

# Métodos Estatísticos Básicos

## Aula 3 - Medidas de Tendência Central e de Posição

Regis A. Ely

Departamento de Economia  
Universidade Federal de Pelotas

06 de julho de 2020

# Conteúdo

## Medidas de tendência central

Média aritmética

Média geométrica

Média harmônica

Moda

Mediana

## Medidas de posição

Quartil

Decil

Percentil

## Exemplo no R

Potência de veículos e medidas de posição

# Medidas de tendência central

Medidas de tendência central são estatísticas que representam o ponto central de um conjunto de dados

- **Média:** os tipos mais comuns são a média *aritmética*, *harmônica* e *geométrica*
- **Mediana:** valor que separa a metade maior e a metade menor de um conjunto de dados
- **Moda:** valor mais frequente de um conjunto de dados

# Média aritmética simples

**Média aritmética:** razão entre a soma dos valores e o número de observações de um conjunto de dados

- Para dados brutos, calculamos a *média aritmética simples*

- $\bar{X} = \frac{\sum_{i=1}^n X_i}{n}$ , onde  $n$  é o número de observações

**Exemplo no R:** média aritmética de um conjunto com 7 valores

```
x <- c(10, 14, 13, 15, 16, 18, 12)
mean(x)
```

```
[1] 14
```

# Desvio em relação à média

**Desvio em relação à média:** é a diferença entre um valor específico dos dados e a média aritmética do conjunto de todos os dados

- $d_i = X_i - \bar{X}$

**Exemplo no R:** desvios em relação à média do exemplo anterior

```
x - mean(x)
```

```
[1] -4  0 -1  1  2  4 -2
```

# Média aritmética ponderada

**Média aritmética ponderada:** cada observação entra com um peso diferente no cálculo da média

- Para dados agrupados em uma tabela de frequência, calculamos a *média aritmética ponderada*<sup>1</sup>
- $\bar{X} = \frac{\sum_{i=1}^n X_i f_i}{\sum_{i=1}^n f_i}$ , onde  $f_i$  é o peso da observação  $i$

**Exemplo no R:** dados utilizados na Aula 1 estão agrupados por classes

```
library(HistData)
DrinksWages
```

---

<sup>1</sup>Se os dados estiverem agrupados em intervalos de classe,  $X_i$  sempre será o ponto médio da classe.

# Média aritmética ponderada

A média do salário semanal de todos os indivíduos é obtida ponderando o salário (`wage`) pelo número de pessoas em cada profissão (`n`)

- A função `weighted.mean` faz isso no R<sup>2</sup>:

```
library(tidyverse)
DrinksWages %>%
  summarise("Salário Médio" = weighted.mean(wage, n))
```

```
Salário Médio
1      24.59782
```

---

<sup>2</sup>Para esse cálculo utilizaremos o operador `%>%`, que é carregado com o pacote `tidyverse`. O livro escrito pelo criador deste pacote pode ser obtido aqui.

# Propriedades da média aritmética

A média aritmética sempre respeita as seguintes propriedades<sup>3</sup>:

1. A soma algébrica dos desvios em relação à média é nula:

$$\bullet \sum_{i=1}^n d_i = \sum_{i=1}^n (X_i - \bar{X}) = \sum_{i=1}^n X_i - n \cdot \bar{X} = 0$$

2. Somando ou subtraindo uma constante  $c$  a todos os elementos do conjunto de dados, a média também aumentará em  $c$ :

$$\bullet \frac{\sum_{i=1}^n (X_i + c)}{n} = \frac{\sum_{i=1}^n X_i}{n} + \frac{n \cdot c}{n} = \bar{X} + c$$

3. Multiplicando (ou dividindo) todos os valores por uma constante  $c$ , a média será multiplicada (ou dividida) por  $c$ :

$$\bullet \frac{\sum_{i=1}^n (c \cdot X_i)}{n} = \frac{c \sum_{i=1}^n X_i}{n} = c \cdot \bar{X}$$

---

<sup>3</sup>A média aritmética ponderada também respeita estas propriedades, porém deve-se sempre multiplicar as expressões pelos pesos  $f_i$ .



# Propriedades da média aritmética

**Exemplo no R:** testando as propriedades da média aritmética

```
## Soma dos desvios em relação à média  
sum(mtcars$hp - mean(mtcars$hp))
```

```
[1] 0
```

```
## Média de hp+10 é igual à média de hp mais 10?  
all.equal(mean(mtcars$hp + 10), mean(mtcars$hp) + 10)
```

```
[1] TRUE
```

```
## Média de hp*10 é igual à média de hp vezes 10?  
all.equal(mean(mtcars$hp * 10), mean(mtcars$hp) * 10)
```

```
[1] TRUE
```

# Média geométrica simples

**Média geométrica:** é a raiz n-ésima do produto dos dados

- $\bar{X}_g = \sqrt[n]{\prod_{i=1}^n X_i}$ , onde  $\prod_{i=1}^n X_i = X_1 \times X_2 \times \dots \times X_n$

O logaritmo da média geométrica é igual à média aritmética dos logaritmos:

- $\log \bar{X}_g = \frac{1}{n} \sum_{i=1}^n \log X_i$

Logo, a média geométrica é uma média aritmética suavizada:

- É muito utilizada em finanças, para calcular médias de taxas de juros

# Média geométrica ponderada

**Média geométrica ponderada:** cada observação tem um peso diferente no cálculo (útil para dados em tabela de frequência)

$$\bullet \bar{X}_g = \sqrt[n]{\prod_{i=1}^n X_i^{f_i}} = \sqrt[n]{X_1^{f_1} \times X_2^{f_2} \times \dots \times X_n^{f_n}}$$

**Exemplo no R:** média geométrica simples da taxa Selic em 2020<sup>4</sup>

```
library(lubridate) # Para lidar com datas
library(psych) # Para calcular média geométrica
url_bcb <- "http://api.bcb.gov.br/dados/serie/bcdata.sgs.1178/dados?formato=csv"
selic <- read_csv2(url_bcb) %>% # Ler dados da taxa Selic anualizada
  mutate(data = dmy(data)) %>% # Criar variável data com padrão dia/mês/ano
  filter(data >= "2020-01-01") # Filtrar ano de 2020 em diante
geometric.mean(selic$valor) # Calcular média geométrica simples da taxa Selic
```

```
[1] 3.514823
```

---

<sup>4</sup>Ao invés de usar a função `geometric.mean`, pode-se obter o mesmo resultado com `prod(x)^(1/length(x))`

# Propriedades da média geométrica

A média geométrica sempre respeita as seguintes propriedades:

1. A média geométrica é sempre menor ou igual a média aritmética, sendo igual apenas no caso em que todas as observações tem o mesmo valor
2. O produtório dos dados permanece inalterado se todas as observações forem substituídas pelo valor da média geométrica
3. A média geométrica da razão das observações em duas séries é igual à razão de suas médias geométricas
4. A média geométrica da multiplicação de duas séries é igual a multiplicação de suas respectivas médias geométricas

# Propriedades da média geométrica

**Exemplo no R:** propriedades da média geométrica para dados fictícios

```
x <- c(1, 4, 9, 12, 14, 19)
y <- c(2, 4, 7, 11, 20, 32)
geometric.mean(x) < mean(x)
```

```
[1] TRUE
```

```
all.equal(prod(x), prod(rep(geometric.mean(x), length(x))))
```

```
[1] TRUE
```

```
all.equal(geometric.mean(x/y), geometric.mean(x)/geometric.mean(y))
```

```
[1] TRUE
```

```
all.equal(geometric.mean(x*y), geometric.mean(x)*geometric.mean(y))
```

```
[1] TRUE
```

# Média harmônica simples

**Média harmônica:** É o inverso da média aritmética dos inversos de cada observação

- $\bar{X}_h = \left(\frac{1}{n} \cdot \sum_{i=1}^n X_i^{-1}\right)^{-1} = \frac{n}{\sum_{i=1}^n \frac{1}{X_i}}$
- Algumas utilizações comuns da média harmônica incluem:
  1. Na física, com dados de velocidade e tempo
  2. No cálculo de scores padronizados de concursos
  3. Em finanças, para calcular médias de razões contábeis

**Exemplo no R:** média harmônica simples da variável  $x$ , criada no exemplo anterior

```
harmonic.mean(x) # ou 1/mean(1/x)
```

```
[1] 3.8253
```

# Média harmônica ponderada e propriedades

Se os dados estiverem agrupados por distribuição de frequência, deve-se utilizar a *média harmônica ponderada*:

- $$\bar{X}_h = \frac{\sum_{i=1}^n f_i}{\sum_{i=1}^n \frac{f_i}{X_i}}$$

A média harmônica é sempre menor ou igual a geométrica, valendo a igualdade apenas se todas observações forem iguais. Podemos testar isso no R:

```
harmonic.mean(x) < geometric.mean(x)
```

```
[1] TRUE
```

# Moda simples

**Moda:** valor que ocorre com maior frequência em uma série de dados

- Se nenhum valor ocorre mais vezes do que outro, a série é amodal
- Se há valores mais frequentes que se repetem o mesmo número de vezes, a série tem mais de um valor modal
- A média aritmética possui maior estabilidade que a moda

**Dados agrupados:** com dados agrupados em frequência simples, é possível determinar a moda apenas olhando o dado com a maior frequência. Para dados agrupados em intervalos de classe, teremos mais de uma alternativa



# Moda simples

**Exemplo no R:** Na base de dados `mtcars`, os dados não estão agrupados em frequências, mas para calcular a moda do número de carburadores, podemos utilizar a função `table` para agrupar os dados e então verificar os valores com maior frequência

```
table(mtcars$carb)
```

```
1  2  3  4  6  8  
7 10  3 10  1  1
```

Pode-se ver que esta é uma série *bimodal*, sendo que o número de carburadores que aparece com mais frequência é 2 e 4

# Moda simples

**Exemplo no R:** Na base de dados `DrinksWages`, os dados já estão agrupados em frequências, de acordo com as profissões dos indivíduos. Para calcular a moda dos salários, basta encontrar a linha com o maior valor da variável `n`

```
DrinksWages %>% filter(n == max(DrinksWages$n))
```

```
  class          trade sober drinks wage   n
1  A general labourer    71    85 18.5 156
```

A profissão mais frequente é a de *general labourer*, com salário semanal de 18.5 xelins

# Moda com intervalos de classe

Quando os dados estão agrupados em intervalos de classe, a classe com a maior frequência é a classe modal. A moda será um valor compreendido entre os limites da classe modal. Veremos duas alternativas para calcular a moda:

1. **Moda bruta:**  $M_o = \left(\frac{l^*+L^*}{2}\right)$ , onde  $l^*$  é o limite inferior da classe modal e  $L^*$  o limite superior da classe modal
2. **Moda de Czuber:**  $M_c = l^* + \left(\frac{d_1}{d_1+d_2}\right).h^*$ , onde  $d_1$  é a frequência da classe modal menos a frequência da classe anterior a modal;  $d_2$  é a frequência da classe modal menos a frequência da classe posterior a modal; e  $h^*$  é a amplitude da classe modal

## Moda com intervalos de classe

Vamos calcular a moda bruta e a moda de Czuber utilizando o exemplo da Aula 2:

Idade	Frequência
21  – 23	4
23  – 25	7
25  – 27	5

A classe modal, que ocorre com maior frequência, é 23 |– 25. Assim:

- $M_o = \frac{23+25}{2} = 24$
- $M_c = 23 + \frac{(7-4)}{(7-4)+(7-5)} \times 2 = 24,2$

# Mediana simples

**Mediana:** é o valor que separa uma série (disposta em ordem crescente ou decrescente) em duas partes com o mesmo número de elementos

- Se a série tiver número ímpar de termos, a mediana será o elemento  $\frac{n+1}{2}$
- Se a série tiver número par de termos, a mediana será a média dos elementos  $\frac{n}{2}$  e  $\frac{n}{2} + 1$
- Útil quando há valores extremos nos dados. *Ex: salário*

Considere os dados:  $\{1, 3, 0, 0, 2, 4, 1, 2, 5\}$ . Devemos:

1. Colocar a série em ordem crescente  $\{0, 0, 1, 1, 2, 2, 3, 4, 5\}$
2. Como existem 9 elementos, a mediana será o elemento de número  $\frac{n+1}{2} = \frac{10}{2} = 5$ . Assim,  $M_e = 2$

# Mediana simples

Para dados agrupados em frequência simples, em ordem crescente:

- Se o somatório das frequências for ímpar, a mediana será o elemento  $\frac{\sum_{i=1}^n f_{i+1}}{2}$
- Se o somatório das frequências for par, a mediana será a média dos termos  $\frac{\sum_{i=1}^n f_i}{2}$  e  $\frac{\sum_{i=1}^n f_i}{2} + 1$

**Exemplo no R:** mediana simples do número de carburadores

```
median(mtcars$carb)
```

```
[1] 2
```

# Mediana com intervalos de classe

Para calcularmos a mediana de dados agrupados em intervalos de classe, devemos:

1. Determinar as frequências acumuladas,
2. Calcular  $\sum_{i=1}^n fi/2$ ,
3. Marcar a classe correspondente a frequência acumulada imediatamente superior a  $\sum_{i=1}^n fi/2$ . Essa será a classe mediana,
4. Calcular  $M_e = l^* + \frac{[(\sum_{i=1}^n fi/2 - FAA) \cdot h^*]}{f^*}$ , onde  $l^*$  é o limite inferior da classe mediana,  $FAA$  é a frequência acumulada da classe anterior à classe mediana,  $f^*$  é a frequência simples da classe mediana, e  $h^*$  é a amplitude do intervalo da classe mediana

## Mediana com intervalos de classe

Considere os seguintes dados agrupados em intervalos de classe:

Classes	$f_i$	$F_i$
50 ┆ 54	4	4
54 ┆ 58	9	13
58 ┆ 62	11	24
62 ┆ 66	8	32
66 ┆ 70	5	37
70 ┆ 74	3	40
Total	40	



# Mediana com intervalos de classe

Vamos aplicar os passos 1 a 4 no exemplo anterior:

1. As frequências acumuladas são dadas na coluna  $F_i$

2.  $\frac{\sum f_i}{2} = 20$

3. *Classe mediana*: 58 † 62

4. Temos  $l^* = 58$ ,  $FAA = 13$ ,  $f^* = 11$ ,  $h^* = 4$ , logo,  
 $M_e = 58 + \frac{[(20-13) \times 4]}{11} = 58 + \frac{28}{11} = 60,54$

- Assim, a mediana é 60,54

# Separatrizes

Medidas de posição são estatísticas que representam a tendência de concentração de um conjunto de dados ao redor de certos pontos

As medidas de posição mais usuais são chamadas *separatrizes* e incluem<sup>5</sup>:

- **Quartil:** são os valores que dividem os dados em quatro partes
  - São necessários 3 quartis para dividir os dados em quatro partes
- **Decil:** são os valores que dividem a série em dez partes
  - São necessários 9 decis para dividir os dados em dez partes
- **Percentil:** são os valores que separam a série em cem partes
  - São necessários 99 percentis para dividir os dados em cem partes

---

<sup>5</sup>Há uma equivalência entre as medidas de posição:  $P_{50} = D_5 = Q_2 = M_e$

## Quartil simples

Considere o seguinte conjunto de dados: {5, 2, 6, 9, 10, 13, 15}

- Para calcular os quartis, devemos:
  1. Ordenar a série {2, 5, 6, 9, 10, 13, 15}
  2. Calcular a mediana, que será o segundo quartil,  $M_e = Q_2 = 9$
  3. Dividir a série em dois grupos {2, 5, 6} e {10, 13, 15}<sup>6</sup>
  4. Calcular os outros quartis como sendo as medianas desses dois grupos,  $Q_1 = 5$  e  $Q_3 = 13$

**Exemplo no R:** quartis da potência dos veículos na base mtcars

```
quantile(mtcars$hp)
```

0%	25%	50%	75%	100%
52.0	96.5	123.0	180.0	335.0

<sup>6</sup>A divisão é sempre feita com base no valor da mediana

# Quartil com dados agrupados

- Se os dados forem *agrupados sem intervalos de classe*, utilizamos  $\frac{\sum_{i=1}^n f_i}{2}$  e  $\frac{\sum_{i=1}^n f_i}{2} + 1$  para calcular as posições dos quartis
- Se os dados forem *agrupados com intervalos de classe*, utilizamos a mesma fórmula da mediana para calcular os quartis, entretanto substituímos  $\frac{\sum_{i=1}^n f_i}{2}$  por  $k \frac{\sum_{i=1}^n f_i}{4}$ , sendo k o número do quartil:
  - $Q1 = l^* + \frac{[(\frac{\sum f_i}{4} - FAA).h^*]}{f^*}$
  - $Q2 = l^* + \frac{[(2\frac{\sum f_i}{4} - FAA).h^*]}{f^*}$
  - $Q3 = l^* + \frac{[(3\frac{\sum f_i}{4} - FAA).h^*]}{f^*}$

## Quartil com intervalos de classe

Seguindo os passos no exemplo utilizado para a mediana:

- $\frac{\sum f_i}{2} = 20 \rightarrow$  Classe mediana: 58 † 62
- Temos  $l^* = 58$ ,  $FAA = 13$ ,  $f^* = 11$ ,  $h^* = 4$ , logo  
 $M_e = Q_2 = 58 + \frac{[(20-13) \times 4]}{11} = 60,54$
- $\frac{\sum f_i}{4} = 10 \rightarrow$  Classe mediana do 1º grupo: 54 † 58
- Logo,  $Q_1 = 54 + \frac{[(10-4) \times 4]}{9} = 56,66$
- $\frac{3 \cdot \sum f_i}{4} = 30 \rightarrow$  Classe mediana do 3º grupo: 62 † 66
- Logo,  $Q_3 = 62 + \frac{[(30-24) \times 4]}{8} = 65$

## Decil simples

O procedimento de cálculo dos decis é análogo aos quartis, porém agora o 5º decil será igual ao 2º quartil, que será igual à mediana

**Exemplo no R:** calcular o segundo, terceiro e oitavo decis da potência dos veículos na base `mtcars`

```
quantile(mtcars$hp, c(.2, .3, .8))
```

20%	30%	80%
93.4	106.2	200.0

## Decil com intervalos de classe

O procedimento de cálculo dos decis para dados com intervalos de classe é o mesmo utilizado para os quartis, basta alterar o valor de  $K$  pelo número do decil e dividir  $\sum fi$  por 10

*Exemplo:* calcular o 3º decil da tabela com intervalos de classe utilizada nos exemplos da mediana e quartil

- Como  $K=3$ , temos  $3 \cdot \frac{\sum fi}{10} = 3 \cdot \frac{40}{10} = 12$ , e a classe mediana é 54 † 58
- Logo,  $D_3 = 54 + \frac{[(12-4) \times 4]}{9} = 57,55$

# Percentil

No caso dos percentis, teremos  $P_{50} = M_e$ ,  $P_{25} = Q_1$  e  $P_{75} = Q_3$

- O cálculo é análogo ao do quartil e decil, mas utilizando  $k \cdot \frac{\sum f_i}{100}$

**Exemplo no R:** calcular os percentis 34, 67 e 95 da potência dos veículos na base de dados mtcars

```
quantile(mtcars$hp, c(0.34, 0.67, 0.95))
```

34%	67%	95%
109.54	175.00	253.55



## Exemplo no R

Podemos resumir todas as medidas de tendência central para a potência dos veículos na base `mtcars` usando um comando do R:

```
mtcars %>%  
  summarise(  
    `Média aritmética` = mean(hp),  
    `Média geométrica` = geometric.mean(hp),  
    `Média harmônica` = harmonic.mean(hp),  
    `Moda` = which.max(tabulate(mtcars$hp)),  
    `Mediana` = median(hp),  
    `Quartil 1` = quantile(hp)[2],  
    `Quartil 3` = quantile(hp)[4],  
    `Mínimo` = min(hp),  
    `Máximo` = max(hp)  
  )
```

# Potência de veículos e medidas de posição

O resultado será:

```
[,1]  
Média aritmética 146.6875  
Média geométrica 131.8837  
Média harmônica 118.2289  
Moda 110.0000  
Mediana 123.0000  
Quartil 1 96.5000  
Quartil 3 180.0000  
Mínimo 52.0000  
Máximo 335.0000
```