

## MÉTODOS NÃO PARAMÉTRICOS

$$X \sim f(x|\theta), \quad \theta \in \Theta, \quad (X_1, X_2, \dots, X_n)$$

- **Inferência não paramétrica:** Ao contrário da inferência paramétrica onde o único aspeto desconhecido é o valor do(s) parâmetro(s)  $\theta$ , vamos agora assumir que  $f(\cdot)$  é desconhecida.
- A inferência não paramétrica desenvolve-se assim num quadro bastante mais lato do que a inferência paramétrica e cobre múltiplas vertentes como a estimação de probabilidades, a estimação de funções densidade (probabilidade) caso se saiba que a variável aleatória é contínua (discreta), etc ...
- No quadro da inferência paramétrica apenas se irão abordar (e de forma muito sintética) 2 tópicos:
  - **Os testes de ajustamento** ou melhor dizendo um dos testes de ajustamento, o **teste do qui-quadrado à bondade do ajustamento**. A ideia é apresentar uma ferramenta que permita testar a hipótese chave que se admitiu nos 2 capítulos anteriores: a função  $f(\cdot)$  é conhecida a menos de um conjunto de parâmetros.
  - **O teste de independência do qui-quadrado** – Este segundo tópico aborda, como o nome indica, um dos testes existentes com vista a apurar se é aceitável considerar que dois fatores são independentes.

## TESTE DE AJUSTAMENTO

- **Problema:** Recolhida uma amostra casual de determinada população para a qual é proposta determinada distribuição, como testar essa proposta.
- A proposta pode corresponder a uma **hipótese simples** ou a uma **hipótese composta**:
  - Hipótese simples:  $f_0(x)$  é completamente especificada  
Exemplos: Poisson com média igual a 10, binomial 5 e 0.3
  - Hipótese composta:  $f_0(x)$  não é completamente especificada, isto é, depende de parâmetros desconhecidos e escreve-se  $f_0(x | \theta_1, \theta_2, \dots, \theta_k)$   
Exemplos: Poisson com média desconhecida, binomial 5 e  $\theta$
- Assim, o nosso problema pode ser:  
Como testar  $H_0: X \sim f_0(x)$ ? ou como testar  $H_0: X \sim f_0(x | \theta_1, \theta_2, \dots, \theta_k)$ ?  
  
Uma possível solução → Teste do qui-quadrado à bondade do ajustamento.
- O problema vai ser analisado em 3 passos.

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

Exemplo: Um aspirador vendido em cinco cores:  $A_1, A_2, A_3, A_4$  e  $A_5$ .

• Notação:

○  $A_1, A_2, \dots, A_m \rightarrow$  modalidades (categorias) que o atributo pode assumir.

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

▪ A distribuição é caracterizada pelos  $m$  valores desconhecidos  $p_1, p_2, \dots, p_m$

▪ Claro que  $\sum_{j=1}^m p_j = 1$  e  $p_j > 0$  para  $j = 1, 2, \dots, m$ .

• Hipótese nula em teste:  $H_0 : p_j = p_{0j}$  ( $j = 1, 2, \dots, m$ ) contra  $H_1 : p_j \neq p_{0j}$ , para algum  $j$ , sendo  $p_{01}, \dots, p_{0m}$  conhecidos ( $p_{0j} > 0$  com  $j = 1, \dots, m$  e  $\sum_{j=1}^m p_{0j} = 1$ ).

- A estatística de teste:
  - Recolhe-se uma amostra casual  $(X_1, X_2, \dots, X_n)$  – cada valor de  $X$  é um inteiro entre 1 e  $m$  já que o fator  $X$  só assume  $m$  modalidades – e conta-se quantas vezes cada modalidade é observada, seja  $N_j, j = 1, 2, \dots, m$ .
  - $N_j \rightarrow$  v.a. que representa o número de observações (na amostra de dimensão  $n$ ) que assumem a modalidade  $A_j, \sum_{j=1}^m N_j = n$
  - Estatística de teste:

$$Q = \sum_{j=1}^m \frac{(N_j - np_{0j})^2}{np_{0j}}$$

A estatística de teste mede o **afastamento** (ponderado) **entre os dados observados** ( $N_j$ ) e **a hipótese em análise** ( $p_{0j}$ ) - se a modalidade  $j$  tem probabilidade  $p_{0j}$  de ser observada na população, então o número esperado de observações numa amostra de dimensão  $n$  será dado por  $n p_{0j}$ .

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

- O teste:

- (Teorema 9.1 do livro) Quando  $H_0$  é verdadeira a distribuição assintótica de  $Q$  é dada por

$$Q = \sum_{j=1}^m \frac{(N_j - np_{0j})^2}{np_{0j}} \stackrel{a}{\sim} \chi^2(m-1)$$

- A região de rejeição de dimensão  $\alpha$  é  $W_\alpha = \{q : q > q_\alpha\}$  onde  $q_\alpha : P(Q > q_\alpha) = \alpha$
- Verificar se  $Q_{obs} = \sum_{j=1}^m \frac{(n_j - np_{0j})^2}{np_{0j}}$  cai na região crítica
- Alternativamente pode recorrer-se ao cálculo do  $\text{valor-p} = P(Q \geq Q_{obs})$ .

- Observação importante: A distribuição de  $Q$  é válida quando  $n \rightarrow +\infty$ . Para que a aproximação no caso finito seja válida, deve-se garantir um valor mínimo para  $np_{0j}$ . Das várias regras existentes na literatura para fixa este mínimo, iremos utilizar  $np_{0j} \geq 5$  (**número esperado** de elementos em cada classe é pelo menos 5). Se necessário, agregam-se classes. Cuidado que o número mínimo diz respeito aos  $p_{0j}$  e à dimensão da amostra e não aos valores observados.

- **Exemplo** (9.1 do livro) - Um aspirador é vendido em cinco cores: verde ( $A_1$ ), castanho ( $A_2$ ), encarnado ( $A_3$ ), 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

$A_1$	$A_2$	$A_3$	$A_4$	$A_5$	Total
88	65	52	40	55	300

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

Solução:

1. Formalizar a hipótese nula  $H_0 : p_{01} = p_{02} = p_{03} = p_{04} = p_{05} = 0.2$ . e a alternativa  $H_1 : H_0 \text{ falsa}$
2. **Obter as frequências esperadas** e compará-las com as frequências observadas

Modalidades	Freq. Obs. ( $n_j$ )	Freq. esp. ( $np_{0j}$ )	$\frac{(n_j - np_{0j})^2}{np_{0j}}$
$A_1$	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
<b>Total</b>	300	300	21.65

3. Efetuar o teste

$\alpha = 0.05$ ;  $m - 1 = 4$  logo  $Q_{0.05} = 9.49$ . Como  $Q_{\text{obs}} = 21.65 > 9.49$  rejeita-se  $H_0$

Alternativamente: valor- $p = 0.00023$  (computador) logo rejeita-se  $H_0$

Em qualquer dos casos conclui-se que existe preferência por algumas cores em detrimento de outras.

**Exemplo** – O grau de satisfação dos clientes de determinada operadora de telecomunicações é avaliado na seguinte escala qualitativa:  $A_1$  (muito insatisfeito),  $A_2$  (insatisfeito),  $A_3$  (neutro, nem satisfeito nem insatisfeito),  $A_4$  (satisfeito) e  $A_5$  (muito satisfeito). A administração defende que a estrutura de probabilidades que traduz o grau de satisfação dos clientes é dada por  $p_{01} = 0.025$ ,  $p_{02} = 0.175$ ,  $p_{03} = 0.3$ ,  $p_{04} = 0.35$  e  $p_{05} = 0.15$ .

Recolhida uma amostra casual de 100 clientes, observou-se

$A_1$	$A_2$	$A_3$	$A_4$	$A_5$	Total
6	15	35	40	4	100

Teste ( $\alpha = 0.05$ ) a distribuição apresentada pela administração.



## Solução:

1. Formalizar as hipóteses

$H_0: p_{01} = 0.025, p_{02} = 0.175, p_{03} = 0.3, p_{04} = 0.35$  e  $p_{05} = 0.15$  contra  $H_1: H_0$  falsa

2. Obter as frequências esperadas e compará-las com as frequências observadas

Modalidades	$A_1$	$A_2$	$A_3$	$A_4$	$A_5$	Total
Freq. Obs ( $n_j$ )	6	15	35	40	4	100
Freq. Esp ( $np_{0j}$ )	2.5	17.5	30	35	15	100
$\frac{(n_j - np_{0j})^2}{np_{0j}}$						

De acordo com a regra referente ao número mínimo de **elementos esperados** em cada grupo teremos de agregar os 2 primeiros grupos (o mais parecido com “muito insatisfeito” será “insatisfeito”) e testar não a distribuição proposta mas uma distribuição “aparentada”.

Duas notas antes de reformular o teste:

- **O número mínimo é para a frequência esperada e não para a frequência observada.** Assim o grupo 5 não levanta qualquer problema ao contrário do grupo 1.
- Neste caso concreto (frequência esperada de 2.5) outras regras poderiam ter sido mais flexíveis e autorizar a continuação do teste.

3. Formalizemos então a hipótese “aparentada”:

$H'_0: p_{012} = 0.2, p_{03} = 0.3, p_{04} = 0.35$  e  $p_{05} = 0.15$  contra  $H'_1: H'_0$  falsa representando-se por  $p_{012}$  a probabilidade do grupo “muito insatisfeito ou insatisfeito” que se representará por  $A_{12}$

4. Obter as frequências esperadas e compará-las com as frequências observadas

Modalidades	Freq. Obs. ( $n_j$ )	Freq. esp. ( $np_{0j}$ )	$\frac{(n_j - np_{0j})^2}{np_{0j}}$
$A_{12}$	21	20	0.050
$A_3$	35	30	0.833
$A_4$	40	35	0.714
$A_5$	4	15	8.067
<b>Total</b>	100	100	<b>9.664</b>

5. Efetuar o teste

$\alpha = 0.05; m - 1 = 3$  logo  $Q_{0.05} = 7.815$  e como  $Q_{obs} = 9.664 > 7.815$  rejeita-se  $H'_0$ .

Alternativamente: valor- $p = 0.022$  (computador) logo rejeita-se  $H'_0$ .

Rejeita-se assim que a distribuição proposta pela administração seja adequada.

Quando se rejeita  $H'_0$ , não é problemático rejeitar  $H_0$  mas a inversa pode ser mais preocupante!

**2ª situação:**  $H_0$  é hipótese simples  $X \sim f_0(x)$  (não envolvendo qualquer parâmetro desconhecido)

**Ideia base** → Adaptar a situação ao caso anterior para aplicar a metodologia que se acabou de ver.

- Construir uma partição do domínio de  $X$  em  $m$  classes,  $A_1, A_2, \dots, A_m$ .
- Calcular os valores  $p_{0j} = P(A_j)$  ( $j = 1, \dots, m$ ). Para tal recorre-se a  $f_0(x)$ , isto é, assume-se  $H_0$  verdadeira.
  - 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: Seguem-se, tanto quanto possível os valores com probabilidade positiva (geralmente agregam-se na cauda direita).
- Substituir  $H_0 : X \sim f_0(x)$  por  $H'_0 : p_j = p_{0j}$  ( $j = 1, 2, \dots, m$ ) utilizar o procedimento anterior para testar  $H'_0$ .
- **Cuidado:** Testar  $H'_0$  em vez de  $H_0$  pode, por vezes, ser bastante delicado, sobretudo quando o número de classes,  $m$ , é pequeno. Rejeitar  $H'_0$  implica rejeitar  $H_0$  mas a inversa não é verdadeira.

**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	Freq. obs.
$X < 150$	543
$150 \leq X < 300$	258
$300 \leq X < 450$	120
$450 \leq X < 600$	48
$600 \leq X < 750$	20
$X \geq 750$	11
<b>Total</b>	<b>1000</b>

O fabricante afirma que o tempo de vida dos tubos,  $X$ , tem distribuição exponencial com média  $\mu = 200$ . Suportam os dados esta hipótese?

Solução:

1. Formalizar a hipótese nula inicial:

$$H_0 : X \sim f_0(x) = \frac{1}{200} \exp\left\{-\frac{x}{200}\right\} = 0.005 e^{-0.005x} \quad (x > 0)$$

2. Definir as classes: Já estão definidas

Uma distribuição exponencial com

**media  $\mu=200$**

tem parametro

**Lambda=1/ $\mu$ =1/200**

$$\lambda = 1/200 = 0.005$$

3. Calcular as respectivas probabilidades:

Recordar que  $F(x|\lambda) = 1 - e^{-\lambda x}$ ,  $x > 0$

$$p_{01} = P(X < 150) = F(150) = 1 - e^{-0.005 \times 150} = 1 - e^{-0.75} = 0.52763$$

$$p_{02} = P(150 \leq X < 300) = F(300) - F(150) = e^{-0.75} - e^{-1.5} = 0.24924$$

$$p_{03} = P(300 \leq X < 450) = F(450) - F(300) = e^{-1.5} - e^{-2.25} = 0.11773$$

$$p_{04} = P(450 \leq X < 600) = F(600) - F(450) = 0.05561$$

$$p_{05} = P(600 \leq X < 750) = F(750) - F(600) = 0.02627$$

$$p_{06} = P(X \geq 750) = 1 - F(750) = 1 - e^{-0.005 \times 750} = 0.02352$$

4. Construir a hipótese a testar:  $H'_0 : p_{01} = 0.52763; p_{02} = 0.24924; \dots; p_{06} = 0.02352$

5. Obter as frequências esperadas para as seis classes  $1000 \times p_{0j}$  (freq. esperadas  $\geq 5$ ) e compará-las com as frequências observadas

DADOS

Modelo (H0)

Tempo de vida	Freq. obs.	Freq. esp.
$X < 150$	543	527.63
$150 \leq X < 300$	258	249.20
$300 \leq X < 450$	120	117.73
$450 \leq X < 600$	48	55.61
$600 \leq X < 750$	20	26.27
$X \geq 750$	11	23.52
Total	1000	1000.00

6. Efetuar o teste:

$$Q_{\text{obs}} = \frac{(543 - 527.63)^2}{527.63} + \frac{(258 - 249.2)^2}{249.2} + \dots + \frac{(11 - 23.52)^2}{23.52} = 10.0004$$

$\alpha = 0.05$ ,  $m - 1 = 5$  logo  $Q_{0.05} = 11.1$  (ver tabela qui-quadrado com 5 g.l.) ou valor- $p=0.075$

Como  $Q_{\text{obs}} < 11.1$  não se rejeita  $H'_0$  e, então, pode-se admitir que não será de pôr em causa  $H_0$ .

O exemplo que acaba de apresentar-se permite sublinhar um aspeto importante.

- De facto, a hipótese testada não foi,  $H_0 : X \sim f_0(x) = 0.005e^{-0.005x} \ (x > 0)$ , mas sim a hipótese “aparentada”,  $H'_0$ , dada pelas condições seguintes:

$$p_{01} = P(X < 150) = \int_0^{150} 0.005e^{-0.005x} dx;$$

$$p_{02} = P(150 \leq X < 300) = \int_{150}^{300} 0.005e^{-0.005x} dx;$$

...

$$p_{06} = P(X \geq 750) = \int_{750}^{+\infty} 0.005e^{-0.005x} dx.$$

- Se se rejeita  $H'_0$  então não há dúvida de que também se deve rejeitar  $H_0$ . Já o mesmo não pode dizer-se quando não se rejeita  $H'_0$ , sobretudo se forem consideradas poucas classes.

**Exemplo** (9.4 do livro) – Determinada empresa seguradora baseia o seu sistema de prémios para determinado risco na premissa de que o número de sinistros por apólice tem distribuição de Poisson de parâmetro  $\lambda = 0.2$ . Recolhida uma amostra de 1000 apólices referentes ao ano anterior observou-se:

<b>Nº sinistros por apólice</b>	0	1	2	3
<b>Nº apólices</b>	800	175	21	4

A amostra põe em causa a premissa da seguradora?



## Solução

1. Formalizar a hipótese nula inicial:  $H_0: X \sim Po(0.2)$  contra  $H_1: H_0$  falsa
2. Calcular as probabilidades e ver quantas classes se podem definir:

Como a amostra tem dimensão 1000, a probabilidade mínima associada a cada classe é dada por  $1000 \times p \geq 5$  logo  $p \geq \frac{5}{1000} = 0.005$ .

$$\underline{P(X = 0) = 0.8187}; \quad \underline{P(X = 1) = 0.1637}; \quad \underline{P(X = 2) = 0.0164};$$

Propriedades da distribuição  
Poisson com parâmetro 0.2

Como  $P(X > 2) = 1 - P(X \leq 2) = 0.0011 < 0.005$  apenas se poderão considerar 3 classes,  $\{x = 0\}$ ,  $\{x = 1\}$ ,  $\{x \geq 2\}$

3. Construir a hipótese a testar:  $H'_0: p_{01} = 0.8187; p_{02} = 0.1637; p_{03} = 0.0175;$

$$\begin{aligned} P(X > 2) &= 1 - P(X \leq 2) \\ &= 1 - [P(X = 0) + P(X = 1) + P(X = 2)] \end{aligned}$$

4. Obter as frequências esperadas e compará-las com as frequências observadas

<b>Modalidades</b>	<b>Freq. Obs. (<math>n_j</math>)</b>	<b>Freq. esp. (<math>np_{0j}</math>)</b>	$\frac{(n_j - np_{0j})^2}{np_{0j}}$
{ $x = 0$ }	800	818.7	0.427
{ $x = 1$ }	175	163.7	0.780
{ $x \geq 2$ }	25	17.5	3.214
<b>Total</b>	1000	999.9	<b>4.421</b>

5. Efetuar o teste

$\alpha = 0.05$ ;  $m - 1 = 2$  logo  $Q_{0.05} = 5.991$  e como  $Q_{obs} = 4.421 < 5.991$  não se rejeita  $H_0$   
Alternativamente: valor- $p = 0.1096$  (computador) logo não se rejeita  $H_0$

A conclusão deve ser tirada com precaução já que se testou  $H'_0$  que considera apenas as probabilidades de 3 classes e não  $H_0$

**3ª situação:**  $H_0$  é uma hipótese composta,  $f_0(x)$  envolve parâmetros desconhecidos,

$$H_0: X \sim f_0(x | \theta_1, \theta_2, \dots, \theta_k).$$

- Admitir que  $H_0$  é verdadeira e estimar por **máxima verosimilhança** os parâmetros desconhecidos.
- Recorrer ao procedimento anterior, isto é definir as  $m$  classes e utilizar agora as probabilidades estimadas  $p_j(\hat{\theta}_1, \hat{\theta}_2, \dots, \hat{\theta}_k)$  ( $j = 1, 2, \dots, m$ )
- Definir a hipótese  $H'_0$  e proceder como anteriormente (nomeadamente garantindo que o número esperado de elementos por classe é superior a 5).
- Ao fazer o teste, a qui-quadrado tem agora  $m - 1 - k$  graus de liberdade, isto é desconta-se um grau por cada parâmetro estimado. Tem-se (teorema 9.2)

$$Q = \sum_{j=1}^m \frac{[N_j - np_j(\hat{\theta}_1, \hat{\theta}_2, \dots, \hat{\theta}_k)]^2}{np_j(\hat{\theta}_1, \hat{\theta}_2, \dots, \hat{\theta}_k)} \stackrel{a}{\sim} \chi^2(m - k - 1)$$

- Manter a restrição de um mínimo de 5 elementos esperados por cada classe.
- Ter presente, uma vez mais, que não se está a testar  $H_0$  mas sim  $H'_0$ .

**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:

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

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

Solução:

Formalizar o teste  $\rightarrow H_0: X \sim Po(\lambda)$  contra  $H_1: H_0$  falsa

Estimar o parâmetro por MV  $\rightarrow \hat{\lambda} = 1.75$

Recorda-se que o estimador de MV do parâmetro da Poisson é a média da amostra.

Logo a estimativa será dada pela média da amostra observada, isto é,

$$\hat{\lambda} = \frac{20 \times 0 + 30 \times 1 + 25 \times 2 + 10 \times 3 + 10 \times 4 + 5 \times 5}{100} = \frac{175}{100} = 1.75$$

Calcular as probabilidades e ver quantas classes se podem definir

<b><math>x</math></b>	0	1	2	3	4+
<b><math>P(X = x)</math></b>	0.1738	0.3041	0.2661	0.1552	0.1008

Já que  $P(X = 4) = 0.0679$  e  $P(X > 4) = 0.0329$

Definir a hipótese em teste:

$H'_0: p_{01} = 0.1738; p_{02} = 0.3041; p_{03} = 0.2661; p_{04} = 0.1552; p_{05} = 0.1008;$

Calcular o valor da estatística de teste

Classe	{0}	{1}	{2}	{3}	{4,5,...}	Total
Freq. observada	20	30	25	10	15	100
Freq. esperada	17.38	30.41	26.61	15.52	10.08	100
$\frac{(Obs - Esp)^2}{Esp}$	0.395	0.006	0.097	1.963	2.401	<b>4.862</b>

Efetuar o teste:

$\alpha = 0.05$ ;  $m = 5$ ;  $k = 1$  (estimou-se 1 parâmetro) logo  $m - k - 1 = 5 - 1 - 1 = 3$

Assim  $Q_{0.05} = 7.815$  e como  $Q_{obs} = 4.862 < 7.815$  não se rejeita  $H_0$

**alternativamente:** valor- $p = 0.182$  (computador) logo não se rejeita  $H_0$

Tal como no exemplo anterior, mas de forma menos gravosa já que temos um maior número de classes, a conclusão é para ser tomada com precaução. Ter também presente que  $n = 100$  não pode ser considerada uma “grande” amostra.

## TESTE DE INDEPENDÊNCIA

Problema: Testar se 2 variáveis aleatórias qualitativas são (ou não) independentes numa população. A ideia pode, por vezes, ser generalizada, embora com cautela, para variáveis quantitativas.

### TABELA DE CONTINGÊNCIA

Observa-se uma amostra à luz de 2 atributos: O primeiro reveste  $r$  modalidades -  $A_1, A_2, \dots, A_r$  - e o segundo  $s$  modalidades -  $B_1, B_2, \dots, B_s$ . Na célula  $(i, j)$  da tabela de contingência regista-se o número de elementos da amostra que verificam o nível  $i$  do atributo  $A$  e o nível  $j$  do atributo  $B$ .

**Tabela de contingência  $r \times s$  observada**

	$B_1$	$B_2$	...	$B_s$	<b>Totais</b>
$A_1$	$n_{11}$	$n_{12}$	...	$n_{1s}$	$n_{1o}$
$A_2$	$n_{21}$	$n_{22}$	...	$n_{2s}$	$n_{2o}$
...	...	...	...	...	...
$A_r$	$n_{r1}$	$n_{r2}$	...	$n_{rs}$	$n_{ro}$
<b>Totais</b>	$n_{o1}$	$n_{o2}$	...	$n_{os}$	<b><math>n</math></b>

$n_{ij}$  ( $i = 1, 2, \dots, r, j = 1, 2, \dots, s$ ) representa a frequência observada na célula definida por  $(A_i, B_j)$ .

$$n_{i\circ} = \sum_{j=1}^s n_{ij} \quad (i = 1, 2, \dots, r), \quad n_{\circ j} = \sum_{i=1}^r n_{ij} \quad (j = 1, 2, \dots, s) \text{ e, claro, } n = \sum_{i=1}^r n_{i\circ} = \sum_{j=1}^s n_{\circ j} .$$

Antes de observar a amostra tem-se

	$B_1$	$B_2$	...	$B_s$	<b>Totais</b>
$A_1$	$N_{11}$	$N_{12}$	...	$N_{1s}$	$N_{1\circ}$
$A_2$	$N_{21}$	$N_{22}$	...	$N_{2s}$	$N_{2\circ}$
...	...	...	...	...	...
$A_r$	$N_{r1}$	$N_{r2}$	...	$N_{rs}$	$N_{r\circ}$
<b>Totais</b>	$N_{\circ 1}$	$N_{\circ 2}$	...	$N_{\circ s}$	$n$

Note-se que:

- $n$  é não aleatório já que a dimensão da amostra é fixada.
- as frequências em cada classe são aleatórias: variáveis discretas que assumem os valores  $0, 1, \dots, n$ .
- $N_{i\circ}$  e  $N_{\circ j}$  continuam a ser os totais (aleatórios) em linha e coluna respetivamente.
- Existe uma restrição já que  $n = \sum_{j=1}^s N_{\circ j} = \sum_{i=1}^r N_{i\circ} = \sum_{i=1}^r \sum_{j=1}^s N_{ij}$ .

## Teste de independência do qui-quadrado

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

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

As respectivas probabilidades marginais são dadas por,

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

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

- Assumir a **independência entre os 2 atributos** equivale a assumir  $P(A_i, B_j) = P(A_i)P(B_j)$ , logo a hipótese em teste vai ser

$$H_0 : \forall (i, j) : p_{ij} = p_{i\circ} p_{\circ j} \quad \text{contra} \quad H_1 : \exists (i, j) : p_{ij} \neq p_{i\circ} p_{\circ j}.$$

- Assumindo  $H_0$ , pode-se estimar  $p_{ij}$  a partir de  $p_{i\circ}$  e de  $p_{\circ j}$ . Os estimadores de Máxima

Verosimilhança de  $p_{i\circ}$  e de  $p_{\circ j}$  são dados por  $\hat{p}_{i\circ} = \frac{N_{i\circ}}{n}$  ( $i = 1, 2, \dots, r$ );  $\hat{p}_{\circ j} = \frac{N_{\circ j}}{n}$  ( $j = 1, 2, \dots, s$ ).



- Retomando o teorema 9.2, a estatística de teste vai avaliar a diferença entre a frequência observada e a frequência esperada, assumindo  $H_0$  verdadeiro,

$$Q = \sum_{i=1}^r \sum_{j=1}^s \frac{(N_{ij} - n \hat{p}_{i\cdot} \hat{p}_{\cdot j})^2}{n \hat{p}_{i\cdot} \hat{p}_{\cdot j}} \stackrel{a}{\sim} \chi^2[(r-1)(s-1)].$$

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

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

A região de rejeição vai situar-se, pelas mesmas razões do que no teste do qui-quadrado à bondade do ajustamento na aba direita da distribuição, mantendo-se a restrição referente ao número mínimo esperado de elementos em cada célula  $(A_i, B_j)$ , isto é,  $n \hat{p}_{i\cdot} \hat{p}_{\cdot j} \geq 5$ .

**Exemplo** (9.9 do livro) – Barroso, Martins e Macedo (1987), em estudo comparativo da eficiência de empresas agrícolas, consideraram uma amostra de 69 explorações (Ribatejo e Oeste) que classificaram segundo dois atributos:

A – explorações de topo, explorações intermédias, explorações de cauda;

B – explorações vitícolas, explorações frutícolas

As modalidades do atributo A resultaram de uma classificação estabelecida em função de vários indicadores de produtividade e rendibilidade. A tabela de contingência consta do quadro que se segue:

	Vitícolas	Frutícolas	Totais
Topo	6	8	14
Intermédias	10	9	19
Cauda	14	22	36
Totais	30	39	<b>69</b>

O objetivo é testar se existe independência **na população** entre o sistema produtivo (atributo B) e a rendibilidade (atributo A).

Solução:

$$H_0 : p_{ij} = p_{i\cdot} p_{\cdot j} \quad (i = 1, 2, 3; j = 1, 2) \quad \text{vs} \quad H_1 : \exists_{(i,j)} : p_{ij} \neq p_{i\cdot} p_{\cdot j} \quad (i = 1, 2, 3; j = 1, 2).$$

Entre parêntesis apresentam-se as frequências esperadas, na hipótese de os atributos serem independentes. Por exemplo  $\frac{14 \times 30}{69} = 6.09$  ou  $\frac{36 \times 39}{69} = 20.35$ .

	Vitícolas	Frutícolas	Totais
Topo	6 (6.09)	8 (7.01)	14
Intermédias	10 (8.26)	9 (10.74)	19
Cauda	14 (15.65)	22 (20.35)	36
Totais	30	39	<b>69</b>

Calculado o valor particular da estatística-teste,

$$Q_{obs} = \frac{(6-6.09)^2}{6.09} + \frac{(8-7.01)^2}{7.01} + \dots + \frac{(22-20.35)^2}{20.35} = 0.9585,$$

2 graus de liberdade    valor- $p = P(Q > 0.9585) = 0.62$     Não se rejeita  $H_0$     logo ....

**Observação:** Ter presente que a dimensão da amostra é “modesta”

Assumindo independência ( $H_0$ )

$$\begin{aligned} \text{Prob(Topo \& Vitícolas)} \\ &= \text{Prob(Topo)} \times \text{Prob(Vitícolas)} \\ &= 14/69 \times 30/69 \end{aligned}$$

--> freq esperada = Probabilidade \* n

## Medidas de associação

- Quando se rejeita a independência pode haver interesse em avaliar a intensidade da associação entre os atributos.
- As medidas de associação mais conhecidas, baseadas na estatística  $Q$ , são:

a) **Coeficiente de contingência de Pearson**,  $C = \sqrt{\frac{Q}{Q+n}}$ ,

que verifica a dupla desigualdade,  $0 \leq C \leq \sqrt{(q-1)/q} < 1$ ,  $q = \min \{r, s\}$ .

b) **Coeficiente de Tschuprow**,  $T = \sqrt{\frac{Q}{n\sqrt{(r-1)(s-1)}}$ ,

em que o máximo é 1 apenas no caso em que  $r = s$ .

c) **Coeficiente de Cramér**,  $V = \sqrt{\frac{Q}{n(q-1)}}$ ,

que verifica  $0 \leq V \leq 1$ . Note-se que  $V \geq T$  ou mais precisamente  $V = T$  para  $r = s$  e  $V > T$  para  $r \neq s$ .

**Exemplo 9.10** – Tendo-se concluído que não se rejeitava a independência entre os atributos na população, não tem grande interesse calcular as medidas de associação. O exemplo serve apenas para ilustrar os cálculos a fazer.

$$n = 69; r = 3; s = 2; q = \min\{r, s\} = 2; Q_{obs} = 0.9585$$

Logo,

$$C = \sqrt{\frac{Q}{Q+n}} = \sqrt{\frac{0.9585}{0.9585+69}} = 0.117$$

$$T = \sqrt{\frac{Q}{n\sqrt{(r-1)(s-1)}}} = \sqrt{\frac{0.9585}{69 \times \sqrt{2 \times 1}}} = 0.099$$

$$V = \sqrt{\frac{Q}{n(q-1)}} = \sqrt{\frac{0.9585}{69 \times (2-1)}} = 0.118$$