
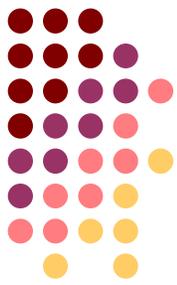


ESTATÍSTICAS DESCRITIVAS PARA DADOS SIMBÓLICOS



Renata Maria C. R. de Souza

Introdução




Média


Variância

Distribuição de
Freqüências


Função de Distribuição
Acumulada



Histograma



Estatísticas para dados clássicos



$E = \{1, 2, \dots, n\}$ conjunto de n elementos

Y - uma variável descritora

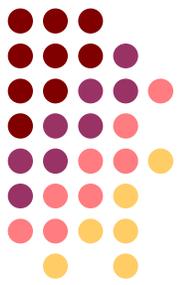
O - conjunto dos possíveis valores de Y

$y = (Y(1), \dots, Y(n))'$ vetor de valores de Y para n elementos

$\{V_1, V_2, \dots, V_t\}$ conjunto desses valores distintos de Y onde

$$V_1 \leq V_2 \leq \dots \leq V_t$$

$\text{freq}_Y(V_i) = \text{número de exemplos do valor } V_i$
 $i \in \{1, \dots, t\}$



Distribuição de freqüências - todos os pares $(V_j, \text{freq}(V_j))$

Função de distribuição - acumulada $F_Y(V) = \frac{1}{n} \sum_{V_j \leq V} \text{freq}(V_j)$

Média - $\bar{y} = \frac{1}{n} \sum_{j=1}^t \text{Freq}(V_j) \times V_j$

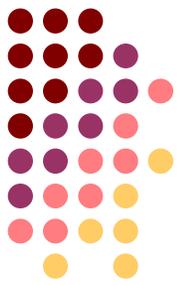
Variância - $s_Y^2 = \frac{1}{n} \sum_{j=1}^t \text{freq}(V_j) (V_j - \bar{y})^2$

Histograma - Considere m subintervalos I_1, \dots, I_m de $[V_1, V_t]$ e

$$m_h = |k \in E / Y(k) \in I_h| \quad \text{ou} \quad m_h = \frac{|k \in E / Y(k) \in I_h|}{n}$$

Representação gráfica dos pares (I_h, m_h)

Estatísticas para dados simbólicos



$E = \{1, 2, \dots, n\}$ conjunto de n unidades

$Y = \{Y_1, \dots, Y_p\}$ – conjunto de variáveis simbólicas (multivalorada, modal ou intervalo) sendo O_j – conjunto dos possíveis valores de Y_j (domínio de Y_j)

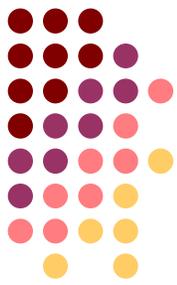
$O = \{O_1 \times \dots \times O_p\}$

$d_i = (\xi_{i1}, \dots, \xi_{ip})$ – descrição simbólica

Tabela de dados simbólicos

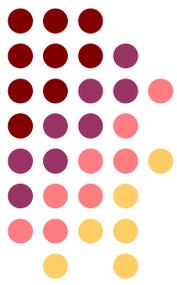
E	Y_1	...	Y_j	...	Y_p
1					
\vdots					
i	ξ_{i1}		ξ_{ij}		ξ_{ip}
\vdots					
n					

Estatísticas para Dados Simbólicos



- Envolve
 - Descrições individuais
 - Dependências lógicas nos dados
 - Extensão virtual

Vetor de Descrição Individual



Seja

$\mathbf{d} = (D_1, \dots, D_p)$ um vetor de descrição e $D = (D_1 \times \dots \times D_p)$ o conjunto de descrição cartesiano associado a \mathbf{d}

\mathbf{x} é chamado de **vetor de descrição individual** se $D_j \subset O_j$ é um único valor ou seja

$$\mathbf{x} = (\{x_1\}, \dots, \{x_p\}) = (x_1, \dots, x_p)$$

Exemplos:

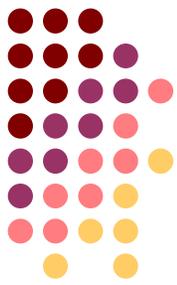
Multivalorada: $Y = \text{cor de pássaro}$

$\xi = \{\text{vermelho, azul, verde}\}$ (descrição simbólica associada a Y)

Descrições individuais associadas a ξ : $x = \text{vermelho}$, $x = \text{azul}$,
 $x = \text{verde}$

Intervalo: $Y = \text{altura}$ $\xi = [65, 70]$ $x = \text{todos os pontos no intervalo}$
 $[65, 70]$

Dependências Lógicas nos Dados



A dependência lógica pode ser representada pela regra

$$r: \text{ Se } \mathbf{x} \in A \text{ então } \mathbf{x} \in B$$


onde $A \subseteq D$ e $B \subseteq D$ são dois conjuntos de descrições e r uma função de O em $[0,1]$.

Um vetor de descrição individual \mathbf{x} satisfaz a regra r se e somente se $\mathbf{x} \in A \cap B$ ou $\mathbf{x} \notin A$. A notação $r(\mathbf{x}) = 1$ indicará que \mathbf{x} satisfaz a regra e $r(\mathbf{x}) = 0$ caso contrário

Exemplo. Considere $\mathbf{d}_1 = (\{10, 26\}, \{1\})$ um descrição simbólica de $Y_1 = \text{idade}$ e $Y_2 = \text{número de filhos}$. Suponha que existe a regra $r: \text{ If } A = \{Y_1 \leq 12\} \text{ então } B = \{Y_2 = 0\}$.

Temos dois vetores de descrições individuais:
 $\mathbf{x}_1 = (10, 1)$ e $\mathbf{x}_2 = (26, 1)$. Então $r(\mathbf{x}_1) = 0$ e $r(\mathbf{x}_2) = 1$

Uso de Dependências Lógicas nos Dados






- Tratamento com grandes conjuntos de dados agregados pode produzir unidades que tem valores de descrições individuais não praticáveis.

	Indivíduo	Idade	No de Filhos
Clássico	1	10	0
	2	26	1
	3	10	0
	4	10	0
	5	26	1
Simbólico	w	[10,26]	{0,1}


Exemplos

- Considere um par de variáveis simbólicas de tipo intervalo (Y_1, Y_2) com $Y_1 =$ custo de medicação e $Y_2 =$ cobertura do seguro e a regra
- Regra r_1 :
- $A_1 = \{Y_1 = \text{Custo} < \$200\}$ e $B_1 = \{Y_2 = \$0\}$.
- Suponha
- $d_u = Y(u) = \xi_u = ([100, 300], [0, 400])$
- Regra r_2 :
- $A_2 = \{Y_1 = \text{Custo}\}$ e $B_2 = \{Y_2 \leq Y_1\}$.

Considerando as duas regras



Extensão Virtual de um vetor de descrição




Considere $\mathbf{d}=(D_1,\dots,D_p)$, $D=(D_1\times\dots\times D_p)$ e R um conjunto de regras de dependências lógicas.

A extensão virtual do vetor de descrição \mathbf{d} $\text{vir}(\mathbf{d})$ é o conjunto de vetores de descrição individual que satisfaz todas as regras em R ou seja

$$\text{vir}(\mathbf{d}): = \{ \mathbf{x} \in D / r(\mathbf{x}) = 1 \} \quad \forall r \in R$$

Exemplo:



E	Y_1	Y_2
1	{a,b}	{3}
2	{b,c}	{2,3}
3	{b}	{1,2}
4	{c}	{1,3}
5	{a}	{1,3}

$$O_1 = \{a,b,c\}$$

$$O_2 = \{1,2,3\}$$

r: Se $A = \{y_1 \in \{b,c\}\}$ então
 $B = \{y_2 \in \{2\}\}$


$$A = \{(b,1), (b,2), (b,3), (c,1), (c,2), (c,3)\}$$

$$B = \{(a,2), (b,2), (c,2)\}$$

$r(x) = 1$ se $x \in A \cap B$ ou $x \notin A$

d_1	d_2	d_3	d_4	d_5
{a},{3}	{b},{2}	{b},{1}	{c},{1}	{a},{1}
{b},{3}	{b},{3}	{b},{2}	{c},{3}	{a},{3}
	{c},{2}			
	{c},{3}			

Extensão Virtual



$$\text{Vir}(d_1) = \{\mathbf{x} \in \{a,b\} \times \{3\} / r(x) = 1 \} = \{(a,3)'\}$$

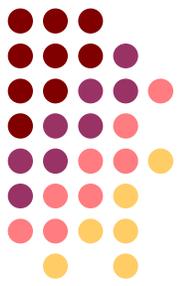
$$\text{Vir}(d_2) = \{(b,2)', (c,2)'\}$$

$$\text{Vir}(d_3) = \{(b,2)'\}$$

$$\text{Vir}(d_4) = \emptyset$$

$$\text{Vir}(d_5) = \{(a,1)', (a,3)'\}$$

Distribuição de Freqüências para Variáveis Multivaloradas



Seja $Y_j = Z$ uma variável simbólica multivalorada que toma valores $\xi \in O_Z$. Esses valores podem ser categóricos ou discretos.

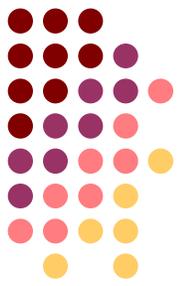
Para um conjunto de observações multivaloradas $\{\xi_1, \dots, \xi_n\}$, a **freqüência observada** de Z é dada por

$$Freq_z(\xi) = \sum_{k \in E} w_z(\xi : k)$$

onde
$$w_z(\xi; k) = \frac{|\mathbf{x} \in \text{vir}(d_k) / x_{[z]} = \xi|}{|\text{vir}(d_k)|}$$

$Freq(\xi)$ pode não ser um valor inteiro como no caso clássico.
 $x_{[z]}$ valor individual da variável simbólica Z

Distribuição de Freqüências para Variáveis Multivaloradas




- A **distribuição de frequência empírica** é o conjunto de pares $\{\xi, \text{Freq}_z(\xi)\}$ para todo $\xi \in O_z$.
- A **distribuição de frequência relativa** ou o histograma é o conjunto para todo $\xi \in O_z$

$$\{\xi, \text{Freq}_z(\xi)\} = \frac{1}{m} \sum_{k \in E} w_z(\xi : k)$$

- $m = n - n_0$ onde n_0 é a quantidade de k cujo $|\text{vird}(d_k)| = 0$

Distribuição de Freqüências para Variáveis Multivaloradas



- A **Função de distribuição empírica** é dada por

$$F_z(\xi) = \frac{1}{m} \sum_{\xi_k \leq \xi} \text{Freq}_z(\xi_k)$$


- A **Média e Variância amostral simbólica** são

$$\bar{z} = \frac{1}{m} \sum_{\xi_k \in O_z} \xi_k \text{Freq}(\xi_k) \quad S_z^2 = \frac{1}{m} \sum_{\xi_k \in O_z} (\xi_k - \bar{z})^2 \text{Freq}(\xi_k)$$

- A **Mediana amostral simbólica** é dada por

$$\tilde{z} = \xi / F_z(\xi) = 1/2$$

Exemplo 1: Com dependência lógica



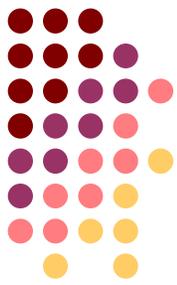
$$Freq_z(\xi) = \begin{cases} 0+0+0+1/2=0.5 & \text{se } \xi = 1 \\ 2 & \text{se } \xi = 2 \\ 1.5 & \text{se } \xi = 3 \\ 0 & \text{outro caso} \end{cases}$$

$$\bar{z} = \frac{1}{4} (1 \times 0.5 + 2 \times 2 + 3 \times 1.5) = 2,125$$

$$S_z^2 = \frac{1}{4} (0.5 (1 - 2.125)^2 + 2(2 - 2.125)^2 + 1.5(3 - 2.125)^2) = 1,81$$

$$\tilde{z} = \xi / F_z(\xi) = 0,50 = 2$$


Exemplo 1: Com dependência lógica



Função de distribuição
Acumulada

$$F_Z(\xi) = \begin{cases} 0 & \text{se } \xi < 1 \\ 0,125 & \text{se } 1 \leq \xi < 2 \\ 0,625 & \text{se } 2 \leq \xi < 3 \\ 1 & \text{outro caso} \end{cases}$$


Exemplo 2: Sem dependência lógica



E	Y_1	Y_2
1	{a,b}	{3}
2	{b,c}	{2,3}
3	{b}	{1,2}
4	{c}	{1,3}
5	{a}	{1,3}

d_1	d_2	d_3	d_4	d_5
{a},{3}	{b},{2}	{b},{1}	{c},{1}	{a},{1}
{b},{3}	{b},{3}	{b},{2}	{c},{3}	{a},{3}
	{c},{2}			
	{c},{3}			

Exemplo 1: Sem dependência lógica



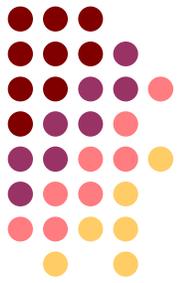
$$\text{Freq}_z(\xi) = \begin{cases} 0+0+0.5+0.5+0.5=1.5 & \text{se } \xi = 1 \\ 1 & \text{se } \xi = 2 \\ 2.5 & \text{se } \xi = 3 \\ 0 & \text{outro caso} \end{cases}$$

$$\bar{z} = \frac{1}{4} (1 \times 1.5 + 2 \times 1 + 3 \times 2.5) = 3,25$$

$$S_z^2 = 2,71$$

$$\tilde{z} = \xi / F_z(\xi) = 0,5 = 2$$



Exemplo 1: Sem dependência lógica



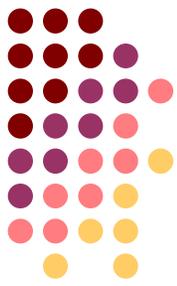
Função de distribuição
Acumulada

$$F_Z(\xi) = \left\{ \begin{array}{ll} 0 & \text{se } \xi < 1 \\ 0.375 & \text{se } 1 \leq \xi < 2 \\ 0.875 & \text{se } 2 \leq \xi < 3 \\ 1 & \text{outro caso} \end{array} \right.$$

- não dep.
- com dep.



Distribuição de Frequência para Variáveis Intervalo



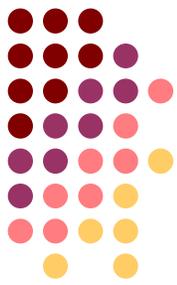
Seja Z uma variável intervalo. Para cada $u \in E$, $Z(u) = [a_u, b_u]$.

Hipóteses

1 - Cada $u \in E$ é selecionado com a mesma probabilidade $1/n$

2 - Os valores $x_{[z]}$ para $\underline{x} \in \text{vir}(d_u)$ são uniformemente distribuído no intervalo $Z(u) = [a_u, b_u]$.

Z é considerada uma variável aleatória cuja distribuição é uma mistura de n distribuições uniformes




$$\Pr(x_{[z]} \leq \xi / \mathbf{x} \in \text{vir}(d_u)) = \begin{cases} 0 & \text{se } \xi < a_u \\ \frac{\xi - a_u}{b_u - a_u} & \text{se } a_u \leq \xi < b_u \\ 1 & \text{se } b_u \leq \xi \end{cases}$$

A Função de Distribuição Empírica é dada por

$$F_z(\xi) = \frac{1}{n} \sum_{u \in E} \Pr(x_{[z]} \leq \xi / \mathbf{x} \in \text{vir}(d_u))$$

$$F_z(\xi) = \frac{1}{n} \sum_{u: \xi \in Z(u)} \frac{\xi - a_u}{b_u - a_u} + \frac{|\{u / \xi \geq b_u\}|}{n}$$



A Função de Densidade Empírica é dada por

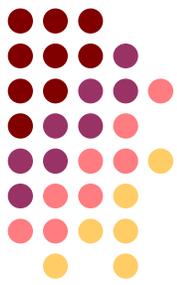
$$f_z(\xi) = \frac{1}{n} \sum_{u: \xi \in Z(u)} \frac{1}{b_u - a_u} = \frac{1}{n} \sum_{u \in E} \frac{1l_{Z(u)}(\xi)}{L(Z(u))} \quad \xi \in \mathbb{R}$$

onde $1l_{Z(u)}(\xi)$ é uma função indicadora e L a largura do intervalo $Z(u)$

A média empírica é dada por

$$\bar{z} = \int_{-\infty}^{+\infty} \xi f_z(\xi) d_\xi = \frac{1}{n} \sum_{u \in E} \int_{z_u}^{\bar{z}_u} \frac{1l_{Z(u)}(\xi)}{L(Z(u))} \xi d_\xi = \frac{1}{n} \sum_{u \in E} \frac{1}{b_u - a_u} \int_{a_u}^{b_u} \xi d_\xi$$

$$\bar{z} = \frac{1}{2n} \sum_{u \in E} \frac{b_u^2 - a_u^2}{b_u - a_u} = \frac{1}{n} (b_u + a_u) / 2$$



O desvio padrão empírico é dada por

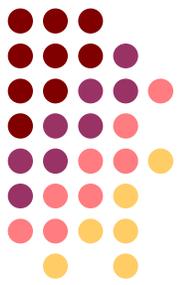
$$s_z = \sqrt{\int_{-\infty}^{+\infty} \xi^2 f_Z(\xi) d_\xi - \bar{z}^2}$$

Segundo momento $M_2 = \int_{-\infty}^{+\infty} f_Z(\xi) d_\xi = \frac{1}{n} \sum_{u \in E} \int_{a_u}^{b_u} \frac{\xi^2}{L(Z(u))} d_\xi$

$$M_2 = \frac{1}{n} \sum_{u \in E} \frac{b_u^3 - a_u^3}{3 \times L(Z(u))} = \frac{1}{3n} \sum_{u \in E} (b_u^2 + b_u a_u + a_u^2)$$

$$s_z = \sqrt{\frac{1}{3n} \sum_{u \in E} (b_u^2 + b_u a_u + a_u^2) - \frac{1}{4n^2} \left[\sum_{u \in E} (a_u + b_u) \right]^2}$$

Exemplo



$$E = \{1, \dots, 8\}$$

$$Z(E) = \{[0,2]; [1,3]; [1.5,2.5]; [2,4]; [3.5,5]; [4.5,5.5]; [5,7]; [6.5,7.5]\}$$


$$I = [0, 7.5]$$

u	1	2	3	4	5	6	7	8
$\frac{a_u + b_u}{2}$	2	2	3	4.25	4.75	0.50	6	0.50

Média = 3.781

Desvio Padrão = 2.045

Histogramas sem Dependências Lógicas



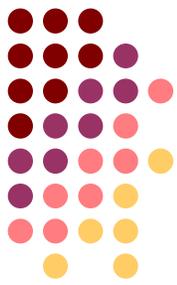
Considere uma partição de $I = [\min \{z_u / k \in E\}, \max \{z_u / k \in E\}]$ em r subintervalos $I_j = [u_{g-1}, u_g]$ para $g \in \{1, \dots, r\}$ que estão em ordem crescente.

A frequência observada é dada por

$$f_g = \sum_{u \in E} \frac{L(Z(u) \cap I_g)}{L(Z(u))}$$

A frequência relativa é dada por $p_g = \frac{1}{n} f_g$


O histograma é a representação gráfica $\{I_g, f_g\}$ para $g=1, \dots, r$



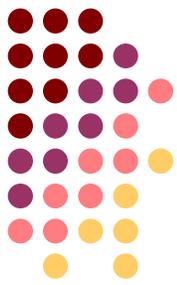
$$p_j = \frac{1}{n} \sum_{u \in E} \frac{L(Z(u) \cap I_j)}{L(Z(u))}$$

Distribuição de Frequências

j	1	2	3	4	5
I	[0,1.5]	[1.5,3.0]	[3.0,4.5]	[4.5,6.0]	[6.0,7.5]
p	0.125	0.312	0.145	0.229	0.187




Histogramas com Dependências Lógicas



u	pulso	Pressão sistólica	Pressão diastólica
u_1	[44,68]	[90,110]	[50,70]
u_2	[60,72]	[90,130]	[70,90]
u_3	[56,90]	[140,180]	[90,100]
u_4	[70,112]	[110,142]	[80,108]
u_5	[54,72]	[90,100]	[50,70]
u_6	[70,100]	[134,142]	[80,110]
u_7	[72,100]	[130,160]	[76,90]
u_8	[76,98]	[110,190]	[70,110]
u_9	[86,96]	[138,180]	[90,110]
u_{10}	[86,100]	[110,150]	[78,100]
u_{11}	[53,55]	[160,190]	[205,219]
u_{12}	[50,55]	[180,200]	[110,125]
u_{13}	[73,81]	[125,138]	[78,99]
u_{14}	[60,75]	[175,194]	[90,100]
u_{15}	[42,52]	[105,115]	[70,82]

Histogramas com Dependências Lógicas



- r_1 Se $A = \{Y_1 \leq 55\}$ então $B = \{Y_2 \leq 170, Y_3 \leq 100\}$
- O conjunto A inclui os elementos $u=1,5,11,12,15$.
- Os elementos $u=11,12$ não são válidos na região de B
- Então os elementos $u=11,12$ são omitidos do conjunto.
- Considerando os intervalos I_{jj} ($j=1,5$) $I_1=[80,100)$, $I_2=[100,120)$, $I_3=[120,140)$, $I_4=[140,160)$, $I_5=[160,180)$, $I_6=[180,200)$ para variável pressão sistólica temos que

$$f_5 = 0 + 0 + \left(\frac{180-160}{180-140}\right)_{u=3} + 0 + \dots + 0 + \left(\frac{180-160}{180-138}\right)_{u=9} + 0_{u=10} + 0_{u=13} + \left(\frac{180-175}{194-175}\right) = 1,489$$

$$p_5 = 1,489/13 = 0,114$$


$$\bar{z} = 133,769$$

Média

$$S_z^2 = 730$$

Desvio Padrão

Histogramas com Dependências Lógicas




- r_2 Se $A = \{Y_1 < 55\}$ então $B = \{Y_2 \leq 170\}$
- O conjunto A inclui os elementos $u=1,5,11,12,15$.
- O elemento $u=12$ não é válido na região de B e é omitido do conjunto.
- A extensão virtual da descrição de $u=11$ são todos os pontos em $[53,55] \times [160,170]$
- Considerando os intervalos I_j ($j=1,5$) $I_1=[80,100)$, $I_2=[100,120)$, $I_3=[120,140)$, $I_4=[140,160)$, $I_5=[160,180)$, $I_6=[180,200)$ para variável pressão sistólica temos que

$$f_5 = 0 + 0 + \left(\frac{180-160}{180-140}\right)_{u=3} + 0 + \dots + 0 + \left(\frac{180-160}{190-110}\right)_{u=8} + \left(\frac{180-160}{180-138}\right)_{u=9} + 0_{u=10} + \left(\frac{170-160}{170-160}\right)_{u=11} + 0 + \left(\frac{180-160}{194-175}\right)_{u=14} = 2,489$$

$\bar{z} = 136,$ Média
 $S_Z^2 = 743,88$ Desvio Padrão

Histogramas com Dependências Lógicas



- r_3 Se $A = \{Y_1 \leq 70\}$ então $B = \{Y_2 \leq 170\}$
- O elemento $u=12$ não é logicamente verdadeiro e é omitido do conjunto.
- Partes da descrição de $u=3,11,14$ não são válidas.
- A descrição virtual de $u=3$ é:
- $R = [56,90] \times [140,170] \cup [70,90] \times [170,180]$

$$\frac{(90-56) \times (170-140)}{(90-56) \times (170-140) + (90-70) \times (180-70)}$$

$$f_5 = 0 + 0 + \left\{ \left(\frac{170-160}{170-140} \right) (0.836)_{R_1} + \left(\frac{180-170}{180-170} \right) (0.164)_{R_2} \right\}_{u=3} + 0 + \dots + \left(\frac{180-160}{190-110} \right)_{u=8} +$$

$$\left(\frac{180-160}{180-138} \right)_{u=9} + 0_{u=10} + \left(\frac{180-160}{190-160} \right)_{u=11} + 0 + 0 + \left(\frac{180-160}{194-175} \right)_{u=14} + 0$$

$$= 2,432$$

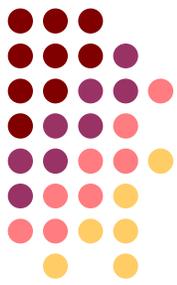
$$\bar{z} = 135,87$$

Média

$$S_z^2 = 737,05$$

Desvio Padrão

Distribuição de Frequências para Variáveis Modais



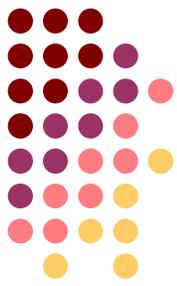
- Y_j uma variável modal (multivalorada modal)
- ξ_{jk} - categorias ou valores de Y_j com frequências relativas p_{jk} ($k=1, \dots, s$) tal que

$$\sum p_{jk} = 1$$

- Assumindo $Z = Y_j$ a frequência observada de Z é dada por:


$$O_Z(\xi_k) = \sum_{u \in E} \pi_z(\xi_k : u) \quad \pi_z(\xi_k : u) = P(Z = \xi_k / x \in \text{virt}(d_u), u)$$
$$P(Z = \xi_k / x \in \text{virt}(d_u), u) = \frac{\sum_x P(x = \xi_k / x \in \text{virt}(d_u), u)}{\sum_x \sum_{k=1}^s P(x = \xi_k / x \in \text{virt}(d_u), u)}$$

Distribuição de Frequências para Variáveis Modais



u	Tipo de Combustível					Indicadora	
	{Nada	Gasolina	Óleo	Eletricidade	Carvão}	{Não	Sim}
u_1	{0,0	0,87	0,07	0,05	0,01}	{0,09	0,91}
u_2	{0,0	0,71	0,11	0,10	0,08}	{0,12	0,88}
u_3	{0,0	0,83	0,08	0,09	0,00}	{0,23	0,77}
u_4	{0,0	0,76	0,06	0,11	0,07}	{0,19	0,81}
u_5	{0,0	0,78	0,06	0,09	0,07}	{0,12	0,88}
u_6	{0,0	0,90	0,01	0,08	0,01}	{0,22	0,78}
u_7	{0,0	0,87	0,01	0,10	0,02}	{0,22	0,78}
u_8	{0,0	0,78	0,02	0,13	0,07}	{0,13	0,87}
u_9	{0,0	0,91	0,00	0,09	0,00}	{0,24	0,76}
u_{10}	{0,25	0,00	0,41	0,14	0,20}	{0,09	0,91}

Distribuição de Frequências para Variáveis Modais



Frequências para variável Y_1

$$O_{Y_1}(\text{Nada}) = 0,25$$

$$O_{Y_1}(\text{Gas.}) = (0,87 + \dots + 0,91 + 0,00) = 7,41$$

$$O_{Y_1}(\text{Óleo}) = 0,83$$

$$O_{Y_1}(\text{Eletric.}) = 0,98$$

$$O_{Y_1}(\text{Carvão}) = 0,53$$


Frequências para variável Y_2

$$O_{Y_2}(\text{Não}) = 1,65$$

$$O_{Y_2}(\text{Sim}) = 8,35$$

$$\sum_{k=1}^{10} O_Y(\xi_k) = n$$

Distribuição de Frequências para Variáveis Modais



Frequências Relativas para variável Y_1

$$P_{Y_1}(Nada) = 0,25 / 10 = 0,025$$

$$P_{Y_1}(Gas.) = 0,741$$

$$P_{Y_1}(Óleo) = 0,083$$

$$P_{Y_1}(Eletric.) = 0,098$$

$$P_{Y_1}(Carvão) = 0,053$$

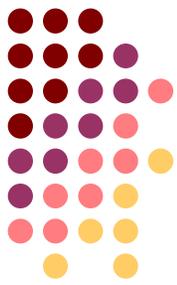
Frequências Relativas para variável Y_2

$$P_{Y_2}(Não) = 0,165$$

$$P_{Y_2}(Sim) = 0,835$$

$$\sum_{k=1}^{10} P_Y(\xi_k) = 1$$

Distribuição de Frequências para Variáveis Modais



- Considere a regra

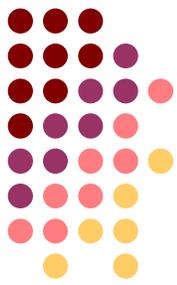
$$r = \begin{cases} r_1 : Y_2 \in \{N\tilde{a}o\} \Rightarrow Y_1 \in \{Nada\} \\ r_2 : Y_2 \in \{Sim\} \Rightarrow Y_1 \in \{Gas, \acute{O}leo, Eletric.Carv\tilde{a}o\} \end{cases}$$

- Descrições individuais validas

$$C = \{(\xi_0, N\tilde{a}o); (\xi_1, Sim); (\xi_2, Sim); (\xi_3, Sim); (\xi_3, Sim)\}$$

- Assumindo que Y_1 e Y_2 sao independentes, sera obtido a probabilidade conjunta de (Y_1, Y_2)

Distribuição de Frequências para Variáveis Modais



- Considere $u=10$ e a tabela de probabilidades conjunta


$Y_1,$ Y_2	(Nada, Não)	(Gas., Sim)	(Óleo, Sim)	(Eletric ,Sim)	(Carvão, Sim)	TOTAL
u_{10}	0,0225	0,00	0,3731	0,1274	0,1820	0,7050

$0,25 \times 0,09$

Probabilidades Padronizadas


$Y_1,$ Y_2	(Nada, Não)	(Gas., Sim)	(Óleo, Sim)	(Eletric ,Sim)	(Carvão, Sim)
u_{10}	0,0319	0,00	0,5292	0,1807	0,2582

Distribuição de Frequências para Variáveis Modais



$Y_1,$ Y_2	(Nada, Não)	(Gas., Sim)	(Óleo, Sim)	(Eletric ,Sim)	(Carvão, Sim)
u_1	0,0900	0,7917	0,0637	0,0455	0,0091
u_2	0,1200	0,6248	0,0968	0,0880	0,0704
u_3	0,2300	0,6391	0,0616	0,0693	0,0000
u_4	0,1900	0,6156	0,0486	0,0891	0,0567
u_5	0,1200	0,6864	0,0528	0,0792	0,0616
u_6	0,2200	0,7020	0,0078	0,0624	0,0078
u_7	0,2200	0,6786	0,0078	0,0708	0,0156
u_8	0,1300	0,6786	0,0174	0,1131	0,0609
u_9	0,2400	0,6916	0,0000	0,0684	0,0000
u_{10}	0,0319	0,00	0,5292	0,1807	0,2582

Distribuição de Frequências para Variáveis Modais



Frequências
para variável Y_1

Frequências
para variável Y_2

$$O_{Y_1}(\text{Nada}) = 1,5919$$

$$O_{Y_2}(\text{Não}) = 1,6$$

$$O_{Y_1}(\text{Gas.}) = 6,1084$$

$$O_{Y_2}(\text{Sim}) = 8,4$$

$$O_{Y_1}(\text{Óleo}) = 0,0637 + \dots + 0,000 + 0,5292 = 0,5403$$

$$O_{Y_1}(\text{Eletric.}) = 0,8737$$

$$O_{Y_1}(\text{Carvão}) = 0,403$$