

## 4. Medidas de posição

2010

Também chamadas de medidas de **localização** e medidas de **tendência central** (*location* e *central tendency*).

Cada medida é um valor **representativo** dos dados  $x_1, x_2, \dots, x_n$ .

Redução (**drástica**) de  $n$  observações a **um só** valor.

#### 4.1. Média aritmética (ou **média**) (*mean*)

Notação:  $\bar{x}$  (xis barra).

(a) Dados **brutos**  $x_1, x_2, \dots, x_n$ : 
$$\bar{x} = \frac{x_1 + x_2 + \dots + x_n}{n} = \frac{1}{n} \sum_{i=1}^n x_i.$$

(b)  $k$  diferentes **valores** e **frequências**  $(x_1, f_1), \dots, (x_k, f_k)$ :

$$\bar{x} = \frac{f_1 x_1 + f_2 x_2 + \dots + f_k x_k}{f_1 + f_2 + \dots + f_k} = \frac{\sum_{j=1}^k f_j x_j}{\sum_{j=1}^k f_j} = \frac{1}{n} \sum_{j=1}^k f_j x_j.$$

(c)  $k$  diferentes valores e frequências relativas  $(x_1, f_1^*), \dots, (x_k, f_k^*)$ :

$$\bar{x} = \frac{f_1^* x_1 + f_2^* x_2 + \dots + f_k^* x_k}{f_1^* + f_2^* + \dots + f_k^*} = \frac{\sum_{j=1}^k f_j^* x_j}{\sum_{j=1}^k f_j^*} = \sum_{j=1}^k f_j^* x_j.$$

Obs. Em (b) e (c) as médias são ponderadas com pesos  $f_j$  e  $f_j^*$ ,  $j = 1, \dots, k$  (*weighted mean*).

(d)  $k$  intervalos de classe com pontos médios e frequências  $(x_1^*, f_1), \dots, (x_k^*, f_k)$ :

$$\bar{x} \cong \frac{f_1 x_1^* + f_2 x_2^* + \dots + f_k x_k^*}{f_1 + f_2 + \dots + f_k} = \frac{\sum_{j=1}^k f_j x_j^*}{\sum_{j=1}^k f_j} = \frac{1}{n} \sum_{j=1}^k f_j x_j^*.$$

# Propriedades da média

**P1.** Se  $y_i = a + x_i$ ,  $i = 1, \dots, n$ ,  $a$  um número real, então  $\bar{y} = a + \bar{x}$ .

**P2.** Se  $y_i = bx_i$ ,  $i = 1, \dots, n$ ,  $b$  um número real, então  $\bar{y} = b\bar{x}$ .



então

**P3.** Se  $y_i = a + bx_i$ ,  $i = 1, \dots, n$ ,  $a$  e  $b$  números reais, então  $\bar{y} = a + b\bar{x}$ .

então

**P4.** A média é o **centro de gravidade** (centro de massa) dos dados.

$$\sum_{i=1}^n (x_i - \bar{x}) = 0 \quad \text{ou} \quad \sum_{j=1}^k f_j (x_j - \bar{x}) = 0 \quad \text{ou} \quad \sum_{i=1}^k f_j^* (x_j - \bar{x}) = 0.$$



# Propriedades da média

P5.  $\sum_{i=1}^n (x_i - v)^2$  é minimizada se, e somente se,  $v = \bar{x}$ .

Curva de sensibilidade (CS).

$g_n$  é uma função de  $x_1, \dots, x_n$ :  $g_n(x_1, \dots, x_n)$ .

Dados:  $x_1, \dots, x_{n-1}$ ,  $g_n$ . Valor adicional:  $x$ .

Como quantificar a mudança em  $g_{n-1}(x_1, \dots, x_{n-1})$  após a inclusão de  $x$ ?

$$CS(x; x_1, \dots, x_{n-1}, g_n) = n \{ g_n(x_1, \dots, x_{n-1}, x) - g_{n-1}(x_1, \dots, x_{n-1}) \}.$$

$$\begin{aligned} CS(x; x_1, \dots, x_{n-1}, \bar{x}_n) &= n \left( \frac{x_1 + x_2 + \dots + x_{n-1} + x}{n} - \frac{x_1 + x_2 + \dots + x_{n-1}}{n-1} \right) \\ &= x - \frac{x_1 + x_2 + \dots + x_{n-1}}{n-1} = x - \bar{x}_{n-1}. \end{aligned}$$

# Exemplo. Notas de 46 alunos

```
> x = c(c(4.8, 7.8, 9.9, 7.8, 6.8, 7.6, 8.7, 3.8, 6.9, 6.4,  
3.6, 7.8, 5.2, 3.5, 8.9, 8.0, 7.0, 6.7, 3.4, 7.5, 5.1, 5.1,  
4.9, 4.4, 7.2, 9.8, 3.9, 8.6, 5.2, 6.2, 3.8, 5.2, 4.6, 5.2,  
6.6, 6.7, 8.6, 5.1, 4.1, 5.0, 5.0, 4.7, 10.0, 4.8, 6.9, 5.3))
```

```
> (xb = mean(x))
```


```
[1] 6.176087
```

```
> cs = function(x) { x - xb }
```

```
> plot(cs, 0, 10, lwd = 2, ylab  
= "CS(x)")
```

```
> segments(xb, cs(0), xb, 0, lty  
= 2)
```

```
> segments(xb, 0, 0, 0, lty = 2)
```



## 4.2. Mediana (*median*)

Dados ordenados (ou **rol**):  $x_{(1)} \leq x_{(2)} \leq \dots \leq x_{(n)}$ .

Se  $n$  é ímpar, a **posição central** é  $c = (n + 1) / 2$ .

Se  $n$  é par, as **posições centrais** são  $c = n / 2$  e  $c + 1 = n / 2 + 1$ .

$$M = x_{(c)}, \text{ se } n \text{ é ímpar;} \\ = \frac{x_{(c)} + x_{(c+1)}}{2}, \text{ se } n \text{ é par.}$$

**Obs.** Ao contrário da média, no cálculo de  $M$  utilizamos apenas a observação central (ou as duas centrais).

Exemplo. **Dados ordenados.**

```
> (xord = sort(x))
```

```
3.4  3.5  3.6  3.8  3.8  3.9  4.1  4.4  4.6  4.7  4.8  4.8  4.9  5.0  5.0
5.1  5.1  5.1  5.2  5.2  5.2  5.2  5.3  6.2  6.4  6.6  6.7  6.7  6.8  6.9
6.9  7.0  7.2  7.5  7.6  7.8  7.8  7.8  8.0  8.6  8.6  8.7  8.9  9.8  9.9
10.0
```

$n = 46$ :  $c = n / 2 = 23$ . Logo,  $M = (x_{(23)} + x_{(24)}) / 2 = (5,3 + 6,2) / 2 = 5,75$ .

Em R: `> M = (xord[23] + xord[24]) / 2`

# FOLHA DE S. PAULO

QUINTA-FEIRA, 18 DE MARÇO DE 2010 ★ C1

## folha ribeirão

88% dos municípios da  
região têm menos verde  
que a média do Estado c1

# 78 cidades têm menos verde que a média

Só 11 dos 89 municípios da região têm cobertura vegetal acima do índice de 17% apurado em levantamento feito no Estado

O que podemos afirmar sobre a **mediana**?

É **maior** do que ou **menor** do que a **média** estadual (= 17%) ?




## Curva de sensibilidade da mediana

Dados:  $n - 1$  observações,  $n - 1$  é **par**. Logo,  $c = (n - 1) / 2$ .

Observação **adicional**:  $x$  ( $n$  observações,  $n$  é **ímpar**).


$$CS(x; x_1, \dots, x_{n-1}, M_n) = n \{ M_n(x_1, \dots, x_{n-1}, x) - M_{n-1}(x_1, \dots, x_{n-1}) \}.$$

1.  $x < x_{(c)}$ :




Posição de  $x_{(c)}$  passa a ser  $(n - 1) / 2 + 1 = (n + 1) / 2$ . Logo,  $M = x_{(c)}$  ( $n$  ímpar).

2.  $x_{(c)} \leq x \leq x_{(c+1)}$ :



Posição de  $x$ :  $c + 1 = (n - 1) / 2 + 1 = (n + 1) / 2$ . Logo,  $M = x$  ( $n$  ímpar).

3.  $x > x_{(c+1)}$ :



Posição de  $x_{(c+1)}$ :  $c + 1 = (n - 1) / 2 + 1 = (n + 1) / 2$ . Logo,  $M = x_{(c+1)}$  ( $n$  ímpar).

**Exercício**. Obtenha a CS da mediana para  $n - 1$  **ímpar**.

## Curva de sensibilidade da mediana

1.  $x < x_{(c)}$ :  $CS(x; x_1, \dots, x_{n-1}, M_n) = n \{ M_n(x_1, \dots, x_{n-1}, x) - M_{n-1}(x_1, \dots, x_{n-1}) \}$

$$= n \left( x_{(c)} - \frac{x_{(c)} + x_{(c+1)}}{2} \right) = n \left( \frac{x_{(c)} - x_{(c+1)}}{2} \right).$$

2.  $x_{(c)} \leq x \leq x_{(c+1)}$ :

$$CS(x; x_1, \dots, x_{n-1}, M_n) = n \{ M_n(x_1, \dots, x_{n-1}, x) - M_{n-1}(x_1, \dots, x_{n-1}) \}$$
$$= n \left( x - \frac{x_{(c)} + x_{(c+1)}}{2} \right) = n \{ x - M_{n-1}(x_1, \dots, x_{n-1}) \}.$$

3.  $x > x_{(c+1)}$ :  $CS(x; x_1, \dots, x_{n-1}, M_n) = n \{ M_n(x_1, \dots, x_{n-1}, x) - M_{n-1}(x_1, \dots, x_{n-1}) \}$

$$= n \left( x_{(c+1)} - \frac{x_{(c)} + x_{(c+1)}}{2} \right) = n \left( \frac{x_{(c+1)} - x_{(c)}}{2} \right) = -n \left( \frac{x_{(c)} - x_{(c+1)}}{2} \right).$$

**Obs.** (a) CS é contínua.

(b) CS em (1) e (3) **não depende** de  $x$ .


## Exemplo

$n = 46$ .  $M_{n-1} = 5,75$ .  $c = 23$ .  $x_{(c)} = 5,3$  e  $x_{(c+1)} = 6,2$ .

1.  $x < x_{(c)}$ :  $CS(x) = 46 \times (5,3 - 6,2) / 2 = -41,4$ .

2.  $x_{(c)} \leq x \leq x_{(c+1)}$ :  $CS(x) = 46 \times (x - 5,75)$

3.  $x > x_{(c+1)}$ :  $CS(x) = 46 \times (6,2 - 5,3) = 41,4$ .



Obs. A mediana é mais resistente do que a média.

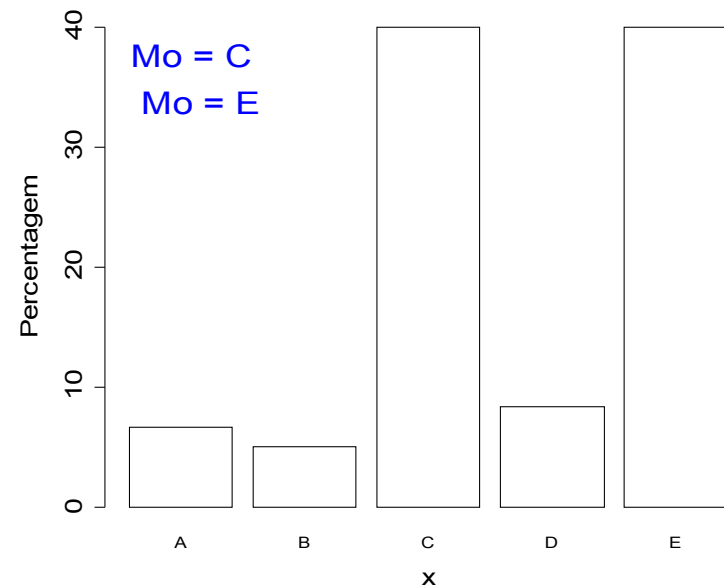


## 4.3. Moda (*mode*)

É o valor com **maior frequência**. Não necessariamente existe.


Pode haver **mais de uma** moda.

**Quantitativas**: menos utilizada do que a média e a mediana.

**Qualitativas nominais**: somente a moda pode ser calculada.



## Cálculo aproximado para variável quantitativa em classes



A moda calculada a partir dos dados  $x_1, \dots, x_n$  é igual a Mo?

A moda calculada a partir dos dados  $x_1, \dots, x_n$  pertence à classe modal?

#### 4.4. Média aparada (*trimmed mean*)

Chamada de **média winsonrizada** (*Winsorized mean*).

Média aparada de **100α%**: média aritmética dos dados após a eliminação das 100α% **menores** e das 100α% **maiores** observações,  $0 \leq \alpha < \frac{1}{2}$ .

Se  $n = 20$  e  $\alpha = 0,1$ , eliminamos as **duas** menores ( $10\% \times 20 = 2$ ) e as **duas** maiores observações, restando 16.

$$\bar{x}_{(\alpha)} = \frac{x_{(3)} + x_{(4)} + \dots + x_{(18)}}{16}.$$

**Obs.** (a) A média aparada é **mais resistente** do que a média.

(b) A mediana é um **caso particular** em que  $\alpha = \frac{1}{2} - 1 / (2n)$ .

# Exemplo. Notas de 46 alunos

```
> x = c(4.8, 7.8, 9.9, 7.8, 6.8, 7.6, 8.7, 3.8, 6.9, 6.4,  
3.6, 7.8, 5.2, 3.5, 8.9, 8.0, 7.0, 6.7, 3.4, 7.5, 5.1, 5.1,  
4.9, 4.4, 7.2, 9.8, 3.9, 8.6, 5.2, 6.2, 3.8, 5.2, 4.6, 5.2,  
6.6, 6.7, 8.6, 5.1, 4.1, 5.0, 5.0, 4.7, 10.0, 4.8, 6.9, 5.3)
```

```
> (xb = mean(x))
```

```
[1] 6.176087
```

```
> (xa5 = mean(x, trim = 0.05))
```


```
[1] 6.12619
```

```
> mean(x, trim = 0.1)
```

```
[1] 6.08421
```

```
> xa = function(alfa)  
{mapply(function(a0) mean(x,  
trim = a0), alfa)}
```

```
> plot(xa, 0.01, 0.5, xlab =  
expression(alpha), ylab =  
expression(bar(x)[alpha]),  
type = "p", pch = 20)
```



## 4.5. Média geométrica (*geometric mean*)

**Exemplo.** Em um certo mês o preço de um produto  **aumentou 10%**. No mês seguinte  **diminui 7%** e no terceiro mês  **aumentou 5%**. De quanto foi a mudança  **média** no preço?

Se  $x_1, \dots, x_n$  são  **positivos**, a média geométrica é definida como

$$m_g = (x_1 \times x_2 \times \dots \times x_n)^{1/n} = \sqrt[n]{x_1 \times x_2 \times \dots \times x_n} = \left( \prod_{i=1}^n x_i \right)^{1/n}.$$

**Obs.** Pode ser calculada usando logaritmos.

$$\log(m_g) = \frac{1}{n} \log \left( \prod_{i=1}^n x_i \right) = \frac{1}{n} \sum_{i=1}^n \log(x_i) = \overline{\log(x)} \Rightarrow m_g = \exp(\overline{\log(x)}).$$

**Exemplo.** No 1º mês o preço foi multiplicado por 1,10. Nos outros dois meses o fator de correção foi 0,93 e 1,05.

A correção  **total** nos três meses foi  $1,10 \times 0,93 \times 1,05 = 1,07415$ .

Mudança média =  $1,07415^{1/3} = 1,024130$ .

Houve um  **aumento médio** mensal de cerca de  **2,4%**.

Três correções sucessivas de 1,024130 têm o  **mesmo efeito** das correções (+10%, -7%, +5%).



## 4.6. Média harmônica (*harmonic mean*)

**Exemplo.** Em três semanas de trabalho um viajante percorreu trechos de 400 km com velocidades de 60, 50 e 40 km/h. De quanto foi a velocidade média?

Se  $x_1, \dots, x_n$  são diferentes de 0, a média harmônica é definida como

$$m_h = \frac{1}{\left( \frac{1}{x_1} + \frac{1}{x_2} + \dots + \frac{1}{x_n} \right) / n}.$$

**Exemplo.** Os tempos de viagem (em h) foram  $400 / 60 = 6,67$ ,  $400 / 50 = 8$  e  $400 / 40 = 10$ .

**Tempo médio** de viagem =  $(6,67 + 8 + 10) / 3 = 8,22$  h.

Velocidade média =  $400 \text{ km} / 8,22 \text{ h} = 48,65 \text{ km/h}$ .

Velocidade média =  $m_h = 1 / \{(1 / 60 + 1 / 50 + 1 / 40) / 3\} = 48,65 \text{ km/h}$ .


**Desigualdade das médias.** Se  $x_1, \dots, x_n$  são positivos, então

$$m_h \leq m_g \leq \bar{x}.$$

## 4.7. Quantil (*quantile*)

Chamado de **separatriz**.

Provocam uma **divisão** nos dados **ordenados**.



Encontramos  $j$  observações **menores** do que ou iguais a  $q$ . Chamamos  $q$  o **quantil  $j/n$**  (ou  $100 \times j / n \%$ ), denotado por  $q_{j/n}$ .

**Obs.** Neste exemplo  $q_{j/n}$  não é único.

Em geral, temos os quantis  $q_{\alpha}$ ,  $0 \leq \alpha \leq 1$ .

**Quartis:**  $Q_1 = q_{0,25}$ ,  $Q_2 = q_{0,5} = M$  e  $Q_3 = q_{0,75}$ .

**Decis:**  $q_{0,1}$ ,  $q_{0,2}, \dots, q_{0,8}$ ,  $q_{0,9}$ .

**Percentis:**  $q_{1\%}$ ,  $q_{2\%}, \dots, q_{98\%}$ ,  $q_{99\%}$ .

**Obs.** Informalmente dizemos que os (três) **quartis** dividem os dados em **quatro** intervalos cada um contendo **25%** das observações.

## Quantis em R

Nove diferentes maneiras de calcular. A opção *default* (`type = 7`) difere do Minitab, SAS e SPSS.

Exemplo. Notas de 46 alunos (lâmina 15).

```
> summary(x)
```

```
   Min. 1st Qu.  Median    Mean 3rd Qu.    Max.
3.400  4.825  5.750  6.176  7.575 10.000
```

```
> quantile(x)
```

```
   0%    25%    50%    75%   100%
3.400  4.825  5.750  7.575 10.000
```

```
> (alfa = seq(0.1, 0.9, by = 0.1))
```

```
[1] 0.1 0.2 0.3 0.4 0.5 0.6 0.7 0.8 0.9
```

```
> (decis = quantile(x, probs = alfa))
```

```
 10%  20%  30%  40%  50%  60%  70%  80%  90%
3.85 4.70 5.00 5.20 5.75 6.70 7.10 7.80 8.65
```

```
> (decisSAS = quantile(x, probs = alfa, type = 3))
```

```
 10% 20% 30% 40% 50% 60% 70% 80% 90%
3.8 4.6 5.0 5.1 5.3 6.7 7.0 7.8 8.6
```