

3. Representação de variáveis quantitativas

2010

3.1 Variáveis discretas

Dados: n observações de uma variável discreta x .

Existem k diferentes valores $x_1 < x_2 < \dots < x_k$, $1 \leq k \leq n$.

Tabela de frequências: tabela com os valores de x_j e uma das ou ambas as frequências f_j e f_j^* , $j = 1, \dots, k$.

Tabela 1. Descrição da tabela.

x	Frequencia	Frequencia relativa
x_1	f_1	f_1^*
x_2	f_2	f_2^*
...
x_k	f_k	f_k^*
Total	n	1 (100%)

As frequências acumuladas F_j e F_j^* estão bem definidas, $j = 1, \dots, k$ e podem ser uma coluna de uma tabela de frequências.

Tabelas e gráficos em R

```
> x = c(2, 3, 3, 1, 0, 0, 2, 2, 2, 2, 2, 1, 2, 3, 2, 0, 2, 0, 2, 2, 1, 3, 1, 3, 5, 0, 3, 2, 3, 2, 2, 3, 1, 3, 3, 0, 2, 2,  
2, 2)
```

```
> barplot(freqa)
```

```
> (n = length(x))
```


```
40
```

```
> (freqa = table(x))
```

```
0  1  2  3  5  
6  5 18 10  1
```

```
> freqa / n * 100
```

```
0      1      2      3      5  
15.0 12.5 45.0 25.0  2.5
```




Tabelas e gráficos em R

Gráfico de pontos (*dot plot*)


Cada observação é representada por um ponto. Valores repetidos produzem pontos empilhados.

```
> library(plotrix)
```

```
> dotplot.mtb(x, xlab = "Número de defeitos")
```




```
> plot(freqa, type = "p", pch = 20, xlab = "Número de defeitos", ylab = "Frequencia")
```



Tabelas e gráficos em R


```
> plot(freqa, xlab = "Número de defeitos",  
ylab = "Frequencia")
```



```
> freqaux = table(c(x, 4))
```

```
> freqaux[which(names(freqaux) == "4")] = 0
```

```
> barplot(freqaux, xlab = "Número de defeitos",  
ylab = "Frequencia")
```



3.2 Variáveis contínuas

Dados: n observações de uma variável contínua x .

Existem m diferentes valores $x_1 < x_2 < \dots < x_m$, $1 \leq m \leq n$.

Tabela de frequências. Se m é “grande”, uma tabela com **todos** os diferentes valores não cumpre o papel de **resumir** os dados.

Representação em k **intervalos de classe** (ou **classes**) do tipo $[LI_j, LS_j)$, $j = 1, \dots, k$.

LI_j : limite **inferior** e LS_j : limite **superior**.

Construção. 1. Escolha do número de classes (k). Usualmente, $5 \leq k \leq 15$.

2. Cálculo da **amplitude** (A): $A = \text{MAX} - \text{min}$, sendo que min e MAX são o menor e o maior valor dos dados.

3. Cálculo da **amplitude de classe** (h): $h = A / k$.

4. Obtenção dos limites das classes: $LI_1 = \text{min}$, $LS_1 = LI_1 + h$, $LI_2 = LS_1$, $LS_2 = LI_2 + h$, ..., $LI_k = LS_{k-1}$, $LS_k = \text{MAX}$.

Obs. (1) h e LI_1 podem ser arredondados por **conveniência**.

(2) Cada valor de x pertence a uma e apenas uma classe.

(3) h pode variar com a classe.

Ponto médio da classe (ou marca de classe):

$$x_j^* = \frac{LI_j + LS_j}{2}$$

Frequência **absoluta** da classe (f_j): número de observações $\in [LI_j, LS_j)$.

Frequência **relativa** de cada intervalo de classe: $f_j^* = f_j / n$.

Frequência **acumulada** da classe (F_j):

$$F_j = f_1 + f_2 + \dots + f_j = \sum_{l=1}^j f_l \quad (F_k = n).$$

Frequência **acumulada**

relativa da classe:

$$F_j^* = \frac{F_j}{n} \quad (F_k^* = 1).$$

Obs. Na representação por classes há **perda de informação**.

Densidade de frequência (ou densidade):

$$f_{d_j} = \frac{f_j}{h_j} \quad \text{ou} \quad f_{d_j}^* = \frac{f_j^*}{h_j}, \quad j = 1, \dots, k.$$

Representação gráfica:

Histograma (*histogram* – Karl Pearson, 1895)

Gráfico de **barras adjacentes** com **bases** iguais às **amplitudes** das classes e **alturas** iguais às **densidades**.

Obs. Se as classes tiverem **amplitude constante**, as alturas das barras usualmente são iguais às frequências.

Propriedade :

$$\sum_{j=1}^k h_j f_{d_j} = \sum_{i=1}^k h_j \frac{f_j}{h_j} = \sum_{j=1}^k f_j = n \quad \text{ou} \quad \sum_{j=1}^k h_j f_{d_j}^* = \sum_{j=1}^k h_j \frac{f_j^*}{h_j} = \sum_{j=1}^k f_j^* = 1.$$


Obs. Na construção de um histograma, quanto **maior** for **n**, **melhor**.

Histograma em R

```
> ? co2
```

```
> x = as.vector(co2)
```

```
> hist(x)
```



Fornece uma ideia sobre a distribuição.

```
> hx = hist(x, right = FALSE, plot = FALSE)
```

```
> names(hx)
```

```
[1] "breaks" "counts"  
"intensities" "density"  
"mids" "xname"  
"equidist"
```

```
> hx$breaks
```

```
[1] 310 315 320 325 330 335  
340 345 350 355 360 365 370
```

```
> hx$counts
```


```
[1] 8 62 65 52 46 40 39 37 41  
45 28 5
```

```
> hx$mids
```


```
[1] 312.5 317.5 322.5 327.5  
332.5 337.5 342.5 347.5 352.5  
357.5 362.5 367.5
```

Histograma em R

```
> hist(x, right = FALSE, freq = FALSE)
```



```
> hist(x, right = FALSE, freq = FALSE,  
main = "", xlab = expression(CO[2]  
(ppm)), ylab = "Densidade")
```




Histograma em R

```
> hist(x, right = FALSE, freq = FALSE, main = "", xlab = expression(CO[2] (ppm)), ylab = "Densidade")
```

```
> rug(x)
```

```
> lines(density(x), col = "blue")
```

```
> box()
```







Número de classes: **fórmula de Sturges** se *breaks* não for especificado.

Outras opções:

1. Fórmula de Scott: *breaks* = "Scott".
2. Fórmula de Freedman-Diaconis: *breaks* = "FD".
3. *breaks* = *número*: nem sempre funciona.
4. *breaks* = *vetor ordenado* com $k + 1$ elementos com os limites das classes.

Escolha do número de classes (k)



Histograma humano




Figure 7. Living histogram of 143 student heights at University of Connecticut.


The American Statistician 56(3), 223 – 229, 2002.

Polígono de frequências

Formado pelos **segmentos** unindo os **pontos centrais** dos topos das barras.

```
> hist(x, right = FALSE, main = "", xlab =  
expression(CO[2] (ppm)), ylab =  
"Frequencia")
```

```
> lines(hx$mid, hx$counts, col = "red")
```




```
> (n = length(x))
```

```
> frel = hx$counts / n
```

```
> plot(hx$mid, frel, type = "l", xlab =  
expression(CO[2] (ppm)), ylab = "Frequencia  
relativa")
```

```
[1] 468
```




Polígono de frequências acumuladas (ogiva)

Formado por segmentos de retas unindo o limite superior das classes no topo das barras.

```
> Frel = cumsum(frel)
```

```
> plot(hx$breaks, c(0, Frel), type = "l", xlab =  
expression(CO[2] (ppm)), ylab =  
"Frequencia relativa acumulada")
```



```
> posb = barplot(Frel, col = "white", space = 0,  
xlab = expression(CO[2] (ppm)), ylab =  
"Frequencia relativa acumulada")
```

```
> lines(posb + posb[1], Frel, col = "red")
```

```
> segments(0, 0, (posb[1] + posb[2]) / 2,  
Frel[1], col = "red")
```

```
> axis(1, c(0, posb + posb[1]), hx$breaks)
```




Gráfico de pontos

Cada observação é representada por um ponto.

Não há perda de informação.


Se n for grande, o gráfico pode perder em **clareza**.

```
> par(mfrow = c(2, 1))
```

```
> stripchart(x, pch = 20, method =  
"stack", xlab = expression(CO[2]  
(ppm)), main = "Sem  
arredondamento")
```

```
> stripchart(round(x, 1), pch = 20,  
method = "stack", xlab =  
expression(CO[2] (ppm)), main =  
"Com arredondamento")
```

Sem arredondamento



Com arredondamento




Gráfico de linhas

Utilizado para representar variáveis coletadas com referência a uma unidade de tempo. Chamadas de **séries históricas** ou **séries temporais** (*time series*).

Obs. Séries temporais podem ser de variáveis discretas ou qualitativas.

```
> ? AirPassengers
```

```
Monthly Airline Passenger  
Numbers 1949-1960
```

```
> class(AirPassengers)
```

```
[1] "ts"
```

```
> plot(AirPassengers)
```




Gráfico de linhas



O Estado de S. Paulo, 28/2/2010.

Gráfico de ramos-e-folhas (*stem-and-leaf plot*)

Representação com **nenhuma** ou **pouca** perda de informação.

Cada valor da variável é dividido em duas partes: **ramo** (dígitos **dominantes**) e **folha** (dígitos **dominados**).

Os **ramos** se situam **à esquerda** de uma linha vertical e as **folhas** **à direita**.

O número de ramos é escolhido.

Usualmente uma **folha** representa o **último dígito** de um número (números podem ser arredondados ou representados como múltiplos de potências de 10).

Os **dígitos restantes** de um número compõem o **ramo**.

Gráfico de ramos-e-folhas

Notas de 100 alunos em uma certa prova.

> notas

```
5.3  7.0  6.0  7.0  4.4  5.5  9.0  3.1  5.9  4.4  5.5  5.7  3.4  4.8  9.6  7.9
4.7  4.1  7.7  4.2  9.3  3.6  4.6  3.7  8.9  6.0  3.4  7.2  4.2  5.9  5.0  1.8
7.1  5.9  7.3  6.9  3.5  6.4  4.7  4.6  5.2  6.8  8.4  9.3  8.7  4.0  7.6  7.2
3.4  7.8  6.4  4.1  7.9  6.0  5.3  5.3  5.7  5.1  4.0  4.5  8.2  2.6  5.1  5.8
9.0  5.6  5.4  4.1  3.8  5.5  5.6  4.9  8.3  6.8  5.5  5.0  4.6  3.4  6.2  5.1
4.4  6.8  10.0  6.5  7.7  6.1  5.3  6.2  4.6  4.8  8.5  7.2  3.5  2.5  5.3  6.5
4.6  3.9  6.6  7.7
```

> sort(notas)

```
1.8  2.5  2.6  3.1  3.4  3.4  3.4  3.4  3.5  3.5  3.6  3.7  3.8  3.9  4.0  4.0
4.1  4.1  4.1  4.2  4.2  4.4  4.4  4.4  4.5  4.6  4.6  4.6  4.6  4.6  4.7  4.7
4.8  4.8  4.9  5.0  5.0  5.1  5.1  5.1  5.2  5.3  5.3  5.3  5.3  5.3  5.4  5.5
5.5  5.5  5.5  5.6  5.6  5.7  5.7  5.8  5.9  5.9  5.9  6.0  6.0  6.0  6.1  6.2
6.2  6.4  6.4  6.5  6.5  6.6  6.8  6.8  6.8  6.9  7.0  7.0  7.1  7.2  7.2  7.2
7.3  7.6  7.7  7.7  7.7  7.8  7.9  7.9  8.2  8.3  8.4  8.5  8.7  8.9  9.0  9.0
9.3  9.3  9.6  10.0
```

Parte **fracionária**: folhas. Parte **inteira**: ramos.

Gráfico de ramos-e-folhas

> stem(notas)

```
The decimal point is at the |
 1 | 8
 2 | 56
 3 | 14444556789
 4 | 001112244456666677889
 5 | 001112333334555566778999
 6 | 000122445568889
 7 | 00122236777899
 8 | 234579
 9 | 00336
10 | 0
```

Fornecer uma ideia sobre a distribuição.

> stem(notas, density = 2)

```
The decimal point is at the |
 1 | 8
 2 |
 2 | 56
 3 | 14444
 3 | 556789
 4 | 0011122444
 4 | 56666677889
 5 | 001112333334
 5 | 555566778999
 6 | 00012244
 6 | 5568889
 7 | 0012223
 7 | 6777899
 8 | 234
 8 | 579
 9 | 0033
 9 | 6
10 | 0
```