



## SME0803 Visualização e Exploração de Dados

### **Associação entre variáveis qualitativas**

Prof. Cibele Russo

cibele@icmc.usp.br

Baseado em

Murteira, B. J. F., Análise Exploratória de Dados. McGraw-Hill, Lisboa, 1993.

Notas de aula de Análise Exploratória de Dados do Mário de Castro, ICMC-USP, 2010.

# Tabelas de contingência (frequências absolutas)

Sejam  $x \in x_1, \dots, x_k$  e  $y \in y_1, \dots, y_m$ ,  $1 < k \leq n$  e  $1 < m \leq n$ .

Seja  $f_{ij}$  a **frequência absoluta** do par  $(x_i, y_j)$ ,  $i = 1, \dots, k$ ,  $j = 1, \dots, m$ .

# Tabelas de contingência (frequências absolutas)

Sejam  $x \in x_1, \dots, x_k$  e  $y \in y_1, \dots, y_m$ ,  $1 < k \leq n$  e  $1 < m \leq n$ .

Seja  $f_{ij}$  a **frequência absoluta** do par  $(x_i, y_j)$ ,  $i = 1, \dots, k$ ,  $j = 1, \dots, m$ .

**Tabela de contingência** (*contingency table*) ou **tabela de dupla entrada**: tabela com os diferentes pares  $(x_i, y_j)$  e suas frequências  $f_{ij}$ .

## Distribuição conjunta de frequências absolutas $x$ e $y$ .

$x \backslash y$	$y_1$	...	$y_j$	...	$y_m$	Total
$x_1$	$f_{11}$	...	$f_{1j}$	...	$f_{1m}$	$f_{1\bullet}$
$\vdots$	$\vdots$	...	$\vdots$	...	$\vdots$	$\vdots$
$x_i$	$f_{i1}$	...	$f_{ij}$	...	$f_{im}$	$f_{i\bullet}$
$\vdots$	$\vdots$	...	$\vdots$	...	$\vdots$	$\vdots$
$x_k$	$f_{k1}$	...	$f_{kj}$	...	$f_{km}$	$f_{k\bullet}$
Total	$f_{\bullet 1}$	...	$f_{\bullet j}$	...	$f_{\bullet m}$	n

## Distribuição conjunta de frequências absolutas $x$ e $y$ .

$x \backslash y$	$y_1$	$\dots$	$y_j$	$\dots$	$y_m$	Total
$x_1$	$f_{11}$	$\dots$	$f_{1j}$	$\dots$	$f_{1m}$	$f_{1\bullet}$
$\vdots$	$\vdots$	$\dots$	$\vdots$	$\dots$	$\vdots$	$\vdots$
$x_i$	$f_{i1}$	$\dots$	$f_{ij}$	$\dots$	$f_{im}$	$f_{i\bullet}$
$\vdots$	$\vdots$	$\dots$	$\vdots$	$\dots$	$\vdots$	$\vdots$
$x_k$	$f_{k1}$	$\dots$	$f_{kj}$	$\dots$	$f_{km}$	$f_{k\bullet}$
Total	$f_{\bullet 1}$	$\dots$	$f_{\bullet j}$	$\dots$	$f_{\bullet m}$	n

em que  $f_{i\bullet} = \sum_{j=1}^m f_{ij}$  para  $i = 1, \dots, k$

## Distribuição conjunta de frequências absolutas $x$ e $y$ .

$x \backslash y$	$y_1$	$\dots$	$y_j$	$\dots$	$y_m$	Total
$x_1$	$f_{11}$	$\dots$	$f_{1j}$	$\dots$	$f_{1m}$	$f_{1\bullet}$
$\vdots$	$\vdots$	$\dots$	$\vdots$	$\dots$	$\vdots$	$\vdots$
$x_i$	$f_{i1}$	$\dots$	$f_{ij}$	$\dots$	$f_{im}$	$f_{i\bullet}$
$\vdots$	$\vdots$	$\dots$	$\vdots$	$\dots$	$\vdots$	$\vdots$
$x_k$	$f_{k1}$	$\dots$	$f_{kj}$	$\dots$	$f_{km}$	$f_{k\bullet}$
Total	$f_{\bullet 1}$	$\dots$	$f_{\bullet j}$	$\dots$	$f_{\bullet m}$	n

em que  $f_{i\bullet} = \sum_{j=1}^m f_{ij}$  para  $i = 1, \dots, k$  e  $\sum_{i=1}^k f_{i\bullet} = n$ ,

## Distribuição conjunta de frequências absolutas $x$ e $y$ .

$x \backslash y$	$y_1$	$\dots$	$y_j$	$\dots$	$y_m$	Total
$x_1$	$f_{11}$	$\dots$	$f_{1j}$	$\dots$	$f_{1m}$	$f_{1\bullet}$
$\vdots$	$\vdots$	$\dots$	$\vdots$	$\dots$	$\vdots$	$\vdots$
$x_i$	$f_{i1}$	$\dots$	$f_{ij}$	$\dots$	$f_{im}$	$f_{i\bullet}$
$\vdots$	$\vdots$	$\dots$	$\vdots$	$\dots$	$\vdots$	$\vdots$
$x_k$	$f_{k1}$	$\dots$	$f_{kj}$	$\dots$	$f_{km}$	$f_{k\bullet}$
Total	$f_{\bullet 1}$	$\dots$	$f_{\bullet j}$	$\dots$	$f_{\bullet m}$	n

em que  $f_{i\bullet} = \sum_{j=1}^m f_{ij}$  para  $i = 1, \dots, k$  e  $\sum_{i=1}^k f_{i\bullet} = n$ ,

$$f_{\bullet j} = \sum_{i=1}^k f_{ij} \text{ para } j = 1, \dots, m$$

## Distribuição conjunta de frequências absolutas $x$ e $y$ .

$x \backslash y$	$y_1$	$\dots$	$y_j$	$\dots$	$y_m$	Total
$x_1$	$f_{11}$	$\dots$	$f_{1j}$	$\dots$	$f_{1m}$	$f_{1\bullet}$
$\vdots$	$\vdots$	$\dots$	$\vdots$	$\dots$	$\vdots$	$\vdots$
$x_i$	$f_{i1}$	$\dots$	$f_{ij}$	$\dots$	$f_{im}$	$f_{i\bullet}$
$\vdots$	$\vdots$	$\dots$	$\vdots$	$\dots$	$\vdots$	$\vdots$
$x_k$	$f_{k1}$	$\dots$	$f_{kj}$	$\dots$	$f_{km}$	$f_{k\bullet}$
Total	$f_{\bullet 1}$	$\dots$	$f_{\bullet j}$	$\dots$	$f_{\bullet m}$	n

em que  $f_{i\bullet} = \sum_{j=1}^m f_{ij}$  para  $i = 1, \dots, k$  e  $\sum_{i=1}^k f_{i\bullet} = n$ ,

$f_{\bullet j} = \sum_{i=1}^k f_{ij}$  para  $j = 1, \dots, m$  e  $\sum_{j=1}^m f_{\bullet j} = n$

## Distribuição conjunta de frequências absolutas $x$ e $y$ .

$x \backslash y$	$y_1$	$\dots$	$y_j$	$\dots$	$y_m$	Total
$x_1$	$f_{11}$	$\dots$	$f_{1j}$	$\dots$	$f_{1m}$	$f_{1\bullet}$
$\vdots$	$\vdots$	$\dots$	$\vdots$	$\dots$	$\vdots$	$\vdots$
$x_i$	$f_{i1}$	$\dots$	$f_{ij}$	$\dots$	$f_{im}$	$f_{i\bullet}$
$\vdots$	$\vdots$	$\dots$	$\vdots$	$\dots$	$\vdots$	$\vdots$
$x_k$	$f_{k1}$	$\dots$	$f_{kj}$	$\dots$	$f_{km}$	$f_{k\bullet}$
Total	$f_{\bullet 1}$	$\dots$	$f_{\bullet j}$	$\dots$	$f_{\bullet m}$	n

em que  $f_{i\bullet} = \sum_{j=1}^m f_{ij}$  para  $i = 1, \dots, k$  e  $\sum_{i=1}^k f_{i\bullet} = n$ ,

$f_{\bullet j} = \sum_{i=1}^k f_{ij}$  para  $j = 1, \dots, m$  e  $\sum_{j=1}^m f_{\bullet j} = n$  e  $\sum_{i=1}^k \sum_{j=1}^m f_{ij} = n$ .

# Tabelas de contingência (frequências absolutas)

Distribuição marginal de  $x$  (em destaque)

$x$	$y$	$y_1$	$\dots$	$y_j$	$\dots$	$y_m$	Total
$x_1$		$f_{11}$	$\dots$	$f_{1j}$	$\dots$	$f_{1m}$	$f_{1\bullet}$
$\vdots$		$\vdots$	$\dots$	$\vdots$	$\dots$	$\vdots$	$\vdots$
$x_i$		$f_{i1}$	$\dots$	$f_{ij}$	$\dots$	$f_{im}$	$f_{i\bullet}$
$\vdots$		$\vdots$	$\dots$	$\vdots$	$\dots$	$\vdots$	$\vdots$
$x_k$		$f_{k1}$	$\dots$	$f_{kj}$	$\dots$	$f_{km}$	$f_{k\bullet}$
Total		$f_{\bullet 1}$	$\dots$	$f_{\bullet j}$	$\dots$	$f_{\bullet m}$	n

# Tabelas de contingência (frequências absolutas)

Distribuição marginal de  $y$  (em destaque)

$x \backslash y$	$y_1$	$\dots$	$y_j$	$\dots$	$y_m$	Total
$x_1$	$f_{11}$	$\dots$	$f_{1j}$	$\dots$	$f_{1m}$	$f_{1\bullet}$
$\vdots$	$\vdots$	$\dots$	$\vdots$	$\dots$	$\vdots$	$\vdots$
$x_i$	$f_{i1}$	$\dots$	$f_{ij}$	$\dots$	$f_{im}$	$f_{i\bullet}$
$\vdots$	$\vdots$	$\dots$	$\vdots$	$\dots$	$\vdots$	$\vdots$
$x_k$	$f_{k1}$	$\dots$	$f_{kj}$	$\dots$	$f_{km}$	$f_{k\bullet}$
Total	$f_{\bullet 1}$	$\dots$	$f_{\bullet j}$	$\dots$	$f_{\bullet m}$	n

## Tabelas de contingência (frequências relativas)

Seja  $f_{ij}^*$  a **frequência relativa** do par  $(x_i, y_j)$ ,  $i = 1, \dots, k, j = 1, \dots, m$ .

# Tabelas de contingência (frequências relativas)

Seja  $f_{ij}^*$  a **frequência relativa** do par  $(x_i, y_j)$ ,  $i = 1, \dots, k$ ,  $j = 1, \dots, m$ .

**Distribuição conjunta de frequências relativas** (*contingency table*) ou **tabela de dupla entrada de frequências relativas**: tabela com os diferentes pares  $(x_i, y_j)$  e suas frequências relativas  $f_{ij}^*$ .

Distribuição conjunta de frequências relativas de  $x$  e  $y$ .

$x \backslash y$	$y_1$	$\dots$	$y_j$	$\dots$	$y_m$	Total
$x_1$	$f_{11}^*$	$\dots$	$f_{1j}^*$	$\dots$	$f_{1m}^*$	$f_{1\bullet}^*$
$\vdots$	$\vdots$	$\dots$	$\vdots$	$\dots$	$\vdots$	$\vdots$
$x_i$	$f_{i1}^*$	$\dots$	$f_{ij}^*$	$\dots$	$f_{im}^*$	$f_{i\bullet}^*$
$\vdots$	$\vdots$	$\dots$	$\vdots$	$\dots$	$\vdots$	$\vdots$
$x_k$	$f_{k1}^*$	$\dots$	$f_{kj}^*$	$\dots$	$f_{km}^*$	$f_{k\bullet}^*$
Total	$f_{\bullet 1}^*$	$\dots$	$f_{\bullet j}^*$	$\dots$	$f_{\bullet m}^*$	1

Distribuição conjunta de frequências relativas de  $x$  e  $y$ .

$x \backslash y$	$y_1$	$\dots$	$y_j$	$\dots$	$y_m$	Total
$x_1$	$f_{11}^*$	$\dots$	$f_{1j}^*$	$\dots$	$f_{1m}^*$	$f_{1\bullet}^*$
$\vdots$	$\vdots$	$\dots$	$\vdots$	$\dots$	$\vdots$	$\vdots$
$x_i$	$f_{i1}^*$	$\dots$	$f_{ij}^*$	$\dots$	$f_{im}^*$	$f_{i\bullet}^*$
$\vdots$	$\vdots$	$\dots$	$\vdots$	$\dots$	$\vdots$	$\vdots$
$x_k$	$f_{k1}^*$	$\dots$	$f_{kj}^*$	$\dots$	$f_{km}^*$	$f_{k\bullet}^*$
Total	$f_{\bullet 1}^*$	$\dots$	$f_{\bullet j}^*$	$\dots$	$f_{\bullet m}^*$	1

em que  $f_{i\bullet}^* = \sum_{j=1}^m f_{ij}^*$  para  $i = 1, \dots, k$

Distribuição conjunta de frequências relativas de  $x$  e  $y$ .

$x \backslash y$	$y_1$	$\dots$	$y_j$	$\dots$	$y_m$	Total
$x_1$	$f_{11}^*$	$\dots$	$f_{1j}^*$	$\dots$	$f_{1m}^*$	$f_{1\bullet}^*$
$\vdots$	$\vdots$	$\dots$	$\vdots$	$\dots$	$\vdots$	$\vdots$
$x_i$	$f_{i1}^*$	$\dots$	$f_{ij}^*$	$\dots$	$f_{im}^*$	$f_{i\bullet}^*$
$\vdots$	$\vdots$	$\dots$	$\vdots$	$\dots$	$\vdots$	$\vdots$
$x_k$	$f_{k1}^*$	$\dots$	$f_{kj}^*$	$\dots$	$f_{km}^*$	$f_{k\bullet}^*$
Total	$f_{\bullet 1}^*$	$\dots$	$f_{\bullet j}^*$	$\dots$	$f_{\bullet m}^*$	1

em que  $f_{i\bullet}^* = \sum_{j=1}^m f_{ij}^*$  para  $i = 1, \dots, k$  e  $\sum_{i=1}^k f_{i\bullet}^* = 1$ ,

Distribuição conjunta de frequências relativas de  $x$  e  $y$ .

$x \backslash y$	$y_1$	$\dots$	$y_j$	$\dots$	$y_m$	Total
$x_1$	$f_{11}^*$	$\dots$	$f_{1j}^*$	$\dots$	$f_{1m}^*$	$f_{1\bullet}^*$
$\vdots$	$\vdots$	$\dots$	$\vdots$	$\dots$	$\vdots$	$\vdots$
$x_i$	$f_{i1}^*$	$\dots$	$f_{ij}^*$	$\dots$	$f_{im}^*$	$f_{i\bullet}^*$
$\vdots$	$\vdots$	$\dots$	$\vdots$	$\dots$	$\vdots$	$\vdots$
$x_k$	$f_{k1}^*$	$\dots$	$f_{kj}^*$	$\dots$	$f_{km}^*$	$f_{k\bullet}^*$
Total	$f_{\bullet 1}^*$	$\dots$	$f_{\bullet j}^*$	$\dots$	$f_{\bullet m}^*$	1

em que  $f_{i\bullet}^* = \sum_{j=1}^m f_{ij}^*$  para  $i = 1, \dots, k$  e  $\sum_{i=1}^k f_{i\bullet}^* = 1$ ,

$f_{\bullet j}^* = \sum_{i=1}^k f_{ij}^*$  para  $j = 1, \dots, m$

Distribuição conjunta de frequências relativas de  $x$  e  $y$ .

$x \backslash y$	$y_1$	$\dots$	$y_j$	$\dots$	$y_m$	Total
$x_1$	$f_{11}^*$	$\dots$	$f_{1j}^*$	$\dots$	$f_{1m}^*$	$f_{1\bullet}^*$
$\vdots$	$\vdots$	$\dots$	$\vdots$	$\dots$	$\vdots$	$\vdots$
$x_i$	$f_{i1}^*$	$\dots$	$f_{ij}^*$	$\dots$	$f_{im}^*$	$f_{i\bullet}^*$
$\vdots$	$\vdots$	$\dots$	$\vdots$	$\dots$	$\vdots$	$\vdots$
$x_k$	$f_{k1}^*$	$\dots$	$f_{kj}^*$	$\dots$	$f_{km}^*$	$f_{k\bullet}^*$
Total	$f_{\bullet 1}^*$	$\dots$	$f_{\bullet j}^*$	$\dots$	$f_{\bullet m}^*$	1

em que  $f_{i\bullet}^* = \sum_{j=1}^m f_{ij}^*$  para  $i = 1, \dots, k$  e  $\sum_{i=1}^k f_{i\bullet}^* = 1$ ,

$f_{\bullet j}^* = \sum_{i=1}^k f_{ij}^*$  para  $j = 1, \dots, m$  e  $\sum_{j=1}^m f_{\bullet j}^* = 1$

Distribuição conjunta de frequências relativas de  $x$  e  $y$ .

$x \backslash y$	$y_1$	$\dots$	$y_j$	$\dots$	$y_m$	Total
$x_1$	$f_{11}^*$	$\dots$	$f_{1j}^*$	$\dots$	$f_{1m}^*$	$f_{1\bullet}^*$
$\vdots$	$\vdots$	$\dots$	$\vdots$	$\dots$	$\vdots$	$\vdots$
$x_i$	$f_{i1}^*$	$\dots$	$f_{ij}^*$	$\dots$	$f_{im}^*$	$f_{i\bullet}^*$
$\vdots$	$\vdots$	$\dots$	$\vdots$	$\dots$	$\vdots$	$\vdots$
$x_k$	$f_{k1}^*$	$\dots$	$f_{kj}^*$	$\dots$	$f_{km}^*$	$f_{k\bullet}^*$
Total	$f_{\bullet 1}^*$	$\dots$	$f_{\bullet j}^*$	$\dots$	$f_{\bullet m}^*$	1

em que  $f_{i\bullet}^* = \sum_{j=1}^m f_{ij}^*$  para  $i = 1, \dots, k$  e  $\sum_{i=1}^k f_{i\bullet}^* = 1$ ,

$f_{\bullet j}^* = \sum_{i=1}^k f_{ij}^*$  para  $j = 1, \dots, m$  e  $\sum_{j=1}^m f_{\bullet j}^* = 1$  e  $\sum_{i=1}^k \sum_{j=1}^m f_{ij}^* = 1$ .

Distribuição conjunta de frequências relativas de  $x$  e  $y$ .

	$y$	$y_1$	$\dots$	$y_j$	$\dots$	$y_m$	Total
$x$							
$x_1$		$f_{11}/n$	$\dots$	$f_{1j}/n$	$\dots$	$f_{1m}/n$	$f_{1\bullet}/n$
$\vdots$		$\vdots$	$\dots$	$\vdots$	$\dots$	$\vdots$	$\vdots$
$x_i$		$f_{i1}/n$	$\dots$	$f_{ij}/n$	$\dots$	$f_{im}/n$	$f_{i\bullet}/n$
$\vdots$		$\vdots$	$\dots$	$\vdots$	$\dots$	$\vdots$	$\vdots$
$x_k$		$f_{k1}/n$	$\dots$	$f_{kj}/n$	$\dots$	$f_{km}/n$	$f_{k\bullet}/n$
Total		$f_{\bullet 1}/n$	$\dots$	$f_{\bullet j}/n$	$\dots$	$f_{\bullet m}/n$	1

Distribuição conjunta de frequências relativas de  $x$  e  $y$ .

	$y$	$y_1$	$\dots$	$y_j$	$\dots$	$y_m$	Total
$x$							
$x_1$		$f_{11}/n$	$\dots$	$f_{1j}/n$	$\dots$	$f_{1m}/n$	$f_{1\bullet}/n$
$\vdots$		$\vdots$	$\dots$	$\vdots$	$\dots$	$\vdots$	$\vdots$
$x_i$		$f_{i1}/n$	$\dots$	$f_{ij}/n$	$\dots$	$f_{im}/n$	$f_{i\bullet}/n$
$\vdots$		$\vdots$	$\dots$	$\vdots$	$\dots$	$\vdots$	$\vdots$
$x_k$		$f_{k1}/n$	$\dots$	$f_{kj}/n$	$\dots$	$f_{km}/n$	$f_{k\bullet}/n$
Total		$f_{\bullet 1}/n$	$\dots$	$f_{\bullet j}/n$	$\dots$	$f_{\bullet m}/n$	1

# Tabelas de contingência (frequências relativas)

Distribuição marginal de  $x$  (em destaque)

$x$	$y$	$y_1$	$\dots$	$y_j$	$\dots$	$y_m$	Total
$x_1$		$f_{11}/n$	$\dots$	$f_{1j}/n$	$\dots$	$f_{1m}/n$	$f_{1\bullet}/n$
$\vdots$		$\vdots$	$\dots$	$\vdots$	$\dots$	$\vdots$	$\vdots$
$x_i$		$f_{i1}/n$	$\dots$	$f_{ij}/n$	$\dots$	$f_{im}/n$	$f_{i\bullet}/n$
$\vdots$		$\vdots$	$\dots$	$\vdots$	$\dots$	$\vdots$	$\vdots$
$x_k$		$f_{k1}/n$	$\dots$	$f_{kj}/n$	$\dots$	$f_{km}/n$	$f_{k\bullet}/n$
Total		$f_{\bullet 1}/n$	$\dots$	$f_{\bullet j}/n$	$\dots$	$f_{\bullet m}/n$	1

# Tabelas de contingência (frequências relativas)

Distribuição marginal de  $y$  (em destaque)

x \ y	$y_1$	...	$y_j$	...	$y_m$	Total
$x_1$	$f_{11}/n$	...	$f_{1j}/n$	...	$f_{1m}/n$	$f_{1\bullet}/n$
$\vdots$	$\vdots$	...	$\vdots$	...	$\vdots$	$\vdots$
$x_i$	$f_{i1}/n$	...	$f_{ij}/n$	...	$f_{im}/n$	$f_{i\bullet}/n$
$\vdots$	$\vdots$	...	$\vdots$	...	$\vdots$	$\vdots$
$x_k$	$f_{k1}/n$	...	$f_{kj}/n$	...	$f_{km}/n$	$f_{k\bullet}/n$
Total	$f_{\bullet 1}/n$	...	$f_{\bullet j}/n$	...	$f_{\bullet m}/n$	1

# Tabelas de contingência (frequências relativas)

Distribuição **condicional** de  $y$  dado  $x = x_i$  (em destaque)

$x \backslash y$	$y_1$	$\dots$	$y_j$	$\dots$	$y_m$	Total
$x_1$	$f_{11}/f_{1\bullet}$	$\dots$	$f_{1j}/f_{1\bullet}$	$\dots$	$f_{1m}/f_{1\bullet}$	1
$\vdots$	$\vdots$	$\dots$	$\vdots$	$\dots$	$\vdots$	$\vdots$
$x_i$	$f_{i1}/f_{i\bullet}$	$\dots$	$f_{ij}/f_{i\bullet}$	$\dots$	$f_{im}/f_{i\bullet}$	1
$\vdots$	$\vdots$	$\dots$	$\vdots$	$\dots$	$\vdots$	$\vdots$
$x_k$	$f_{k1}/f_{k\bullet}$	$\dots$	$f_{kj}/f_{k\bullet}$	$\dots$	$f_{km}/f_{k\bullet}$	1

# Tabelas de contingência (frequências relativas)

Distribuição **condicional** de  $x$  dado  $y = y_j$  (em destaque)

$x$	$y_1$	$\dots$	$y_j$	$\dots$	$y_m$
$x_1$	$f_{11}/f_{\bullet 1}$	$\dots$	$f_{1j}/f_{\bullet j}$	$\dots$	$f_{1m}/f_{\bullet m}$
$\vdots$	$\vdots$	$\dots$	$\vdots$	$\dots$	$\vdots$
$x_i$	$f_{i1}/f_{\bullet 1}$	$\dots$	$f_{ij}/f_{\bullet j}$	$\dots$	$f_{im}/f_{\bullet m}$
$\vdots$	$\vdots$	$\dots$	$\vdots$	$\dots$	$\vdots$
$x_k$	$f_{k1}/f_{\bullet 1}$	$\dots$	$f_{kj}/f_{\bullet j}$	$\dots$	$f_{km}/f_{\bullet m}$
Total	1	$\dots$	1	$\dots$	1

# Associação entre variáveis qualitativas

As tabelas de distribuição condicional também são tabelas de frequências relativas. Qual usar?

- (a) Relação causal bilateral ( $x \leftrightarrow y$ ): Tabela de frequências relativas (dividido por  $n$ ).

# Associação entre variáveis qualitativas

As tabelas de distribuição condicional também são tabelas de frequências relativas. Qual usar?

- (a) Relação causal bilateral ( $x \leftrightarrow y$ ): Tabela de frequências relativas (dividido por  $n$ ).
- (b) Relação causal unilateral ( $x \rightarrow y$ ): Distribuição condicional de  $y$  dado  $x$ .

# Associação entre variáveis qualitativas

As tabelas de distribuição condicional também são tabelas de frequências relativas. Qual usar?

- (a) Relação causal bilateral ( $x \leftrightarrow y$ ): Tabela de frequências relativas (dividido por  $n$ ).
- (b) Relação causal unilateral ( $x \rightarrow y$ ): Distribuição condicional de  $y$  dado  $x$ .
- (b) Relação causal unilateral ( $y \rightarrow x$ ) Distribuição condicional de  $x$  dado  $y$ .

# Associação entre variáveis qualitativas

Obs 1: Em (b) temos  $k$  distribuições condicionais de  $y$ . Quanto mais semelhantes forem estas distribuições, mais fraca é a associação entre  $x$  e  $y$ .

# Associação entre variáveis qualitativas

Obs 1: Em (b) temos  $k$  distribuições condicionais de  $y$ . Quanto mais semelhantes forem estas distribuições, mais fraca é a associação entre  $x$  e  $y$ .

Obs 2: Em (c) é usual trocar os nomes, de modo que  $x$  ocupe as linhas e  $y$  ocupe as colunas da tabela de contingências.

# Adaptação do conceito de independência

Para avaliar a associação entre duas variáveis qualitativas, precisamos entender a ideia de independência.

$x$  e  $y$  são independentes se, e somente se,

$$f_{ij} = \frac{f_{i\bullet} f_{\bullet j}}{n}, j = 1, \dots, m \text{ e } i = 1, \dots, k.$$

De forma equivalente,

$$\frac{f_{ij}}{n} = \frac{f_{i\bullet}}{n} \frac{f_{\bullet j}}{n}, j = 1, \dots, m \text{ e } i = 1, \dots, k.$$

Obs: Adaptação do conceito de independência entre as variáveis aleatórias discretas  $X$  e  $Y$ :  $P(X = a, Y = b) = P(X = a)P(Y = b)$ .

## Exemplo

Considere novamente os dados da CompanhiaMB, especificamente as variáveis grau de instrução e estado civil. Como avaliar se existe associação entre elas? Considere a tabela de contingência.

		estado civil	
		casado	solteiro
grau de instrução	ensino_fundamental	5	7
	ensino_medio	12	6
	superior	3	3

## Exemplo

Como seria essa tabela sob independência? Primeiro obtemos os totais por linhas e colunas:

grau de instrução \ estado civil			Total
	casado	solteiro	
ensino_fundamental	5	7	12
ensino_medio	12	6	18
superior	3	3	6
Total	20	16	36

## Exemplo

E então fazemos  $f_{ij}^{ind} = \frac{f_{i\bullet} f_{\bullet j}}{n}$ ,  $j = 1, \dots, m$  e  $i = 1, \dots, k$ .

grau de instrução \ estado civil			Total
	casado	solteiro	
ensino_fundamental	6,7	5,3	12
ensino_medio	10	8	18
superior	3,3	2,7	6
Total	20	16	36

## Medidas de associação: Qui-quadrado de Pearson

Baseado nas diferenças entre as frequências absolutas observadas ( $f_{ij}$ ) e as frequências calculadas supondo independência entre  $x$  e  $y$  ( $f_{ij}^{ind} = f_{i\bullet}f_{\bullet j}/n$ ):

$$Q^2 = \sum_{i=1}^k \sum_{j=1}^m \frac{(f_{ij} - f_{ij}^{ind})^2}{f_{ij}^{ind}}$$

$Q^2 = 0 \implies$  ausência de associação entre  $x$  e  $y$

$Q^2 > 0 \implies$  comparar com o quantil de uma v.a. com distribuição

$$\chi^2_{(k-1)(m-1)}$$

# Coeficientes de associação

## Coeficiente de Contingência:

$$C = \sqrt{\frac{Q^2}{Q^2 + n}}.$$

O valor máximo de  $C$  depende de  $k$  e  $m$ .

## Coeficiente de Tschuprow: (ver

[https://en.wikipedia.org/wiki/Tschuprow%27s\\_T](https://en.wikipedia.org/wiki/Tschuprow%27s_T))

$$T = \sqrt{\frac{Q^2}{n\sqrt{(k-1)(m-1)}}}$$

Obs:  $0 \leq T \leq 1$ .  $T = 0$  indica independência.

# Exemplo

Considere o caso particular em que

Distribuição conjunta de frequências absolutas  $x$  e  $y$ .

$x \backslash y$	$y_1$	$\dots$	$y_i$	$\dots$	$y_k$	Total
$x_1$	$f_{11}$	$\dots$	0	$\dots$	0	$f_{11}$
$\vdots$	$\vdots$	$\dots$	$\vdots$	$\dots$	$\vdots$	$\vdots$
$x_i$	0	$\dots$	$f_{ii}$	$\dots$	0	$f_{ii}$
$\vdots$	$\vdots$	$\dots$	$\vdots$	$\dots$	$\vdots$	$\vdots$
$x_k$	0	$\dots$	0	$\dots$	$f_{kk}$	$f_{kk}$
Total	$f_{11}$	$\dots$	$f_{ii}$	$\dots$	$f_{kk}$	n

## Exemplo

Considere o caso particular em que

Distribuição conjunta de frequências absolutas  $x$  e  $y$ .

$x \backslash y$	$y_1$	$\dots$	$y_i$	$\dots$	$y_k$	Total
$x_1$	$f_{11}$	$\dots$	0	$\dots$	0	$f_{11}$
$\vdots$	$\vdots$	$\dots$	$\vdots$	$\dots$	$\vdots$	$\vdots$
$x_i$	0	$\dots$	$f_{ii}$	$\dots$	0	$f_{ii}$
$\vdots$	$\vdots$	$\dots$	$\vdots$	$\dots$	$\vdots$	$\vdots$
$x_k$	0	$\dots$	0	$\dots$	$f_{kk}$	$f_{kk}$
Total	$f_{11}$	$\dots$	$f_{ii}$	$\dots$	$f_{kk}$	n

Exercício: Provar que, neste caso,  $Q^2 = n(k - 1)$ . Logo,  $T = 1$ .

Apresente outros exemplos nos quais  $T = 1$ .

## Exemplo: estado civil x grau de instrução

$Q^2 = 1.91$  (exercício: desenvolva os cálculos ou use o R).

Comparar com o quantil da  $Q^2_{(3-1)(2-1)}$ , supondo  $\alpha = 0.05$  temos  $q_c = 5.99 \implies$  Não existe associação entre estado civil e grau de instrução. Obs: Um teste mais adequado nesse caso seria o Teste Exato de Fisher.

$$C = \sqrt{\frac{Q^2}{Q^2 + n}} = 0.22$$

$$T = \sqrt{\frac{Q^2}{n\sqrt{(k-1)(m-1)}}} = 0.19, \text{ que também indica associação fraca entre estado civil e instrução.}$$

# Exemplo: variável qualitativa x variável qualitativa

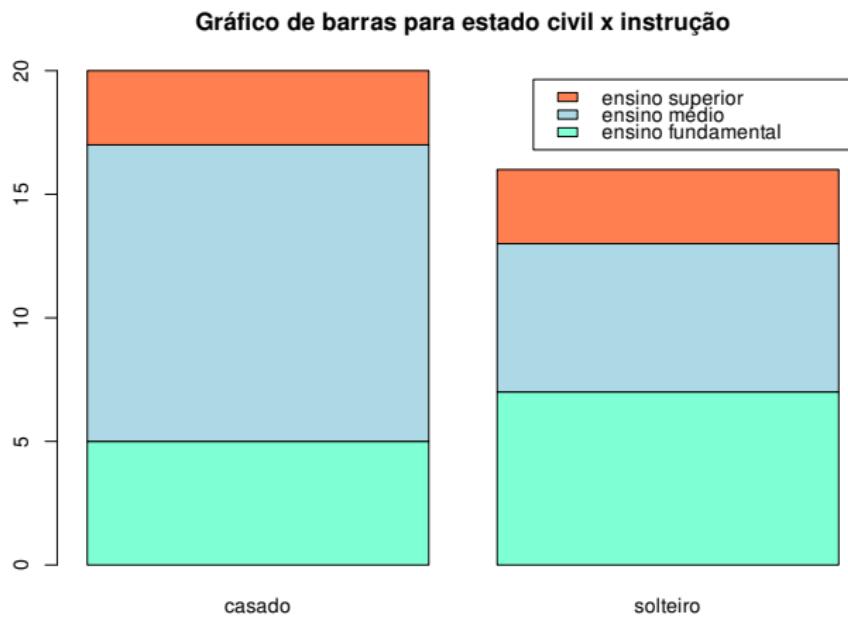


Figura: Gráfico de barras empilhadas de estado civil e grau de instrução para os dados da Companhia MB. Fonte: Elaborado pela autora.

# Exemplo: variável qualitativa x variável qualitativa

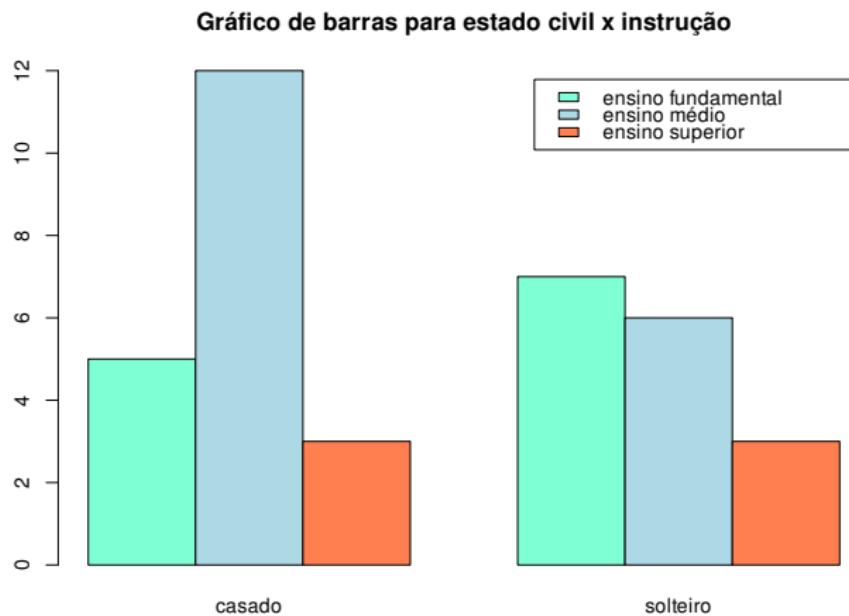


Figura: Gráfico de barras adjacentes de estado civil e grau de instrução para os dados da Companhia MB. Fonte: Elaborado pela autora.

# Exemplo: variável qualitativa x variável qualitativa

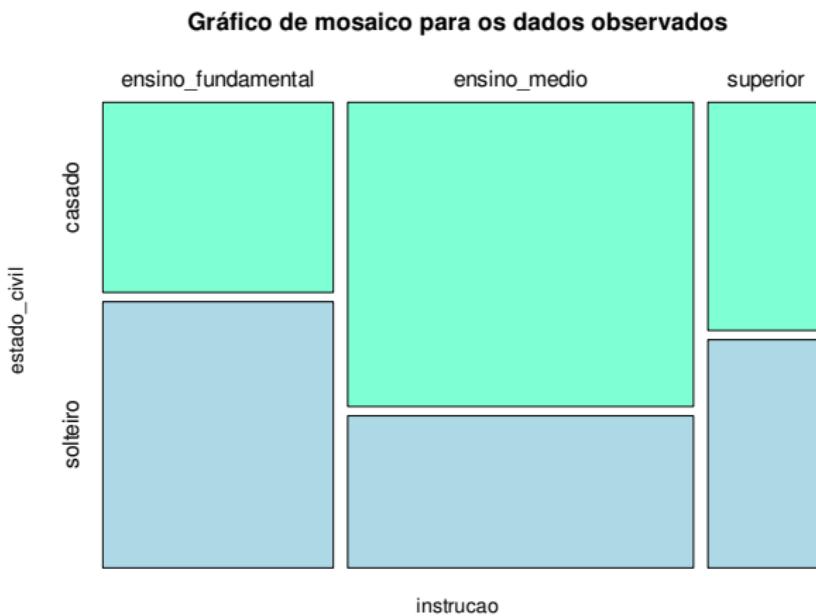


Figura: Gráfico de mosaico de estado civil e grau de instrução para os dados da Companhia MB. Fonte: Elaborado pela autora.

# Exemplo: variável qualitativa x variável qualitativa



Figura: Gráfico de mosaico de estado civil e grau de instrução sob independência. Fonte: Elaborado pela autora.