma lei Poisson, com valor esperado 7.

No. de gomos	0	1	2	3	4	5	6	7	8	9	10	11	12	13	14	15
No. de árvores	0	1	3	9	6	15	4	8	7	6	4	6	3	4	3	1

Para que as probabilidades, ao abrigo da hipótese de validade da Poisson, somem 1 é necessário acrescentar a categoria “ $\geq 16$ ”.

Sendo  $X \sim \mathcal{P}(7)$ ,  $P[X = x] = \frac{e^{-7}7^x}{x!}$ ,  $x = 0, 1, 2, \dots$ . As frequências esperadas para as duas primeiras categorias são  $E_1 = 80 P[X = 0] = 0.073$  e  $E_2 = 0.51$ , ambas  $< 1$ . Há também demasiadas categorias com  $E_i < 5$ . É portanto necessário agrupar categorias para que se verifique o critério de Cochran. Sugere-se o seguinte agrupamento em  $k = 9$  categorias:

No. de gomos	$\leq 3$	4	5	6	7	8	9	10	$\geq 11$
No. de árvores	13	6	15	4	8	7	6	4	17

## Exemplo 14 | ajustamento à Poisson

Teste de ajustamento  $\chi^2$  de Pearson :

- $H_0: X \sim \mathcal{P}(7)$  vs  $H_1: X \not\sim \mathcal{P}(7)$
- Estatística de teste:

$$\chi^2 = \sum_{i=1}^9 \frac{(\mathcal{O}_i - E_i)^2}{E_i} \sim \chi_{(8)}^2 \quad \text{sob } H_0$$

em que  $\mathcal{O}_i$  é a frequência observada da  $i$ -ésima categoria e  $E_i = N\pi_i = 80\pi_i$  é a frequência esperada. As probabilidades sob  $H_0$  são  $P[X = x] = \frac{e^{-7}7^x}{x!}$ ,  $x = 0, 1, \dots$ . A validade da distribuição  $\chi_{(8)}^2$  é justificada pela validade do critério de Cochran (no quadro abaixo).

- Região crítica: ao nível de significância  $\alpha = 0.05$ , rejeita-se  $H_0$  se  $\chi_{\text{calc}}^2 > \chi_{0.05(8)}^2 = 15.5043$ .

## Exemplo 14 | ajustamento à Poisson

- Tabela resumo<sup>1</sup>:

$x_i$	$\leq 3$	4	5	6	7	8	9	10	$\geq 11$	Total
$\pi_i$	0.082	0.091	0.128	0.149	0.149	0.130	0.101	0.071	0.099	1
$E_i$	6.541	7.30	10.22	11.92	11.92	10.43	8.11	5.68	7.88	80
$O_i$	13	6	15	4	8	7	6	4	17	80
$\frac{(O_i - E_i)^2}{E_i}$	6.377	0.231	2.239	5.262	1.289	1.128	0.550	0.496	10.549	28.121

- $\chi^2_{\text{calc}} = 28.121$  pertence à região crítica, logo rejeita-se a hipótese de que  $X$  tenha distribuição Poisson com valor esperado 7, ao nível de significância de 5 %. A última parcela da estatística de teste tem um valor muito elevado, contribuindo fortemente para a rejeição de  $H_0$ .

---

<sup>1</sup>Os valores de  $E_i$  (frequências esperadas) foram obtidos utilizando mais casas decimais em  $\pi_i$  do que as mostradas.

## Exemplo 14 | ajustamento à Poisson

No :

```
> pi<-c(ppois(3,7), dpois(4:10, 7), 1-ppois(10,7))  
> Oi <- c(13, 6, 15, 4, 8, 7, 6, 4, 17)  
> chisq.test(Oi,p=pi)
```

Chi-squared test for given probabilities

data: Oi

X-squared = 28.122, df = 8, p-value = 0.0004516

# Teste de ajustamento com estimação de parâmetros

## Nota:

Em vez de se admitir um valor para o parâmetro  $p$  da distribuição binomial ou para o parâmetro  $\lambda$  da distribuição de Poisson, poder-se-ia, em alternativa, estimar-se  $p$  e  $\lambda$  a partir dos dados da amostra. Quando se usam estimativas de parâmetros para estimar as frequências esperadas, a distribuição da estatística do teste de Pearson ainda é assintoticamente  $\chi^2$  mas o número de graus de liberdade terá que ser adaptado ao número de parâmetros estimados. Este assunto não vai ser desenvolvido.

# Testes $\chi^2$ em tabelas de contingência

Uma **tabela de contingência** é uma matriz onde se representam **frequências absolutas de pares** de categorias de dois atributos qualitativos ou discretos. Existem **duas características**,  $A$  e  $B$ , em que  $A$  pode tomar  $a$  valores distintos e  $B$  pode assumir  $b$  valores distintos. Na tabela

	$B_1$	$B_2$	$\dots$	$B_b$	Soma
$A_1$	$O_{11}$	$O_{12}$	$\dots$	$O_{1b}$	$N_{1.}$
$A_2$	$O_{21}$	$O_{22}$	$\dots$	$O_{2b}$	$N_{2.}$
$\vdots$	$\vdots$	$\vdots$	$\vdots$	$\vdots$	
$A_a$	$O_{a1}$	$O_{a2}$	$\dots$	$O_{ab}$	$N_{a.}$
Soma	$N_{.1}$	$N_{.2}$	$\vdots$	$N_{.b}$	$N$

$O_{ij}$  representa a frequência observada do par ( $i$ -ésima categoria de  $A$ ,  $j$ -ésima categoria de  $B$ ).  $N_{i.}$  e  $N_{.j}$  são as frequências marginais observadas,  $N_{i.} = \sum_{j=1}^b O_{ij}$  e  $N_{.j} = \sum_{i=1}^a O_{ij}$ .

# Testes $\chi^2$ em tabelas de contingência

Nos testes  $\chi^2$  em tabelas de contingência pretende-se **testar hipóteses sobre as probabilidades conjuntas  $P(A_i, B_j)$**  (desconhecidas) de o atributo  $A$  pertencer à categoria  $A_i$  e o atributo  $B$  pertencer à categoria  $B_j$ . Designam-se  $\pi_{ij}$  ( $i = 1, \dots, a, j = 1, \dots, b$ ) essas probabilidades sob a hipótese nula.

- As probabilidades  $\pi_{ij}$  **podem ser totalmente especificadas** por alguma hipótese (genética, por exemplo) - **Situação 1**

Duas situações com interesse em que  $\pi_{ij}$  têm que ser estimadas são:

- **Teste de independência - Situação 2**
- **Teste de homogeneidade - Situação 3**

## Situação 1: $\pi_{ij}$ especificadas por uma hipótese

Considerando um conjunto de valores  $\pi_{ij}$  ( $i = 1, \dots, a, j = 1, \dots, b$ ) tais que  $\sum_{i=1}^a \sum_{j=1}^b \pi_{ij} = 1$ , pretende-se testar as hipóteses:

$H_0: P(A_i, B_j) = \pi_{ij} \forall (i, j)$  versus  $H_1: P(A_i, B_j) \neq \pi_{ij}$  para algum  $(i, j)$

Recolhe-se uma amostra de dimensão  $N$  e conta-se o número de elementos da amostra que pertencem a cada par de categorias. Para o par  $(A_i, B_j)$ , seja

$O_{ij}$  : a frequência observada na amostra;

$E_{ij} = N\pi_{ij}$  : a frequência esperada ao abrigo da hipótese nula.

# Situação 1: $\pi_{ij}$ especificadas por uma hipótese

A estatística do teste e a sua distribuição por amostragem são idênticas ao caso unidimensional:

## Estatística de teste

$$\chi^2 = \sum_{i=1}^a \sum_{j=1}^b \frac{(\mathcal{O}_{ij} - E_{ij})^2}{E_{ij}}$$

## Distribuição por amostragem

$$\chi^2 = \sum_{i=1}^a \sum_{j=1}^b \frac{(\mathcal{O}_{ij} - E_{ij})^2}{E_{ij}} \sim \chi^2_{(ab-1)} \quad \text{sob } H_0$$

A validade da distribuição assintótica depende da verificação de um critério que define quando é que uma amostra é considerada suficientemente grande. Pode-se aplicar o critério de Cochran às frequências esperadas  $E_{ij}$  de cada célula da matriz.

## Situação 1: $\pi_{ij}$ especificadas por uma hipótese

O teste  $\chi^2$  em tabelas de contingência pode resumir-se na seguinte tabela:

	$B_1$	$B_2$	$\dots$	$B_b$	Soma
$A_1$	$O_{11} (E_{11})$	$O_{12} (E_{12})$	$\dots$	$O_{1b} (E_{1b})$	$N_{1.}$
$A_2$	$O_{21} (E_{21})$	$O_{22} (E_{22})$	$\dots$	$O_{2b} (E_{2b})$	$N_{2.}$
$\vdots$	$\vdots$	$\vdots$	$\vdots$	$\vdots$	
$A_a$	$O_{a1} (E_{a1})$	$O_{a2} (E_{a2})$	$\dots$	$O_{ab} (E_{ab})$	$N_{a.}$
Soma	$N_{.1}$	$N_{.2}$	$\vdots$	$N_{.b}$	$N$

## Exemplo 15 | hipótese genética

Supõe-se que em coelhos existe: um gene que controla a cor do pêlo, com um alelo determinante do cinzento (dominante) e um alelo determinante do branco (recessivo); outro gene que controla o tipo de pelagem, com um alelo determinante do pêlo normal (dominante) e um alelo determinante da pelagem tipo Rex (recessivo).

Para avaliar a hipótese de segregação independente e dominância / recessividade dos genes, realiza-se uma experiência cruzando coelhos duma população inicial que são heterozigóticos nos dois genes, i.e., têm um alelo de cada cor e um alelo de cada tipo de pelagem.

Numa descendência de  $N = 232$  coelhos, observou-se:

Cor	Pêlo	
	Normal	Rex
Cinzento	134	44
Branco	42	12

## Exemplo 15 | hipótese genética

Na hipótese de segregação independente e dominância / recessividade dos 2 genes, espera-se que a proporção de coelhos na descendência com cada par de características seja: 9 : 3 : 3 : 1 de, respetivamente, coelhos cinzentos de pelagem normal : coelhos cinzentos de pelagem Rex : coelhos brancos de pelagem normal : coelhos brancos de pelagem Rex. Portanto as hipóteses do teste são:

- $H_0: \pi_{11} = \frac{9}{16}, \pi_{12} = \pi_{21} = \frac{3}{16}, \pi_{22} = \frac{1}{16}$  versus  $H_1: \text{algum } \pi_{ij} \text{ diferente}$
- A estatística do teste é:  $X^2 = \sum_{i=1}^2 \sum_{j=1}^2 \frac{(O_{ij} - E_{ij})^2}{E_{ij}} \sim \chi_{(4-1)}^2$  sob  $H_0$ .  
As frequências esperadas obtêm-se multiplicando as probabilidades pelo número total de observações,  $E_{ij} = 232\pi_{ij}$ .
- $H_0$  é rejeitada para valores elevados de discrepância entre frequências observadas e esperadas, a região crítica é unilateral direita. Ao nível de significância  $\alpha = 0.05$ , rejeita-se  $H_0$  se  $X_{\text{calc}}^2 > \chi_{0.05(3)}^2 = 7.8147$ .

## Exemplo 15 | hipótese genética

- Tabela resumo:

Cor	Pêlo	
	Normal	Rex
Cinzento	134 (130.5)	44 (43.5)
Branco	42 (43.5)	12 (14.5)

- O valor da estatística de teste é então:

$$X_{\text{calc}}^2 = \frac{(134 - 130.5)^2}{130.5} + \frac{(44 - 43.5)^2}{43.5} + \frac{(42 - 43.5)^2}{43.5} + \frac{(12 - 14.5)^2}{14.5} = 0.5824$$

- Não se rejeita  $H_0$ , i.e., não se rejeitam as hipóteses genéticas referidas (dominância/recessividade e segregação independente dos genes), ao nível de significância de 5%.

- No :

```
> Oij <- c(134, 44, 42, 12)
> pij <- c(9, 3, 3, 1)/16
> chisq.test(Oij, p=pij)
      Chi-squared test for given probabilities
data:  Oij
X-squared = 0.58238, df = 3, p-value = 0.9005
```

## Situação 2: Teste de independência

Os **testes de independência** têm por objetivo averiguar a existência de uma associação entre dois atributos  $A$  e  $B$ . A hipótese testada é a hipótese de independência. Se os atributos são independentes, as probabilidades conjuntas são iguais aos produtos das probabilidades marginais:

$$P(A_i, B_j) = P(A_i)P(B_j), \forall(i, j)$$

Portanto as hipóteses em confronto no teste são:

$H_0: \pi_{ij} = \pi_{i.} \pi_{.j} \forall(i, j)$  versus  $H_1: \text{algum } \pi_{ij} \neq \pi_{i.} \pi_{.j}$

em que  $\pi_{i.} = \sum_{j=1}^b \pi_{ij}$  e  $\pi_{.j} = \sum_{i=1}^a \pi_{ij}$  são as probabilidades marginais, em geral desconhecidas.

Este teste difere do anterior no sentido em que a hipótese nula do teste não está completamente especificada.

## Situação 2: Teste de independência

As **probabilidades marginais são estimadas** a partir dos dados. Se os dados estão representados numa tabela de contingência como a do slide 241, as probabilidades marginais são estimadas por

$$\hat{\pi}_{i.} = \frac{N_{i.}}{N}, (i = 1, \dots, a) \quad \text{e} \quad \hat{\pi}_{.j} = \frac{N_{.j}}{N}, (j = 1, \dots, b)$$

Assim, as **frequências esperadas** ao abrigo de  $H_0$ ,  $E_{ij} = N\pi_{ij} = N\pi_{i.}\pi_{.j}$ , **são estimadas** como

$$\hat{E}_{ij} = N\hat{\pi}_{i.}\hat{\pi}_{.j} = N\frac{N_{i.}}{N}\frac{N_{.j}}{N} = \frac{N_{i.}N_{.j}}{N}$$

## Situação 2: Teste de independência

A estatística do teste tem a expressão idêntica à da Situação 1, a distribuição por amostragem é assintoticamente  $\chi^2$ , mas os **graus de liberdade** são diferentes devido à necessidade de estimação de parâmetros:

### Estatística do teste e distribuição por amostragem

$$\chi^2 = \sum_{i=1}^a \sum_{j=1}^b \frac{(O_{ij} - \hat{E}_{ij})^2}{\hat{E}_{ij}} \sim \chi^2_{(a-1)(b-1)} \quad \text{sob } H_0$$

## Exemplo 16 | Teste de independência

Análises qualitativas sugerem que a distribuição da vegetação herbácea em torno de árvores isoladas, em climas áridos, depende da orientação geográfica. Pretende-se validar estatisticamente esta suspeita, para um dado ecossistema.

Contabilizou-se (até totalizar mil) o número de plantas de três espécies herbáceas que germinaram em torno de árvores isoladas de *Acacia tortilis*, em cada um dos quadrantes com orientação Norte, Este, Sul e Oeste. Obtiveram-se os seguintes resultados:

Espécie	Orientação geográfica				$N_{.j}$
	Norte	Sul	Este	Oeste	
<i>Tribulus terrestris</i>	4	157	12	28	201
<i>Zygophyllum simplex</i>	150	243	26	47	466
<i>Aristida adsencionis</i>	47	73	27	186	333
$N_{.j}$	201	473	65	261	$N = 1000$

## Exemplo 16 | Teste de independência

Pretende-se testar se existe **independência** entre os 2 atributos: Espécie (com  $a = 3$  categorias) e Orientação (com  $b = 4$  categorias).

Teste de hipóteses:

- $H_0: \pi_{ij} = \pi_{i.} \times \pi_{.j}, \forall i = 1, 2, 3, j = 1, 2, 3, 4$  vs.  $H_1: \exists(i, j): \pi_{ij} \neq \pi_{i.} \pi_{.j}$   
 $\pi_{ij}$  é a probabilidade de uma planta ser da  $i$ -ésima espécie e ter germinado num quadrante com a  $j$ -ésima orientação  
 $\pi_{i.}$  é a probabilidade de uma planta escolhida ao acaso ser da  $i$ -ésima espécie  
 $\pi_{.j}$  é a probabilidade de uma planta (de qualquer espécie) ter germinado num quadrante na  $j$ -ésima orientação  
As probabilidades marginais têm que ser estimadas a partir dos dados.

- Estatística de teste: 
$$X^2 = \sum_{i=1}^3 \sum_{j=1}^4 \frac{(O_{ij} - \hat{E}_{ij})^2}{\hat{E}_{ij}} \sim \chi^2_{(6)} \quad \text{sob } H_0,$$

$O_{ij}$  é o número de plantas da  $i$ -ésima espécie observadas num quadrante com a  $j$ -ésima orientação

$\hat{E}_{ij} = N \times \hat{\pi}_{i.} \times \hat{\pi}_{.j} = \frac{N_{i.} \cdot N_{.j}}{1000}$  é a frequência esperada estimada.

## Exemplo 16 | Teste de independência

O menor valor de  $\hat{E}_{ij}$  é  $\hat{E}_{13} = \frac{201 \times 65}{1000} = 13.065$ , que é superior a 5, o que justifica a validade da distribuição assintótica, de acordo com o critério de Cochran.

- Região crítica (unilateral direita): ao nível de significância  $\alpha = 0.05$ , rejeita-se  $H_0$  se  $X_{\text{calc}}^2 > \chi_{0.05(6)}^2 = 12.59$ .
- $X_{\text{calc}}^2 = 332.79 \gg 12.59$ . Trata-se de um valor muito elevado, que leva à rejeição clara da hipótese de independência entre espécie e orientação geográfica.
- Dada a rejeição da hipótese de independência, é interessante investigar quais são as associações significativas entre espécie e orientação.

## Exemplo 16 | Teste de independência

Por exemplo, para a espécie *Zygophyllum simplex*, tem-se

<i>Zygophyllum simplex</i>	Orientação geográfica				Total
	Norte	Sul	Este	Oeste	
$O_{2j}$	150	243	26	47	466
$\hat{E}_{2j}$	93.666	220.418	30.290	121.626	333
$\frac{(O_{2j} - \hat{E}_{2j})^2}{\hat{E}_{2j}}$	33.881	2.314	0.608	45.788	82.591

Só esta espécie contribui com duas parcelas para a estatística de teste que seriam, por si só, suficientes para rejeitar a hipótese nula (cada uma é  $> 12.59$ ). Note-se que  $O_{21} \gg \hat{E}_{21}$ , o que indica uma associação positiva entre esta espécie e a orientação Norte. Pelo contrário,  $O_{24} \ll \hat{E}_{24}$ , o que indica uma associação negativa entre a espécie e a orientação Oeste.

## Exemplo 16 | Teste de independência

No :

```
> Oij <- matrix(c(4,150,47,157,243,73,12,26,27,28,47,186),nrow=3, ncol=4)
```

```
> Oij
```

	[,1]	[,2]	[,3]	[,4]
[1,]	4	157	12	28
[2,]	150	243	26	47
[3,]	47	73	27	186

```
> chisq.test(Oij)
```

Pearson's Chi-squared test

```
data: Oij
```

```
X-squared = 332.79, df = 6, p-value < 2.2e-16
```

## Situação 3: Teste de homogeneidade

Suponha-se que uma população é classificada em  $a$  subpopulações, de acordo com as categorias do atributo  $A$  ( $A_1, A_2, \dots, A_a$ ). O objetivo do teste de homogeneidade é o de averiguar se a distribuição do atributo  $B$  é idêntica (homogénea) para todas as subpopulações, ou seja, pretende-se averiguar se

$$P(B_j|A_1) = P(B_j|A_2) = \dots = P(B_j|A_a), \forall j = 1, 2, \dots, b$$

Designando por  $\pi_{j|i}$  a probabilidade de uma observação da subpopulação  $A_i$  ser classificada na categoria  $B_j$ , as hipóteses em confronto no teste são:

$$H_0 : \begin{cases} \pi_{1|1} = \pi_{1|2} = \dots = \pi_{1|a} [= \pi_{.1}] \\ \pi_{2|1} = \pi_{2|2} = \dots = \pi_{2|a} [= \pi_{.2}] \\ \vdots \\ \pi_{b|1} = \pi_{b|2} = \dots = \pi_{b|a} [= \pi_{.b}] \end{cases} \quad \text{vs} \quad H_1 : \text{alguma igualdade falha}$$

## Situação 3: Teste de homogeneidade

Na disposição do slide 241, a hipótese nula é a de as probabilidades condicionais serem iguais em cada coluna, ou seja de homogeneidade de cada coluna (atributo  $B$ ), através das linhas (subpopulações).

As probabilidades marginais que intervêm em  $H_0$  não são conhecidas e terão que **ser estimadas** a partir dos dados. Neste caso, os dados são constituídos por  $N_1$  elementos da subpopulação  $A_1$ ,  $N_2$

elementos da subpopulação  $A_2, \dots, N_a$  elementos da subpopulação  $A_a$ , ou seja os **totais por linha na tabela de contingência do slide 241 são previamente fixados**. Assim, as **probabilidades marginais de  $B$  são estimadas** por

$$\hat{\pi}_{.j} = \frac{N_{.j}}{N}, \quad (j = 1, \dots, b)$$

As frequências esperadas ao abrigo de  $H_0$  são  $E_{ij} = N_{i.} \pi_{j|i} = N_{i.} \pi_{.j}$ .

As **frequências esperadas estimadas** são  $\hat{E}_{ij} = N_{i.} \hat{\pi}_{.j} = N_{i.} \frac{N_{.j}}{N}$ .

## Situação 3: Teste de homogeneidade

A estatística de teste tem a mesma expressão da Situação 2 e tem a mesma distribuição assintótica (slide 251), isto é,

Estatística do teste e distribuição por amostragem

$$\chi^2 = \sum_{i=1}^a \sum_{j=1}^b \frac{(O_{ij} - \hat{E}_{ij})^2}{\hat{E}_{ij}} \sim \chi_{(a-1)(b-1)}^2 \quad \text{sob } H_0$$

## Exemplo 17 | Teste de homogeneidade

Nos solos de uma dada região foi assinalada a presença de larvas de 4 espécies de insectos que afetam as principais culturas da região.

Pretende-se investigar se as frequências relativas das espécies de larvas são, ou não, iguais nos vários tipos de solos.

Classificaram-se os solos em três tipos: arenosos, limosos e argilosos (atributo  $A$ , com  $a = 3$  categorias).

Em cada tipo de solo foram recolhidas 100 larvas, que foram classificadas de acordo com a respetiva espécie (atributo  $B$ , com  $b = 4$  categorias).

## Exemplo 17 | Teste de homogeneidade

As frequências observadas das espécies de larvas, para cada tipo de solo, foram:

Tipo de solo	Espécie de larva				$N_{j\cdot}$
	1	2	3	4	
Arenoso	27	24	23	26	100
Limoso	20	32	18	30	100
Argiloso	13	37	16	34	100
$N_{\cdot j}$	60	93	57	90	$N = 300$

O objetivo é averiguar se cada espécie de larva se distribui de forma análoga (homogénea) pelos 3 tipos de solo, ou seja

$$P(j|\text{solo arenoso}) = P(j|\text{solo limoso}) = P(j|\text{solo argiloso}) \quad \forall j = 1, 2, 3, 4.$$

# Exemplo 17 | Teste de homogeneidade

## Teste de hipóteses (teste de homogeneidade)

- A hipótese nula é: a probabilidade de uma larva encontrada em cada tipo de solo ser da espécie  $j$ , ( $j = 1, \dots, 4$ ) é igual para todos os tipos de solo, sendo também igual à probabilidade de a larva ser da espécie da  $j$ , independentemente do solo.

$$H_0 : \begin{cases} \pi_{1|\text{solo arenoso}} = \pi_{1|\text{solo limoso}} = \pi_{1|\text{solo argiloso}} [= \pi_{.1}] \\ \pi_{2|\text{solo arenoso}} = \pi_{2|\text{solo limoso}} = \pi_{2|\text{solo argiloso}} [= \pi_{.2}] \\ \pi_{3|\text{solo arenoso}} = \pi_{3|\text{solo limoso}} = \pi_{3|\text{solo argiloso}} [= \pi_{.3}] \\ \pi_{4|\text{solo arenoso}} = \pi_{4|\text{solo limoso}} = \pi_{4|\text{solo argiloso}} [= \pi_{.4}] \end{cases}$$

$H_1$ : alguma igualdade falha

- Estatística do teste:  $X^2 = \sum_{i=1}^3 \sum_{j=1}^4 \frac{(O_{ij} - \hat{E}_{ij})^2}{\hat{E}_{ij}} \sim \chi_{(6)}^2$  sob  $H_0$ ,

$O_{ij}$  é o número de larvas da espécie  $j$  observadas no  $i$ -ésimo solo

$$\hat{E}_{ij} = N_i \cdot \hat{\pi}_{.j} = 100 \times \frac{N_{.j}}{300}, \quad \hat{E}_{i1} = \frac{100 \times 60}{300}, \quad \hat{E}_{i2} = \frac{100 \times 93}{300}, \quad \hat{E}_{i3} = \frac{100 \times 57}{300}, \\ \hat{E}_{i4} = \frac{100 \times 90}{300}.$$

## Exemplo 17 | Teste de homogeneidade

- Região crítica (unilateral direita): ao nível de significância  $\alpha = 0.05$ , rejeita-se  $H_0$  se  $X_{\text{calc}}^2 > \chi_{0.05(6)}^2 = 12.591$ .
- Tabela resumo

Tipo de solo	Espécie de larva				$N_{i.}$
	1	2	3	4	
Arenoso	27 (20)	24 (31)	23 (19)	26 (30)	100
Limoso	20 (20)	32 (31)	18 (19)	30 (30)	100
Argiloso	13 (20)	37 (31)	16 (19)	34 (30)	100
$N_{.j}$	60	93	57	90	$N = 300$

Todas as frequências esperadas são superiores a 5, pelo que o critério de Cochran é válido. Não é necessário agrupar células.

- $X_{\text{calc}}^2 = 10.109$ . Este valor não pertence à região crítica, portanto, ao nível de significância de 5 %, não se rejeita a hipótese de homogeneidade das distribuições de espécies de larva, nos três tipos de solos.

# Exemplo 17 | Teste de homogeneidade

No :

```
> Oij <- matrix(c(27,20,13,24,32,37,23,18,16,26,30,34),nrow=3, ncol=4)
> Oij
      [,1] [,2] [,3] [,4]
[1,]  27  24  23  26
[2,]  20  32  18  30
[3,]  13  37  16  34
> chisq.test(Oij)
```

Pearson's Chi-squared test

```
data:  Oij
X-squared = 10.109, df = 6, p-value = 0.1201
```

# Nota sobre testes de independência *versus* homogeneidade

Os testes de independência e homogeneidade parecem idênticos na sua forma: partilham a mesma estatística de teste e a mesma distribuição de amostragem. A diferença encontra-se no delineamento das experiências.

No **teste de independência**, os elementos da amostra são extraídos ao acaso de uma população e dois atributos são observados para cada elemento. Só o número total de elementos da amostra é previamente fixado pelo experimentador.

No **teste de homogeneidade** os dados são selecionados ao acaso de cada subpopulação separadamente. Os números de elementos de cada subpopulação são previamente definidos pelo experimentador. A hipótese nula é a de cada subpopulação partilhar a mesma distribuição de um outro atributo.

As diferenças são subtis mas importantes: as hipóteses de referência são diferentes e as conclusões também são diferentes.