

Introdução ao R

Anderson Castro Soares de Oliveira

Estatística Descritiva

- Para iniciar uma análise descritiva é importante verificar o tipo de variáveis do conjunto de dados.

Estatística Descritiva

- Para iniciar uma análise descritiva é importante verificar o tipo de variáveis do conjunto de dados.
- `summary` para uma analise preliminar, retorna:

Estatística Descritiva

- Para iniciar uma análise descritiva é importante verificar o tipo de variáveis do conjunto de dados.
- `summary` para uma análise preliminar, retorna:
 - Variáveis qualitativas - frequências absolutas;

Estatística Descritiva

- Para iniciar uma análise descritiva é importante verificar o tipo de variáveis do conjunto de dados.
- `summary` para uma analise preliminar, retorna:
 - Variáveis qualitativas - frequências absolutas;
 - **Variáveis quantitativas - menor valor, primeiro quartil, mediana, média, terceiro quartil e maior valor.**

- Variáveis Qualitativas -table

Tabelas

- Variáveis Qualitativas -`table`
- Variáveis Quantitativas Discretas -`table`

Tabelas

- Variáveis Qualitativas -table
- Variáveis Quantitativas Discretas -table
- Variáveis Quantitativas Contínuas - fdt pacote fdt
`fdt(x, k, start, end, h, breaks=c("Sturges",
"Scott", "FD"))`
em que:

Tabelas

- Variáveis Qualitativas -table
- Variáveis Quantitativas Discretas -table
- Variáveis Quantitativas Contínuas - fdt **pacote fdt**
`fdt(x, k, start, end, h, breaks=c("Sturges",
"Scott", "FD"))`
em que:
 - x - são os dados que devem agrupados;

Tabelas

- Variáveis Qualitativas -table
- Variáveis Quantitativas Discretas -table
- Variáveis Quantitativas Contínuas - fdt **pacote fdt**
`fdt(x, k, start, end, h, breaks=c("Sturges",
"Scott", "FD"))`
em que:
 - x - são os dados que devem agrupados;
 - k - numero de intervalos de classe;

Tabelas

- Variáveis Qualitativas -table
- Variáveis Quantitativas Discretas -table
- Variáveis Quantitativas Contínuas - fdt pacote fdt

```
fdt(x, k, start, end, h, breaks=c("Sturges",
  "Scott", "FD"))
```

em que:
 - x - são os dados que devem agrupados;
 - k - numero de intervalos de classe;
 - start - limite inferior da primeira classe;

Tabelas

- Variáveis Qualitativas -table
- Variáveis Quantitativas Discretas -table
- Variáveis Quantitativas Contínuas - fdt pacote fdt

```
fdt(x, k, start, end, h, breaks=c("Sturges",
  "Scott", "FD"))
```

em que:
 - x - são os dados que devem agrupados;
 - k - numero de intervalos de classe;
 - start - limite inferior da primeira classe;
 - end - limite superior da ultima classe;

Tabelas

- Variáveis Qualitativas - `table`
- Variáveis Quantitativas Discretas - `table`
- Variáveis Quantitativas Contínuas - `fdt` pacote `fdth`
`fdt(x, k, start, end, h, breaks=c("Sturges", "Scott", "FD"))`
em que:
 - x - são os dados que devem agrupados;
 - k - numero de intervalos de classe;
 - start - limite inferior da primeira classe;
 - end - limite superior da ultima classe;
 - h - **amplitude da classe;**

Tabelas

- Variáveis Qualitativas - `table`
- Variáveis Quantitativas Discretas - `table`
- Variáveis Quantitativas Contínuas - `fdt` pacote `fdth`
`fdt(x, k, start, end, h, breaks=c("Sturges", "Scott", "FD"))`
em que:
 - x - são os dados que devem agrupados;
 - k - numero de intervalos de classe;
 - start - limite inferior da primeira classe;
 - end - limite superior da ultima classe;
 - h - amplitude da classe;
 - **breaks** - caso não seja definido k, start, end e h, pode-se utilizar um método para isso.

Tabelas

```
##Distribuição de frequência para variável Grau de Instrução.
> fa=table(GI) ##frequencia absoluta
> fa
GI
fundamental      medio      superior
      7           14           8
> fr=fa/sum(fa) ##frequencia relativa
> fr
GI
fundamental      medio      superior
0.2413793  0.4827586  0.2758621
> fp=100*fr ##fp=frequencia percentual
> fp
GI
fundamental      medio      superior
24.13793  48.27586  27.58621
> dist=cbind(fa,fr,fp) ##distribuição de frequências
> dist
      fa        fr        fp
fundamental 7 0.2413793 24.13793
medio      14 0.4827586 48.27586
superior     8 0.2758621 27.58621
```

Tabelas

```
> fa=table(SEXO,AT) ##frequencia absoluta
> fa
      AT
SEXO Nao Sim
  F    9    8
  M    9    3
> fr=fa/sum(fa) ##frequencia relativ
> fr
      AT
SEXO      Nao      Sim
  F 0.3103448 0.2758621
  M 0.3103448 0.1034483
> fp=100*fr ##fp=frequencia percentual
> fp
      AT
SEXO      Nao      Sim
  F 31.03448 27.58621
  M 31.03448 10.34483
```

Tabelas

```
> fa=table(NFD) ##frequencia absoluta
> fa
NFD
 2  3  4  5
10 8  6  5
> fr=fa/sum(fa) ##frequencia relativa
> fr
NFD
      2          3          4          5
0.3448276 0.2758621 0.2068966 0.1724138
> fp=100*fr ##fp=frequencia percentual
> fp
NFD
      2          3          4          5
34.48276 27.58621 20.68966 17.24138
> dist=cbind(fa,fr,fp) ##distribuição de frequências
> dist
   fa        fr        fp
2 10 0.3448276 34.48276
3  8 0.2758621 27.58621
4  6 0.2068966 20.68966
5  5 0.1724138 17.24138
```

Tabelas

```
> require(fdth)
> x=fdt(IDADE)
> x
  Class limits  f    rf rf(%)  cf  cf(%)
  [19.8,25.1)  10  0.34 34.48 10  34.48
  [25.1,30.4)   8  0.28 27.59 18  62.07
  [30.4,35.7)   2  0.07  6.90 20  68.97
  [35.7,40.9)   3  0.10 10.34 23  79.31
  [40.9,46.2)   2  0.07  6.90 25  86.21
  [46.2,51.5)   4  0.14 13.79 29 100.00
> x1=fdt(IDADE, k=4)
> x1
  Class limits  f    rf rf(%)  cf  cf(%)
  [19.8,27.7)  14  0.48 48.28 14  48.28
  [27.7,35.7)   6  0.21 20.69 20  68.97
  [35.7,43.6)   5  0.17 17.24 25  86.21
  [43.6,51.5)   4  0.14 13.79 29 100.00
```

Tabelas

```
> x2=fdt (IDADE, start=20, end=50, h=5)
> x2
  Class limits  f    rf  rf(%)  cf  cf(%)
  [20,25)    9  0.31  31.03   9 31.03
  [25,30)    8  0.28  27.59  17 58.62
  [30,35)    1  0.03  3.45   18 62.07
  [35,40)    5  0.17  17.24  23 79.31
  [40,45)    2  0.07  6.90   25 86.21
  [45,50)    3  0.10  10.34  28 96.55
> x3=fdt (IDADE, breaks="Scott")
> x3
  Class limits  f    rf  rf(%)  cf  cf(%)
  [19.8,30.4) 18  0.62  62.07  18 62.07
  [30.4,40.9)  5  0.17  17.24  23 79.31
  [40.9,51.5)  6  0.21  20.69  29 100.00
```

Gráficos

- **plot**

Gráficos

- plot
 - Variáveis Qualitativas -gráfico de barras

Gráficos

- `plot`
 - Variáveis Qualitativas -gráfico de barras
 - Variáveis Quantitativas - gráfico de dispersão

Gráficos

- `plot`
 - Variáveis Qualitativas -gráfico de barras
 - Variáveis Quantitativas - gráfico de dispersão
- `barplot` - gráfico de barras

Gráficos

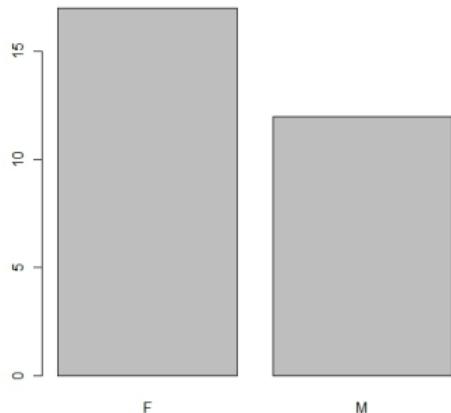
- `plot`
 - Variáveis Qualitativas -gráfico de barras
 - Variáveis Quantitativas - gráfico de dispersão
- `barplot` - gráfico de barras
- `pie` - gráfico de pizza

Gráficos

- `plot`
 - Variáveis Qualitativas -gráfico de barras
 - Variáveis Quantitativas - gráfico de dispersão
- `barplot` - gráfico de barras
- `pie` - gráfico de pizza
- `hist` - **histograma**.

Gráficos

```
##Grafico de barras  
> fa=table(SEXO) #frequênci a absoluta  
> barplot(fa) #plota gráfico.  
> plot(SEXO) ##plota gráfico
```



Gráficos

- `main` para adicionar título;

Gráficos

- `main` para adicionar título;
- `xlab` **titulo para o eixo x;**

Gráficos

- `main` para adicionar título;
- `xlab` título para o eixo x;
- `ylab` título para o eixo y;

Gráficos

- `main` para adicionar título;
- `xlab` título para o eixo x;
- `ylab` título para o eixo y;
- `xlim` delimita os valores de x;

Gráficos

- `main` para adicionar título;
- `xlab` título para o eixo x;
- `ylab` título para o eixo y;
- `xlim` delimita os valores de x;
- `ylim` delimita os valores de y;

Gráficos

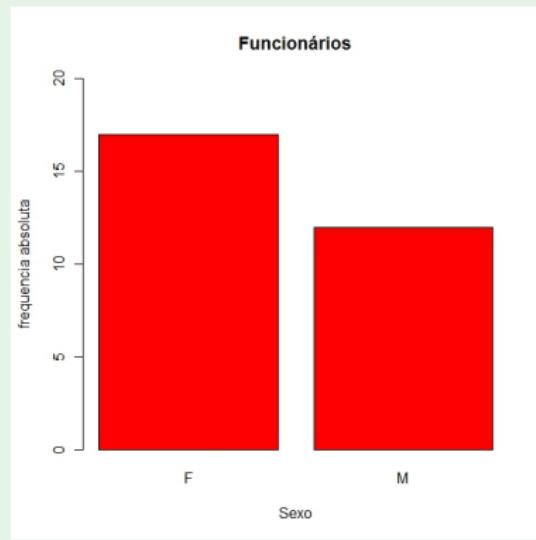
- `main` para adicionar título;
- `xlab` título para o eixo x;
- `ylab` título para o eixo y;
- `xlim` delimita os valores de x;
- `ylim` delimita os valores de y;
- `col` para definir cor;

Gráficos

- `main` para adicionar título;
- `xlab` título para o eixo x;
- `ylab` título para o eixo y;
- `xlim` delimita os valores de x;
- `ylim` delimita os valores de y;
- `col` para definir cor;
- `horiz` para definir se as barras são horizontais ou verticais.

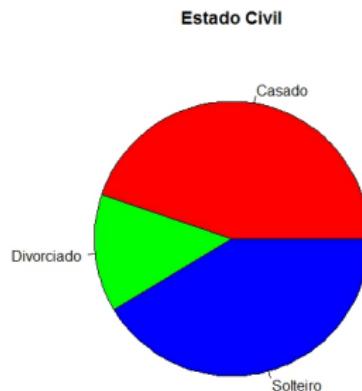
Gráficos

```
> plot(SEXO, main="Funcionários", xlab="Sexo",  
+ ylab="frequencia absoluta", ylim=c(0,20), col="red")
```



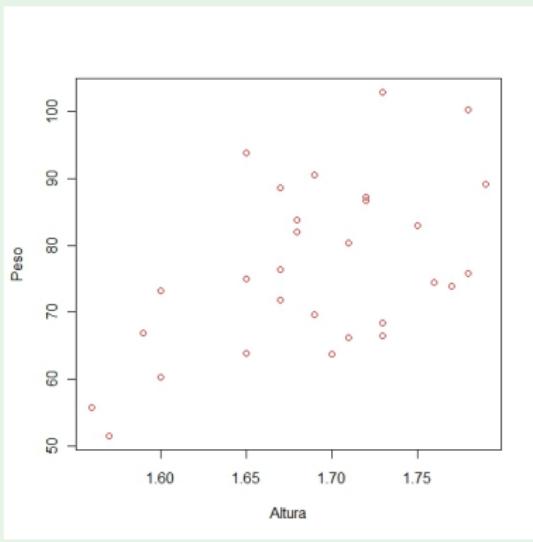
Gráficos

```
> fa=table(EC)
> fr=fa/sum(fa)
> n=length(fr) ##contar quantos classes
> pie(fr,main="Estado Civil",col=rainbow(n))
```



Gráficos

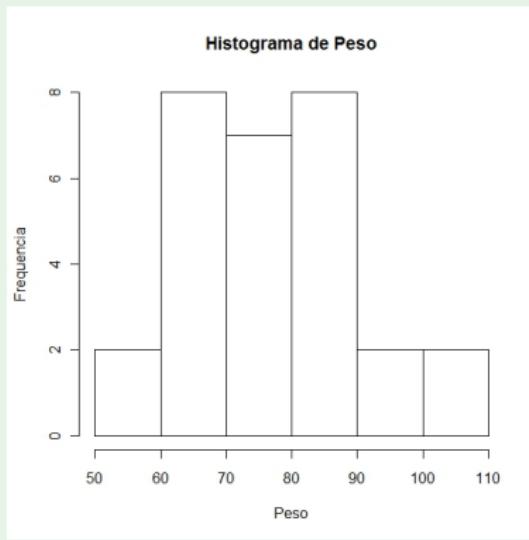
```
> plot (A, P, xlab="Altura", ylab="Peso", col="red")
```



Gráficos

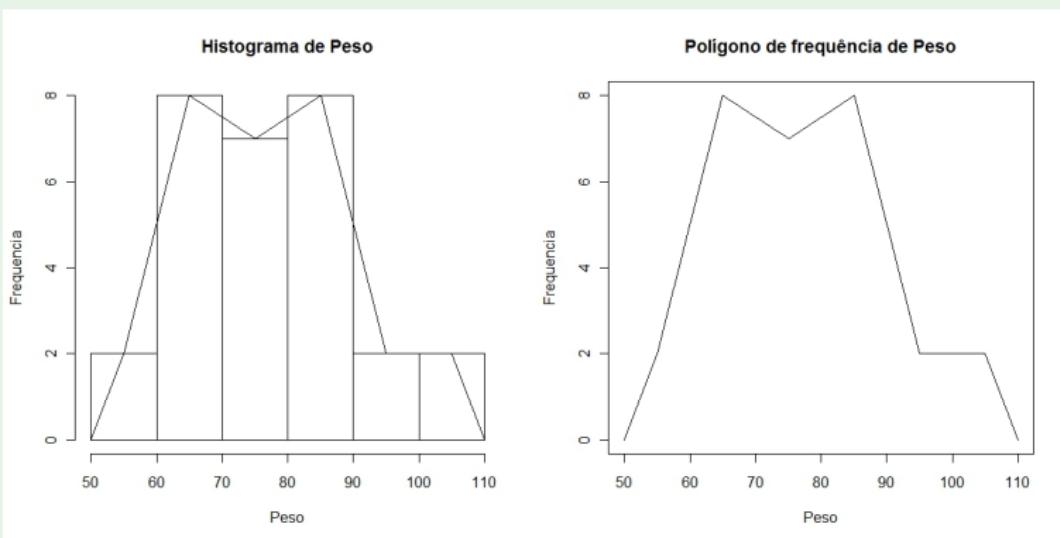
#histogram para variável peso.

```
hist(P, main="Histograma de Peso", xlab="Peso", ylab="")
```



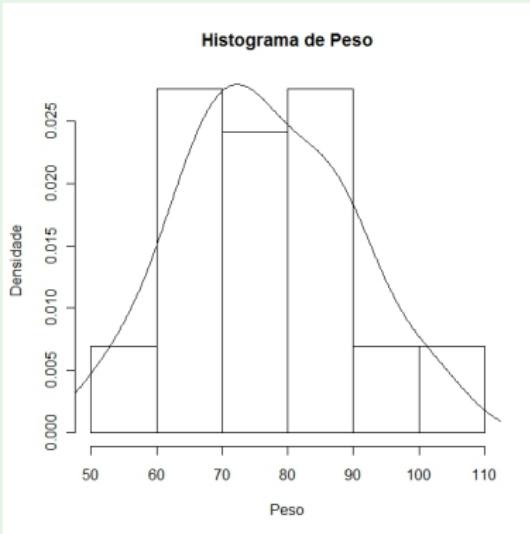
Gráficos

```
h=hist (P, main="Histograma de Peso", xlab="Peso", ylab
##polígono de frequêcia com histograma
lines(c(min(h$breaks), h$mids, max(h$breaks)), c(0,
##polígono de frequêcia
> plot(c(min(h$breaks), h$mids, max(h$breaks)), c(0
+ type = "l", main="Polígono de frequêcia de Peso",
```



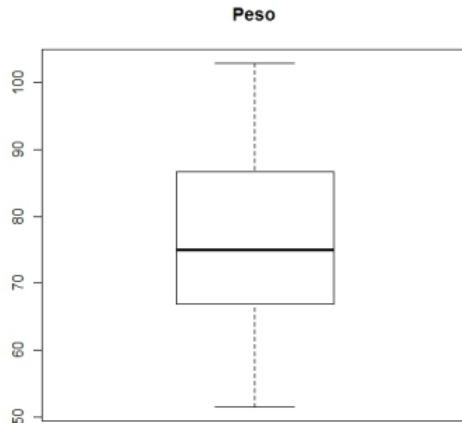
Gráficos

```
##histograma pela densidade de frequêcia  
hist(P, freq=FALSE)  
h1=density(P) ##obtendo a densidade dos dados  
lines(h1) ##adicinar um gráfico de linhas
```



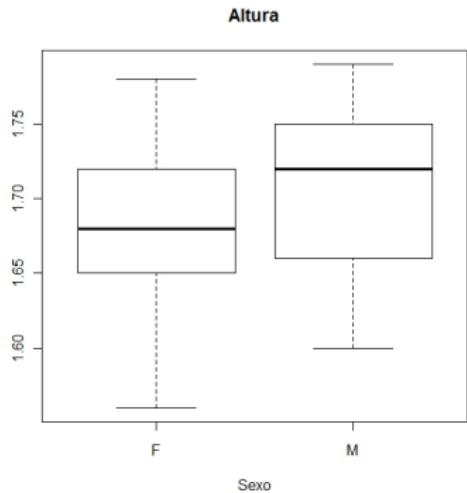
Gráficos

#Boxplot para variável peso.
> boxplot(P, main="Peso")



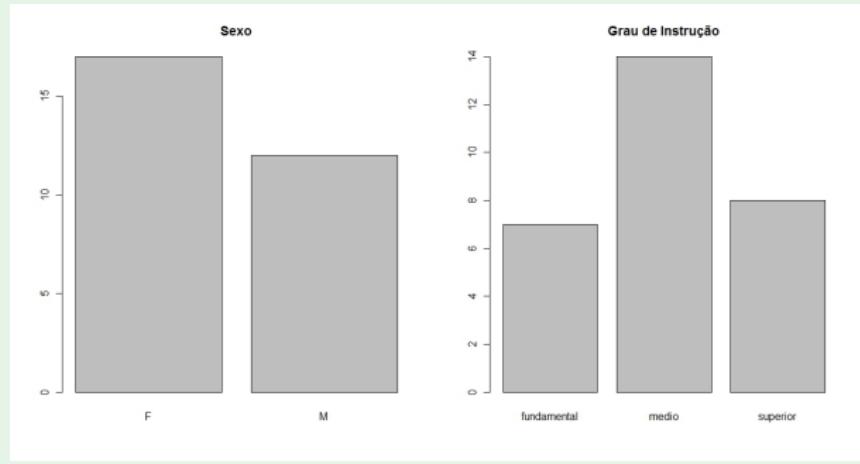
Gráficos

#Boxplot para variável altura dentro de cada sexo.
> boxplot (A~SEXO, main="Altura", xlab="Sexo")



Dividir Janela de Gráficos

```
> par(mfrow=c(1, 2)) ##uma linha e duas colunas
> plot(SEXO, main="Sexo")
> plot(GI, main="Grau de Instrução")
```



Medidas de Posição

- média - mean

Medidas de Posição

- média - mean
- mediana - median

Medidas de Posição

- média - `mean`
- mediana - `median`
- moda - pacote `modeest`.

Medidas de Posição

- média - `mean`
- mediana - `median`
- moda - pacote `modeest`.
 - **Variável discreta** - `mfv`

Medidas de Posição

- média - `mean`
- mediana - `median`
- moda - pacote `modeest`.
 - Variável discreta - `mfv`
 - Variável contínua por diferentes métodos - `mlv`

Medidas de Posição

- média - `mean`
- mediana - `median`
- moda - pacote `modeest`.
 - Variável discreta - `mfv`
 - Variável contínua por diferentes métodos - `mlv`
- Para obter medidas por grupos - `tapply`.

Medidas de Posição

```
> ##Média de Peso
> mean(P)
[1] 76.59655
> ##Média de Altura por Sexo
> tapply(A, SEXO, mean)
      F          M
1.678824 1.705000
> ##Mediana de Peso
> median(P)
[1] 75
> ##Mediana de Altura por Sexo
> tapply(A, SEXO, median)
      F          M
1.68 1.72
```

Medidas de Posição

```
> require(modeest)
> ##Moda de Idade
> mfv(IDADE)
[1] 27
> ##Moda de Idade por Sexo
> tapply(IDADE, SEXO, mfv)
$F
[1] 20 27
$M
[1] 22 39 49
> ##moda de Peso
> mlv(P)
```

Mode (most likely value): 69.71333

Bickel's modal skewness: 0.3103448

Call: mlv.default(x = P)

Warning message:

In mlv.default(P) :

non-numeric 'method' in 'missing' Data are assumed to be

Medidas de Dispersão

- **Amplitude** - `range` combinado com `diff.`

Medidas de Dispersão

- **Amplitude** - `range` combinado com `diff.`
- **Variância** - `var`

Medidas de Dispersão

- **Amplitude** - `range` combinado com `diff.`
- **Variância** - `var`
- **Desvio padrão** - `sd.`

Medidas de Dispersão

- **Amplitude** - `range` combinado com `diff.`
- **Variância** - `var`
- **Desvio padrão** - `sd.`
- **moda** - pacote `modeest`.

Medidas de Dispersão

```
> ##Amplitude de Altura
> range(A)
[1] 1.56 1.79
f(range(A))
[1] 0.23
> X=tapply(A, SEXO, range)
> X
$F
[1] 1.56 1.78

$M
[1] 1.60 1.79

> diff(X$F) ##Amplitude Altura Mulheres
[1] 0.22
> diff(X$M) ##Amplitude Altura Homens
[1] 0.19
```



Medidas de Dispersão

```
> ##Variância de Altura
> var(A)
[1] 0.004010591
> ##Variância de Altura por Sexo
> tapply(A, SEXO, var)
      F          M
0.003886029 0.004118182
> ##Desvio Padrão de Altura
> sd(A)
[1] 0.06332923
> ##Desvio Padrão de Altura por Sexo
> tapply(A, SEXO, sd)
      F          M
0.06233803 0.06417306
```