

# ENSAIOS NÃO PARAMÉTRICOS




## ENSAIOS DE AJUSTAMENTO

Ideia base:



Testar a aderência de um modelo ao comportamento de uma população



# ENSAIOS NÃO PARAMÉTRICOS

Teste pode ser formulado com uma:

Hipótese simples -  $f_0(x|\theta)$  é completamente especificada

Propõe-se um modelo

Propõe-se um valor para o parâmetro

Exemplos:  $X \sim Po(10)$ ,  $X \sim Bi(5, 0.3)$ ,  $X \sim Ex(1/5)$ ,  $X \sim N(2, 16)$

Hipótese composta -  $f_0(x|\theta)$  não é completamente especificada


Propõe-se um modelo

desconhecido

Exemplos:  $X \sim Po(\lambda)$ ,  $X \sim Bi(n, \theta)$ ,  $X \sim Ex(\lambda)$ ,  $X \sim N(\mu, \sigma^2)$

# ENSAIOS NÃO PARAMÉTRICOS

## Testes do Qui-Quadrado



```
graph TD; A[Testes do Qui-Quadrado] --> B[Porque os usamos?]; A --> C[O que é que ele mostra?]; A --> D[Como Calcular e interpretar?]; A --> E[Quando o devemos usar?];
```

**Porque**  
os usamos?

**O que é**  
**que ele**  
mostra?

**Como**  
Calcular e  
interpretar?

**Quando**  
o devemos  
usar?

# ENSAIOS NÃO PARAMÉTRICOS

Testes do Qui-Quadrado

Ensaio de ajustamento

Porque os usamos?



Amostra aleatória de 20 alunos

$(X_1, X_2, \dots, X_{20})$

Para testar a afirmação de que a escola tem igual número de alunos do sexo feminino e masculino




Proporção de alunos sexo feminino = 50%



$H_0: X \sim B(1, 0.5)$

# ENSAIOS NÃO PARAMÉTRICOS


## Testes do Qui-Quadrado



11: 9




Quais os valores para os quais rejeitaríamos  $H_0$ ?



12: 8



Não podemos confiar na intuição\palpite!



14: 6




Precisamos de instrumentos analíticos mais robustos.

# ENSAIOS NÃO PARAMÉTRICOS

## Testes do Qui-Quadrado

## O que é que ele mostra?

Dados observados na amostra



Dados previstos pelo modelo

$X$  - aluno sexo feminino

Hipótese nula -  $H_0 =$  Modelo proposto  $\longrightarrow$

Previsão

DADOS OBSERVADOS  $\begin{matrix} \text{???} \\ \uparrow \\ \text{L-shaped arrow} \end{matrix}$

$$H_0: X \sim B(1, 0.5) \longrightarrow$$
$$\underbrace{10}_{\underbrace{20 * 0.5}_n} : \underbrace{10}_{\underbrace{20 * 0.5}_{1-p_0}}$$

Mostra a distância que separa valores observados e esperados

# ENSAIOS NÃO PARAMÉTRICOS

## Testes do Qui-Quadrado

## Como Calcular?

Estatística teste

Dados observados  
na amostra

Dados previstos  
pelo modelo

$$Q = \sum_{j=1}^m \frac{(\text{Valores Observ.} - \text{Valores Esperados})^2}{\text{Valores Esperados}}$$

Soma

$Q \sim \chi_{(?)^2}$  quando  $H_0$  é verdadeira

# ENSAIOS NÃO PARAMÉTRICOS

Testes do Qui-Quadrado

Como calcular?

	Valores Observ. (1)	Valores previstos. (2)	Val.Obs. - Val. Prev. (1)-(2)	$[(1)-(2)]^2$	$\frac{[(1)-(2)]^2}{(2)}$
Alunas	13	10	3	9	0.9
Alunos	7	10	-3	9	0.9
				$q_{obs} =$	1.8

# ENSAIOS NÃO PARAMÉTRICOS

## Testes do Qui-Quadrado

## Como interpretar?

Para interpretar o teste do Qui-Quadrado precisamos da tabela da Distribuição do  $\chi^2_{(?)}$

df	Probability level (alpha)					
	0.5	0.10	0.05	0.02	0.01	0.001
1	0.455	2.706	3.841	5.412	6.635	10.827
2	1.386	4.605	5.991	7.824	9.210	13.815
3	2.366	6.251	7.815	9.837	11.345	16.268
4	3.357	7.779	9.488	11.668	13.277	18.465
5	4.351	9.236	11.070	13.388	15.086	20.517

Qual a linha do quadro a fixar? A escolha depende dos graus de liberdade da  $\chi^2_{(?)}$



# ENSAIOS NÃO PARAMÉTRICOS

## Testes do Qui-Quadrado

## Como interpretar?

Atributo – género – 2 categorias  $\Rightarrow m = 2 \Rightarrow m - 1 = 1 \Rightarrow \chi^2_{(1)}$

$\alpha$

	Probability level (alpha)					
df	0.5	0.10	0.05	0.02	0.01	0.001
1	0.455	2.706	3.841	5.412	6.635	10.827
2	1.386	4.605	5.991	7.824	9.210	13.815
3	2.366	6.251	7.815	9.837	11.345	16.268
4	3.357	7.779	9.488	11.668	13.277	18.465
5	4.351	9.236	11.070	13.388	15.086	20.517

A região de rejeição de dimensão  $0.05$  é:  $W = \{q: q > q_{0.05}\}$  com

$q_{0.05}: P(Q > q_{0.05}) = 0.05 \Rightarrow q_{0.05} = 3.841$ . Como  $q = 1.8 < 3.841$

Não se  
rejeita  $H_0$

# ENSAIOS NÃO PARAMÉTRICOS

## Testes do Qui-Quadrado

## Como calcular e interpretar?

	Valores Observ. (1)	Valores previstos. (2)	Val.Obs. - Val. Prev. (1)-(2)	$[(1)-(2)]^2$	$\frac{[(1)-(2)]^2}{(2)}$
Alunas	16	10	6	36	3.6
Alunos	4	10	-6	36	3.6
				$q_{obs} =$	7.2

A região de rejeição de dimensão 0.05 é:  $W = \{q: q > 3.841\}$

Como  $q = 7.2 > 3.841$  Rejeita-se  $H_0: X \sim B(1, 0.5)$

# ENSAIOS NÃO PARAMÉTRICOS

Como testar  $H_0: X \sim f_0(x)$ ?

Uma possível solução:  $\longrightarrow$  Teste do Qui-Quadrado à Bondade do Ajustamento

Aplicação do teste em três circunstâncias distintas:

**1ª situação:**  $X$  corresponde a um **atributo qualitativo** com  $m$  categorias

Exemplo: um aspirador vendido em 5 cores  $A_1, A_2, A_3, A_4, A_5$

• Notação:

**Número de categorias**

$A_1, A_2, \dots, A_m$   $\longrightarrow$  Categorias que o atributo pode assumir

$p_j = P(A_j)$   $\longrightarrow$  Probabilidade (desconhecida) de um elemento da população, escolhido ao acaso, apresentar a modalidade  $A_j$  ( $j = 1, 2, \dots, m$ )

# ENSAIOS NÃO PARAMÉTRICOS

- Hipótese nula  $H_0: p_j = p_{0j}$  ( $j = 1, 2, \dots, m$ ) contra  $H_1: p_j \neq p_{0j}$ , para algum  $j$

$p_{0_1}, p_{0_2}, \dots, p_{0_m}$  conhecidos  $p_{0j} > 0$  ( $j = 1, 2, \dots, m$ ),  $\sum_{j=1}^m p_{0j} = 1$

- O teste:

$N_j$  - v.a. que representa o número de observações na amostra (de dimensão  $n$ ) que assumem a modalidade  $A_j$  ( $\sum_{j=1}^m N_j = n$ )

Frequência observada da modalidade  $j$   $\leftarrow$   $\left( N_j - n * p_{0j} \right)^2$   $\rightarrow$  Frequência esperada da modalidade  $j$

Estatística teste:  $Q = \sum_{j=1}^m \frac{\left( N_j - n * p_{0j} \right)^2}{n * p_{0j}}$  mede o afastamento entre os dados observados e esperados

Quanto maior for o valor observado  $Q_{obs}$  menos plausível é a hipótese em teste.

Quando  $H_0$  é verdadeira  $Q = \sum_{j=1}^m \frac{\left( N_j - n * p_{0j} \right)^2}{n * p_{0j}} \sim \chi^2_{(m-1)}$

# ENSAIOS NÃO PARAMÉTRICOS

- O teste (continuação):

A região de rejeição de dimensão  $\alpha$  é:  $W = \{q: q > q_\alpha\}$  onde  $q_\alpha: P(Q > q_\alpha) = \alpha$

Frequência da modalidade j observada na amostra

$$\text{Rejeita-se } H_0 \text{ quando } q_{obs} = \sum_{j=1}^m \frac{(n_j - n \cdot p_{0j})^2}{n \cdot p_{0j}} > q_\alpha$$

Ou, utilizando o valor-p:

$$p_{obs} = P(Q > q_{obs} | H_0) \text{ e rejeita-se } H_0 \text{ quando } p_{obs} < \alpha$$

## Observação importante

A distribuição de  $Q$  é válida quando  $n \rightarrow +\infty$

Para que a aproximação no caso finito seja válida, deve-se garantir que:

$$n * p_{0j} \geq 5 \quad (\text{número esperado de elementos em cada classe/modalidade ser pelo menos 5})$$

# ENSAIOS NÃO PARAMÉTRICOS

## ENSAIOS DE AJUSTAMENTO

Exemplo: um aspirador vendido em 5 cores  $A_1, A_2, A_3, A_4, A_5$

Um aspirador é vendido em cinco cores: verde ( $A_1$ ), castanho ( $A_2$ ), vermelho ( $A_3$ ), azul ( $A_4$ ) e branco ( $A_5$ ). Num estudo de mercado para apreciar a popularidade das várias cores analisou-se uma amostra casual de 300 vendas recentes com o seguinte resultado

$A_1$	$A_2$	$A_3$	$A_4$	$A_5$	<b>Total</b>
88	65	52	40	55	300

Pretende testar-se a hipótese de que os consumidores não manifestam preferência por qualquer das cores ( $\alpha = 0.05$ )

$$H_0: p_{0_1} = p_{0_2} = \dots = p_{0_5} = \frac{1}{5}$$

# ENSAIOS NÃO PARAMÉTRICOS

## ENSAIOS DE AJUSTAMENTO

Solução:

1. Formalizar a hipótese nula  $H_0: p_{0_1} = p_{0_2} = \dots = p_{0_5} = \frac{1}{5}$
2. Calcular as frequências esperadas de cada uma das modalidades

Modalidades	Freq. Observada $n_j$	Freq. Esperada $n * p_{0_j}$	$\frac{(n_j - n * p_{0_j})^2}{n * p_{0_j}}$
$A_1$	88	60	13.07
$A_2$	65	60	0.42
$A_3$	52	60	1.07
$A_4$	40	60	6.67
$A_5$	55	60	0.42
	300	300	21.65

3. Efectuar o teste

$$\alpha = 0.05; m - 1 = 4$$

$$q_{0.05}: P(\chi^2_{(5-1)} > q_{0.05}) = 0.05$$

$$q_{0.05} = CHISQ.INV.RT(0.05,4) = 9.49$$

$$q_{obs} = 21.65 > 9.49$$

$$p_{obs} = P(Q > 21.65)$$

$$= CHISQ.DIST.RT(21.65,4) \\ = 0,000235 < 0.05$$

Rejeita-se  $H_0$

# ENSAIOS NÃO PARAMÉTRICOS

## ENSAIOS DE AJUSTAMENTO

- **2ª situação:**  $H_0$  é uma hipótese simples  $H_0: X \sim f_0(x)$  Não envolve qualquer parâmetro desconhecido

Ideia base  $\longrightarrow$  Adaptar esta situação para aplicar a metodologia anterior

- Construir uma partição do domínio de  $X$  em  $m$  classes  $A_1, A_2, \dots, A_m$
- Calcular os valores  $p_{0j} = P(A_j)$   $j = 1, 2, \dots, m$  recorrendo a  $f_0(x)$ 
  - Quando a partição é dada parte-se dela;
  - Quando a partição fica ao nosso cuidado:
    - ▲ Variável contínua: constroem-se, tanto quanto possível, classes equiprováveis
    - ▲ Variável discreta: classes formadas pelos valores de  $D_X$

# ENSAIOS NÃO PARAMÉTRICOS

## ENSAIOS DE AJUSTAMENTO

**Exemplo** (9. 2 do livro) – Um estudo sobre o tempo de vida, em dias, de uma amostra de 1000 tubos electrónicos deu os seguintes resultados:

Tempo de vida	$X \leq 150$ $A_1$	$150 < X < 300$ $A_2$	$300 < X < 450$ $A_3$	$450 < X < 600$ $A_4$	$600 < X < 750$ $A_5$	$X \geq 750$ $A_6$	Total
Freq.Observ.	543	258	120	48	20	11	1000

$$H_0: X \sim Ex(\lambda) \quad e \quad \mu_X = 200 = \frac{1}{\lambda} \Leftrightarrow \lambda = \frac{1}{200}$$

1. Formalizar a hipótese nula  $H_0: X \sim Ex(1/200)$

2. Definir as classes: neste caso já estão definidas

3. Calcular  $p_{0j} = P(X \in A_j) \quad j = 1, 2, \dots, 6$        $F_X(x) = 1 - e^{-\lambda x} \quad x > 0, \lambda > 0$

# ENSAIOS NÃO PARAMÉTRICOS

## ENSAIOS DE AJUSTAMENTO

3. Calcular  $p_{0_j} = P(X \in A_j)$   $j = 1, 2, \dots, 6$   $F_X(x) = 1 - e^{-\lambda x}$   $x > 0, \lambda > 0$

$$p_{0_1} = P(X \in A_1) = P(X \leq 150) = 1 - e^{-\frac{1}{200} * 150} = 0.52763$$

$$p_{0_2} = P(X \in A_2) = P(150 < X < 300) = F_X(300) - F_X(150) = 0.24924$$

$$p_{0_3} = P(X \in A_3) = P(300 < X < 450) = F_X(450) - F_X(300) = 0.11773$$

$$p_{0_4} = P(X \in A_4) = P(450 < X < 600) = F_X(600) - F_X(450) = 0.05561$$

$$p_{0_5} = P(X \in A_5) = P(600 < X < 750) = F_X(750) - F_X(600) = 0.02627$$

$$p_{0_6} = P(X \in A_6) = P(X \geq 750) = 1 - F_X(750) = 0.02352$$

$H_0: X \sim Ex(1/200) \longrightarrow H'_0: p_{0_1} = 0.52763, \dots, p_{0_6} = 0.02352$

↑  
Hipótese aparentada

# ENSAIOS NÃO PARAMÉTRICOS

## ENSAIOS DE AJUSTAMENTO

4. Obter as frequências esperadas das 6 classes Freq. Esperada da classe  $j = n * p_{0j}$

	Frequência Observada	Frequência Esperada	$\frac{(n_j - n * p_{0j})^2}{n * p_{0j}}$
$X \leq 150$	543	527.63	0.4477
$150 < X < 300$	258	249.20	0.3108
$300 < X < 450$	120	117.73	0.0438
$450 < X < 600$	48	55.61	1.0414
$600 < X < 750$	20	26.27	1.4965
$X \geq 150$	11	23.52	6.6646
Total	1000	1000	10.0047

5. Efectuar o teste

$$\alpha = 0.05; m - 1 = 5$$

$$Q_{0.05} = 11.1$$

$$q_{obs} = 10.0047 < 11.1$$

ou

$$p_{obs} = P(Q > 10.005) \\ = 0,075 > 0.05$$

Não se rejeita  $H'_0 \Rightarrow$  pode-se admitir que não será de pôr em causa  $H_0$

# ENSAIOS NÃO PARAMÉTRICOS

## ENSAIOS DE AJUSTAMENTO

### Observação importante

De facto, a hipótese testada não foi,  $H_0: X \sim Ex(1/200)$

mas a hipótese “aparentada”  $H'_0: p_{0_1} = 0.52763, \dots, p_{0_6} = 0.02352$

Se se rejeita  $H'_0$  então não há dúvida de que também se deve rejeitar  $H_0$ .

Quando não se rejeita  $H'_0$ , sobretudo se se tiverem poucas classes, não se pode afirmar com tanta certeza que não se deve rejeitar  $H_0$

# ENSAIOS NÃO PARAMÉTRICOS

## ENSAIOS DE AJUSTAMENTO

- **3ª situação:**  $H_0$  é uma hipótese composta  $H_0: X \sim f_0 \left( x \mid \overbrace{\theta_1, \theta_2, \dots, \theta_k}^{\text{Desconhecidos}} \right)$

**Exemplo** (9.6 do livro) – Numa amostra de 100 peças de fazenda observou-se o número de defeitos por peça tendo-se obtido os resultados seguintes:

Defeitos por peça	0	1	2	3	4	5	Total
Freq. observada	20	30	25	10	10	5	100

Será de aceitar ( $\alpha = 0.05$ ) uma distribuição de Poisson?

1. Formalizar a hipótese nula  $H_0: X \sim Po(\lambda)$  ↙ Desconhecido
2. Estimar o(s) parâmetro(s) desconhecido(s)  $\tilde{\lambda} = \bar{X} \Rightarrow \tilde{\lambda}(x_1, x_2, \dots, x_{100}) = 1.75$

3. Calcular  $\widehat{p}_{0j} = P(\widehat{X} = j)$   
 $j = 0, 1, 2, \dots, 5$

Defeitos/peça	0	1	2	3	4	5
$\widehat{p}_{0j}$	0,17	0,30	0,27	0,16	0,07	0,02

# ENSAIOS NÃO PARAMÉTRICOS

## ENSAIOS DE AJUSTAMENTO

4. Obter as frequências esperadas das 5 classes Freq. Esperada da classe  $j = n * \widehat{p}_{0j}$

Defeitos por peça	0	1	2	3	4 e 5	Total
Freq. observada	20	30	25	10	15	100
Freq. esperada	17.38	30.41	26.61	15.52	9.17	
$\frac{(n_j - n * \widehat{p}_{0j})^2}{n * \widehat{p}_{0j}}$	0,40	0,01	0,10	1,96	2,73	8,09

5. Efectuar o teste

$$\alpha = 0.05; m - 1 = 4$$

$$Q_{0.05} = 9.488$$

$$q_{obs} = 8.09 < 11.1$$

ou

$$p_{obs} = P(Q > 8.09)$$

$$= 0,088 > 0.05$$

Não se rejeita  $H'_0 \Rightarrow$  pode-se admitir que não será de pôr em causa  $H_0$

# ENSAIOS NÃO PARAMÉTRICOS

## TESTE DE INDEPENDÊNCIA

Objectivo: Testar a independência entre 2 variáveis

Variáveis  2 atributos de uma população

Exemplos:

<b>População</b>	<b>Atributo A</b>	<b>Atributo B</b>
Alunos Ensino Superior	Sucesso escolar	Nº retenções Sec.
Atletas de salto em altura	Altura do salto	Género
Atletas que correm a maratona	Género	Idade

# ENSAIOS NÃO PARAMÉTRICOS

## TESTE DE INDEPENDÊNCIA

- **TABELA DE CONTINGÊNCIA**

Observa-se uma amostra à luz de 2 atributos:

Atributo  $A$  com  $r$  modalidades  $A_1, A_2, \dots, A_r$

Atributo  $B$  com  $s$  modalidades  $B_1, B_2, \dots, B_s$

Na célula  $(A_i, B_j)$  da tabela de contingência regista-se o número de elementos da amostra com a modalidade  $i$  do atributo  $A$  e a modalidade  $j$  do atributo  $B$ .

# ENSAIOS NÃO PARAMÉTRICOS

## TESTE DE INDEPENDÊNCIA

Tabela de contingência ( $r \times s$ ) Antes de observar a amostra

	$B_1$	$B_2$	...	$B_s$	Totais
$A_1$	$N_{11}$	$N_{12}$	...	$N_{1s}$	$N_{1\bullet}$
$A_2$	$N_{21}$	$N_{22}$	...	$N_{2s}$	$N_{2\bullet}$
$\vdots$	$\vdots$	$\vdots$	$\vdots$	$\vdots$	$\vdots$
$A_r$	$N_{r1}$	$N_{r2}$	...	$N_{rs}$	$N_{r\bullet}$
Totais	$N_{\bullet 1}$	$N_{\bullet 2}$	...	$N_{\bullet s}$	$N$

Não é aleatório  
porque dimensão  
da amostra é fixa

$N_{ij}$  ( $i = 1, 2, \dots, r; j = 1, 2, \dots, s$ ) - frequência de elementos com modalidade  $i$  do atributo  $A$  e modalidade  $j$  do atributo  $B$  é uma **variável aleatória**.

$$N_{\bullet j} = \sum_{i=1}^r N_{ij} \quad (j = 1, 2, \dots, s), \quad N_{i\bullet} = \sum_{j=1}^s N_{ij} \quad (i = 1, 2, \dots, r)$$

São variáveis  
aleatórias

# ENSAIOS NÃO PARAMÉTRICOS

## TESTE DE INDEPENDÊNCIA

Tabela de contingência observada ( $r * s$ )

	$B_1$	$B_2$	...	$B_s$	Totais
$A_1$	$n_{11}$	$n_{12}$		$n_{1s}$	$n_{1\bullet}$
$A_2$	$n_{21}$	$n_{22}$		$n_{2s}$	$n_{2\bullet}$
$\vdots$					
$A_r$	$n_{r1}$	$n_{r2}$		$n_{rs}$	$n_{r\bullet}$
Totais	$n_{\bullet 1}$	$n_{\bullet 2}$		$n_{\bullet s}$	$n$

$n_{ij}$  ( $i = 1, 2, \dots, r; j = 1, 2, \dots, s$ ) - frequência observada de elementos com modalidade  $i$  do atributo  $A$  e modalidade  $j$  do atributo  $B$ .

$$n_{\bullet j} = \sum_{i=1}^r n_{ij} \quad (j = 1, 2, \dots, s)$$

$$n_{i\bullet} = \sum_{j=1}^s n_{ij} \quad (i = 1, 2, \dots, r)$$

# ENSAIOS NÃO PARAMÉTRICOS

## TESTE DE INDEPENDÊNCIA

- Em termos do universo, as probabilidades (desconhecidas) das células  $(A_i, B_j)$  representam-se por,

$$p_{ij} = P(A_i, B_j) \quad (i = 1, 2, \dots, r; j = 1, 2, \dots, s), \text{ verificando } \sum_{i=1}^r \sum_{j=1}^s p_{ij} = 1$$

- As respectivas probabilidades marginais são dadas por,

$$p_{i\cdot} = \sum_{j=1}^s p_{ij} \quad (i = 1, 2, \dots, r) \text{ verificando } \sum_{i=1}^r p_{i\cdot} = 1$$

$$p_{\cdot j} = \sum_{i=1}^r p_{ij} \quad (j = 1, 2, \dots, s) \text{ verificando } \sum_{j=1}^s p_{\cdot j} = 1$$

- Assumir a **independência entre os 2 atributos** equivale a assumir

$$P(A_i, B_j) = P(A_i) * P(B_j) = p_{i\cdot} * p_{\cdot j}$$

# ENSAIOS NÃO PARAMÉTRICOS

## TESTE DE INDEPENDÊNCIA

logo, a hipótese a testar vai ser:

$$H_0: p_{ij} = p_{i\cdot} p_{\cdot j} \quad \forall (i, j) \quad \text{contra} \quad H_0: p_{ij} \neq p_{i\cdot} p_{\cdot j} \quad \text{algum } (i, j)$$

- Assumindo  $H_0$ , pode estimar-se  $p_{ij}$  a partir de  $p_{i\cdot}$  e  $p_{\cdot j}$
- As estimativas de máxima verosimilhança de  $p_{i\cdot}$  e  $p_{\cdot j}$  são dados por:

$$\widehat{p}_{i\cdot} = \frac{n_{i\cdot}}{n} \quad (i = 1, 2, \dots, r) \quad \text{e} \quad \widehat{p}_{\cdot j} = \frac{n_{\cdot j}}{n} \quad (j = 1, 2, \dots, s) \Rightarrow \widehat{p}_{ij} = \widehat{p}_{i\cdot} \widehat{p}_{\cdot j}$$

- A estatística teste vai avaliar a diferença entre a frequência observada e esperada

Frequência observada

Frequência esperada

$$Q = \sum_{i=1}^r \sum_{j=1}^s \frac{(n_{ij} - n \widehat{p}_{i\cdot} \widehat{p}_{\cdot j})^2}{n \widehat{p}_{i\cdot} \widehat{p}_{\cdot j}} \sim \chi^2_{[(r-1)(s-1)]}$$

# ENSAIOS NÃO PARAMÉTRICOS

## TESTE DE INDEPENDÊNCIA

Notas:

- Os graus de liberdade obtêm-se verificando que existem  $rs$  células e se estimaram  $(r - 1)$  parâmetros referentes ao atributo  $A$  (o último valor está pré-fixado) e  $(s - 1)$  parâmetros referentes ao atributo  $B$ . Tem-se assim,

$$rs - 1 - (r - 1) - (s - 1) = (r - 1)(s - 1)$$

- A região de rejeição vai situar-se, pelas mesmas razões que no teste do qui-quadrado à bondade do ajustamento na aba direita da distribuição
- Para que o teste seja válido mantem-se a restrição de um número mínimo esperado de elementos de cada célula  $(A_i, B_j)$  dado por  $n \hat{p}_{\cdot i} \hat{p}_{\cdot j}$ .

# ENSAIOS NÃO PARAMÉTRICOS

## TESTE DE INDEPENDÊNCIA

**Exemplo** (9.10 do livro) – No quadro que se segue apresenta-se uma tabela 3 construída considerando os 86441 casamentos realizados em 1977 (que se podem considerar uma amostra dos casamentos realizados durante um período de alguns anos), em Portugal Continental (Anuário Estatístico, INE, 1980). Nela são apresentados, para cada sexo, o estado civil dos cônjuges anterior ao casamento.

Atributo  $A$  – estado civil da mulher

Modalidades do Atributo  $A$ :

- 1 – solteira
- 2 – viúva
- 3 - divorciada

Atributo  $B$  – estado civil do homem

Modalidades do Atributo  $B$ :

- 1 – solteiro
- 2 – viúvo
- 3 - divorciado

# ENSAIOS NÃO PARAMÉTRICOS

## TESTE DE INDEPENDÊNCIA

A hipótese a testar é a existência de independência entre o estado civil e o género de cada cônjuge no momento do casamento.

$$H_0: p_{ij} = p_{i\cdot} \cdot p_{\cdot j} \quad \forall (i, j = 1, 2, 3) \quad \text{contra} \quad H_0: p_{ij} \neq p_{i\cdot} \cdot p_{\cdot j} \quad \text{algum} (i, j = 1, 2, 3)$$

$$\widehat{p_{\cdot 1}} = \frac{79588}{86441} = 0,92$$

$$\widehat{p_{\cdot 2}} = \frac{2785}{86441} = 0,03$$

$$\widehat{p_{\cdot 3}} = \frac{4098}{86441} = 0,05$$

	Mulheres	Homens			Totais
		Solteiros	Viúvos	Divorciados	
Solteiras	77670	1573	3115	82358	
Viúvas	545	796	350	1691	
Divorciadas	1343	416	633	2392	
Totais	79558	2785	4098	86441	

$$\widehat{p_{1\cdot}} = \frac{82358}{86441} = 0,95$$

$$\widehat{p_{2\cdot}} = \frac{1691}{86441} = 0,02$$

$$\widehat{p_{3\cdot}} = \frac{2392}{86441} = 0,03$$

# ENSAIOS NÃO PARAMÉTRICOS

## TESTE DE INDEPENDÊNCIA

Cálculo das estimativas para a probabilidade de  $(A_i, B_j) \longrightarrow \hat{p}_{ij} = \hat{p}_{i\cdot} \hat{p}_{\cdot j}$

	$B_1$	$B_2$	$B_3$	$\hat{p}_{i\cdot}$
$A_1$	0,88	0,03	0,05	0,95
$A_2$	0,02	0,00	0,00	0,02
$A_3$	0,03	0,00	0,00	0,03
$\hat{p}_{\cdot j}$	0,92	0,03	0,05	

# ENSAIOS NÃO PARAMÉTRICOS

## TESTE DE INDEPENDÊNCIA

A azul, frequências esperadas na hipótese de os atributos serem independentes

$$\text{Frequência esperada} = n \hat{p}_{i\cdot} \hat{p}_{\cdot j} = 86441 * \hat{p}_{ij} \quad (i = 1, 2, \dots, r; j = 1, 2, \dots, s)$$

$$Q \sim \chi^2_{\left[ \frac{(3-1)(3-1)}{4} \right]}$$

valor - p  
 $= P(Q > Q_{obs.})$   
 $= P(\chi^2_{(4)} > 16509.74)$   
 $\approx 0 \Rightarrow rej. H_0$

Mulheres	Homens			Totais
	Solteiros	Viúvos	Divorciados	
Solteiras	77670 (75800.12)	1573 (2653.45)	3115 (3904.43)	82358
Viúvas	545 (1556.35)	796 (54.48)	350 (80.17)	1691
Divorciadas	1343 (2201.53)	416 (77.07)	633 (113.40)	2392
Totais	79558	2785	4098	86441

Não existe independência entre género e estado civil no momento do casamento

$$Q_{obs} = \frac{(77670 - 75800.12)^2}{75800.12} + \frac{(1573 - 2653.45)^2}{2653.45} + \dots + \frac{(633 - 113.4)^2}{113.4} = 16509.74$$