

Medidas descritivas

- **Medidas descritivas:**
 - **Objectivo:** Sumariar as características das amostras.
 - **Ex:**
 - Medidas de localização: Média, Moda, Mediana, Quantis, etc.
 - Medidas de dispersão: Variância, Desvio padrão, Coeficiente de variação, etc.
 - Medidas de forma: Coeficiente de assimetria, Coeficiente de Kurtose, etc.
 - **Def:** A **média** (aritmética), \bar{x} , de uma amostra de n observações não agrupadas, x_1, x_2, \dots, x_n , é dada por:

$$\bar{x} = \frac{1}{n} \sum_{k=1}^n x_k$$

Ex: Calcule a média das observações $\{1, 1, 3, 5, 7\}$.

$$\bar{x} = (1 + 1 + 3 + 5 + 7) / 5 = 3.4$$

R: `mean()`

Medidas descritivas

- **Def:** A *média*, \bar{x} , de uma amostra de n observações agrupadas em c classes é dada por:

$$\bar{x} = \frac{1}{n} \sum_{i=1}^c x_i n_i = \sum_{i=1}^c x_i f_i$$

Nota: Para dados contínuos, x_i representa a marca da classe i .

Ex: Calcule a média das observações $\{1,1,3,5,7\}$, agrupando as classes previamente.

$$\bar{x} = (1 \times 2 + 3 \times 1 + 5 \times 1 + 7 \times 1) / 5 = 3.4$$

- **Def:** A *moda*, Mo , de dados discretos ou contínuos não agrupados é o valor observado com maior frequência.

Ex: Para as observações $\{1,1,3,5,7\}$, $Mo = 1$.

- **Def:** A *classe modal* de um conjunto de dados contínuos agrupados é a classe com maior frequência.

Medidas descritivas

- **Def:** A *mediana*, Me , duma série de observações x_1, x_2, \dots, x_n , é o valor que divide a série em 2 partes iguais, tal que 50% das observações têm valor menor ou igual a Me . Calcula-se da seguinte forma:

- a) Se os dados são discretos ou contínuos não agrupados e as observações estão ordenadas por ordem crescente, então:

$$Me = \begin{cases} \frac{x_{n/2} + x_{n/2+1}}{2} & , n \text{ par} \\ x_{(n+1)/2} & , n \text{ ímpar} \end{cases}$$

R: median()

Ex: Para $\{1, 1, 3, 5, 7\}$, $n = 5$ e $(n+1)/2 = 3$. Logo, $Me = x_3 = 3$.

- b) Se os dados são contínuos agrupados, então:

$$Me = L_k + \frac{h_k}{f_k} (0.5 - F_{k-1})$$

Medidas descritivas

onde:

F_{k-1} : Frequência relativa acumulada até à classe $k - 1$.

k : Classe mediana, tal que $F_{k-1} < 0.5$ e $F_k \geq 0.5$.

L_k : Limite inferior da classe mediana.


h_k : Amplitude da classe mediana.

f_k : Frequência relativa da classe mediana.

Ex:

Classe	n_i	f_i	F_i
[5, 7[5	0.1471	0.1471
[7, 9[13	0.3824	0.5295
[9, 11[8	0.2353	0.7648
[11, 15[8	0.2353	1.0001

Medidas descritivas



Por interpolação linear:

$$y = \frac{0.5295 - 0.1471}{9 - 7}(x - 7) + 0.1471 \Leftrightarrow x = 7 + \frac{2}{0.3824}(y - 0.1471)$$
$$\therefore Me = x(0.5) \approx 8.8457$$

L_2 $\frac{h_2}{2}$ F_1
 ↓ ↓ ↓
 f_2

Medidas descritivas

- **Def:** O *quantil de ordem α* , z_α , ($0 < \alpha < 1$), duma série de observações x_1, x_2, \dots, x_n é calculado da seguinte forma:

a) Se os dados são discretos ou contínuos não agrupados e as observações estão ordenadas por ordem crescente, então:

$$z_\alpha = x_k$$

R: quantile(..., type = 1)

onde k é o maior inteiro menor que $n\alpha + 1$

Ex: Seja $\{1,1,3,5,7\}$ a amostra e $\alpha = 0.1$. Então, $n = 5$ e $n\alpha + 1 = 1.5$. Logo, $z_{0.1} = 1$.


b) Se os dados são contínuos agrupados, z_α calcula-se como a mediana mas substituindo a classe mediana pela *classe do quantil α* e o valor 0.5 por α .

$$z_\alpha = L_k + \frac{h_k}{f_k} (\alpha - F_{k-1})$$

k : Classe do quantil α , tal que $F_{k-1} < \alpha$ e $F_k \geq \alpha$


Medidas descritivas

Ex:



Medidas descritivas

- **Def:** O *percentil de ordem k*, p_k , ($k=1,2,\dots,99$), de um conjunto de dados é o quantil de ordem $k/100$. Logo, k % das observações são menores do que p_k .
- **Def:** O *decil de ordem k*, d_k , ($k=1,2,\dots,9$), de um conjunto de dados é o quantil de ordem $k/10$.
- **Def:** O *quartil de ordem k*, q_k , ($k=1,2,3$), de um conjunto de dados é o quantil de ordem $k/4$.
- **Nota:** $\text{Me} = p_{50} = d_5 = q_2$
- **Def:** Um *diagrama de caixa (box plot)* é uma representação gráfica de dados baseada nos seus quartis que mostra a dispersão desses dados.



R: boxplot()

Medidas descritivas

- **Def:** A *variância*, s^2 , de uma amostra de n observações não agrupadas, x_1, x_2, \dots, x_n , é dada por:

$$s^2 = \frac{1}{n-1} \sum_{k=1}^n (x_k - \bar{x})^2 = \frac{1}{n-1} \left[\sum_{k=1}^n x_k^2 - n\bar{x}^2 \right] = \frac{n \sum_{k=1}^n x_k^2 - \left(\sum_{k=1}^n x_k \right)^2}{n(n-1)}$$

R: var()

- **Def:** A *variância*, s^2 , de uma amostra de n observações agrupadas em c classes é dada por:

$$s^2 = \frac{1}{n-1} \sum_{i=1}^c (x_i - \bar{x})^2 n_i = \frac{1}{n-1} \left[\sum_{i=1}^c x_i^2 n_i - n\bar{x}^2 \right] = \frac{n \sum_{i=1}^c x_i^2 n_i - \left(\sum_{i=1}^c x_i n_i \right)^2}{n(n-1)}$$

- **Def:** O *desvio padrão*, s , de uma amostra é a raiz quadrada da sua variância.

Ex: Calcule o desvio padrão das observações $\{4,9,11,14,22\}$. *R: sd()*

$$s^2 = \frac{5(4^2 + 9^2 + 11^2 + 14^2 + 22^2) - (4 + 9 + 11 + 14 + 22)^2}{5 \times 4} = 44.5 \quad \therefore \quad s = \sqrt{44.5} \approx 6.67$$

Medidas descritivas

- **Def:** O *coeficiente de variação* duma amostra é dado por:

$$CV = \frac{s}{|\bar{x}|}$$

- **Vantagem:** O CV é uma medida adimensional.
- **Desvantagem:** Não está definido para $\bar{x} = 0$. Logo, só deve ser usado quando as observações têm todas o mesmo sinal.

Ex: Calcule o coeficiente de variação das observações $\{4,9,11,14,22\}$.

$$\bar{x} = (4 + 9 + 11 + 14 + 22)/5 = 12$$

$$CV = \frac{6.67}{12} \approx 0.556 = 55.6\%$$

Medidas descritivas

- **Def:** O momento amostral centrado de ordem r , ($r \in \mathbb{N}_0$), é calculado da seguinte forma:

a) Para n observações não agrupadas:

$$m_r = \frac{1}{n} \sum_{k=1}^n (x_k - \bar{x})^r$$

b) Para n observações agrupadas em c classes:

$$m_r = \frac{1}{n} \sum_{i=1}^c (x_i - \bar{x})^r n_i$$

Medidas descritivas


- **Def:** O coeficiente de assimetria amostral, a_3 , é dado por

$$a_3 = \frac{m_3}{s^3}$$


- **Notas:**

- É adimensional
- Mede a assimetria da distribuição
- $a_3 = 0$ quando é simétrica
- $a_3 > 0$ quando a cauda direita é a mais comprida
- $a_3 < 0$ quando a cauda esquerda é a mais comprida

Ex:



Distribuição enviesada à direita;
assimétrica positiva



Distribuição enviesada à esquerda;
assimétrica negativa

Medidas descritivas


- **Def:** O coeficiente de curtose amostral, a_4 , é dado por

$$a_4 = \frac{m_4}{s^4}$$

- **Notas:**

- É adimensional
- Mede o achatamento e o peso das caudas da distribuição
- $a_4 = 3 \Rightarrow$ Mesmo achatamento que a normal (*mesocúrtica*)
- $a_4 > 3 \Rightarrow$ Mais esguia e cauda mais pesada que a normal (*leptocúrtica*)
- $a_4 < 3 \Rightarrow$ Mais achatada e cauda menos pesada que a normal (*platicúrtica*)

Ex:



$a_4(A) > a_4(B)$ porque B é mais achatada e tem caudas menos pesadas