

# Análise de Dados Categóricos

## Dados Pareados

Enrico A. Colosimo

Departamento de Estatística  
Universidade Federal de Minas Gerais

## Dados Pareados

Pareamento é frequentemente utilizado quando deseja-se evitar possíveis vícios nos resultados.

Observações pareadas são correlacionadas e, portanto, devem receber tratamento diferenciado.

Duas situações:

- 1 Mudança (antes e depois) ou pareamento, propriamente dito.
- 2 Concordância entre observadores.

## Caso 1: Exemplos

- Efeito de propaganda eleitoral (antes e depois) para um candidato A.
- Efeito de um filme educativo sobre aborto na opinião (antes e depois) das pessoas.
- Resposta dicotômica (diabete: sim e não) com pareamento por idade e sexo entre fumantes e não fumantes (análise mais complexa).

## Caso 1: Eleitores do candidato A

Efeito de propaganda eleitoral para o candidato A.

Duas pesquisas eleitorais foram realizadas em um período de um mês com os mesmos eleitores para avaliar o efeito da propaganda eleitoral para o candidato A.

Primeira Pesquisa	Segunda Pesquisa		Totais
	A	$\bar{A}$	
A	380	70	$n_{1+}$
$\bar{A}$	150	400	$n_{2+}$
Totais	$n_{+1}$	$n_{+2}$	1000

A proporção de eleitores do candidato A se alterou?

Primeira pesquisa:  $\hat{\pi}_{1+} = \frac{450}{1000}$

Segunda pesquisa:  $\hat{\pi}_{+1} = \frac{530}{1000}$

## Teste de McNemar

$$H_0 : \pi_{1+} = \pi_{+1}$$

$$H_1 : \pi_{1+} \neq \pi_{+1}$$

Sob  $H_0$ : As caselas discordantes devem ser iguais

$$X_M^2 = \frac{(n_{12} - \hat{E}_{12})^2}{\hat{E}_{12}} + \frac{(n_{21} - \hat{E}_{21})^2}{\hat{E}_{21}}, \text{ em que } \hat{E}_{12} = \hat{E}_{21} = \frac{n_{12} + n_{21}}{2}$$

$$X_M^2 = \frac{(n_{12} - \frac{n_{12}+n_{21}}{2})^2}{\frac{n_{12}+n_{21}}{2}} + \frac{(n_{21} - \frac{n_{12}+n_{21}}{2})^2}{\frac{n_{12}+n_{21}}{2}}$$

$$X_M^2 = \frac{(n_{12} - n_{21})^2}{n_{12} + n_{21}} \sim \chi_1^2 \quad (\text{sob } H_0)$$

## Exemplo

$$\begin{aligned}X_M^2 &= \frac{(150 - 70)^2}{150 + 70} \\ &= \frac{6400}{220} \\ &= 29,1\end{aligned}$$

$$\text{valor-p} = 6,9 \cdot 10^{-8}$$

## Teste McNemar

$$H_0 : \pi_{1+} = \pi_{+1} \quad \text{ou} \quad H_0 : R = \frac{\pi_{+1}}{\pi_{1+}} = 1$$

Antes	Depois		
	A	$\bar{A}$	
A	$n_{11}$	$n_{12}$	$n_{1+}$
$\bar{A}$	$n_{21}$	$n_{22}$	$n_{2+}$
	$n_{+1}$	$n_{+2}$	1000

$$\hat{V}\text{ar}(\log(\hat{R})) = \frac{(n_{12} + n_{21})}{(n_{12} + n_{11})(n_{21} + n_{11})}$$

## Intervalo 95% de confiança para $\frac{P_D}{P_A}$

$$\exp\{\log \hat{R} \pm 1,96 \cdot \sqrt{\widehat{\text{Var}}(\log(\hat{R}))}\}$$

Para os dados do exemplo:

$$\hat{R} = \frac{\frac{530}{1000}}{\frac{450}{1000}} = 1,18$$

$$\begin{aligned}\widehat{\text{Var}}(\log(\hat{R})) &= \frac{(70 + 150)}{(70 + 380)(150 + 380)} \\ &= \frac{220}{(450)(530)} = 0,0009 = 0,0304^2\end{aligned}$$

$$\begin{aligned}IC(95\%; \hat{R}) &= \exp\{\log 1,18 \pm 1,96 \cdot 0,0304\} \\ &= [1,11 \quad ; \quad 1,25]\end{aligned}$$

A propaganda para o Candidato A aumentou o percentual de eleitores em 18% com um intervalo de 95% de confiança entre 11 e 25%.



## Caso 2: Kappa - Concordância entre observadores

Na presença de erro de medida, observadores analisando o mesmo exame podem obter classificações diferentes.

Exemplo: Dois patologistas analisam biópsias de 149 mulheres com o objetivo de classificá-las com relação a existência ou não de um determinado tipo de câncer.

Patologista 2	Patologista 1		
	-	+	
-	71	6	77
+	13	59	72
	84	65	149

Qual é a força de concordância entre os patologistas?

## Soluções Extremas

- Caso 01 - Perfeita

		Patologista 1	
		-	+
Patologista 2	-		0
	+	0	

- Caso 02 - Nula

		Patologista 1	
		-	+
Patologista 2	-	$\frac{n}{4}$	$\frac{n}{4}$
	+	$\frac{n}{4}$	$\frac{n}{4}$
			n

## Kappa (Colen(1960)): Coeficiente de Concordância $k$

$$k = \frac{\pi_0 - \pi_e}{1 - \pi_e}, \text{ em que } \pi_0 = \sum_{i=1}^2 \pi_{ii} \text{ e } \pi_e = \sum_{i=1}^2 \pi_{i+} \pi_{+i}.$$

em que,  $\hat{\pi}_{ij} = n_{ij}/n$  e  $\hat{\pi}_{i+} = n_{i+}/n$ .

O Kappa varia de 0 (tabela nula) a 1 (tabela perfeita).

Para o exemplo dos patologistas:

$$\begin{aligned} \hat{k} &= \frac{\frac{71+59}{149} - \frac{(77 \cdot 84) + (72 \cdot 65)}{149^2}}{1 - \frac{(77 \cdot 84) + (72 \cdot 65)}{149^2}} \\ &= 0,74 \end{aligned}$$

## Variância Assintótica e Intervalo de Confiança para $k$

$$\widehat{\text{Var}}(\hat{k}) = \frac{A + B - C}{n(1 - \hat{\pi}_e)^2}$$

$$A = \sum_{i=1}^2 \hat{\pi}_{ii} [1 - (\hat{\pi}_{i+} + \hat{\pi}_{+i})(1 - \hat{k})]^2$$

$$B = (1 - \hat{k})^2 \sum_{i \neq j} \hat{\pi}_{ij} (\hat{\pi}_{i+} + \hat{\pi}_{+j})^2$$

$$C = [\hat{k} - \hat{\pi}_e(1 - \hat{k})]^2$$

$$IC(95\%, k) = \{\hat{k} \pm 1,96 \cdot \sqrt{\widehat{\text{Var}}(\hat{k})}\}$$

## Variância Assintótica e Intervalo de Confiança para $k$

No exemplo dos patologistas:

$$A = 0,4756$$

$$B = 0,0089$$

$$C = 0,3714$$

$$\hat{Var}(\hat{k}) = 0,00306$$

E o respectivo Intervalo de 95% de Confiança :

$$\begin{aligned} IC(95\%, \hat{k}) &= \{\hat{k} \pm 1,96 \cdot \sqrt{0,0030}\} \\ &= [0,64 \quad ; \quad 0,85] \end{aligned}$$

A concordância entre os patologistas é 74% com um intervalo de 95% de confiança entre (63; 85%).

O pacote vcd do R calcula o Kappa e seu respectivo IC.

- `print(K, CI = TRUE)`
- value ASE z  $\Pr(> |z|)$  lower upper
- 0.7439 0.05463 13.62 3.232e-42 0.6368 0.8509