





## **6. Medidas de assimetria e curtose**

**2010**

## 6.1. Medidas de assimetria

Uma **variável aleatória contínua**  $X$  tem distribuição **simétrica** (*symmetric*) em relação a um valor  $x_0$  se  $f(x_0 - a) = f(x_0 + a)$ , para todo  $a$ .





Distribuições  
simétricas:



**Obs.**  $M = x_0$ .

Moda e média  
não  
necessariamente  
são iguais a  $x_0$ .



Distribuições  
assimétricas:




## Relação entre moda, mediana e média

Supomos que a distribuição é **unimodal** e que a **média existe**.

Distribuição **simétrica**: moda = mediana = média.



## Relação entre moda, mediana e média



Distribuição  
assimétrica à direita ou  
assimétrica positiva  
(*right skewed* ou  
*positive skewed*):  
média > mediana >  
moda.


Cauda direita (*right tail*) é  
mais longa.

## Relação entre moda, mediana e média

Distribuição  
assimétrica à  
esquerda ou  
assimétrica negativa  
(*left skewed* ou  
*negative skewed*):  
média < mediana <  
moda.

Cauda esquerda (*left  
tail*) é mais longa.

Obs. Dependendo do autor,  
há *troca* de esquerda por  
direita.



Um conjunto de dados  $x_1, x_2, \dots, x_n$  é **simétrico** em relação a  $x_0$  se para todo  $x_j$  existe  $x_k$  tal que  $x_j - x_0 = - (x_k - x_0)$ ,  $j \neq k$ .

Desta forma,

$$\sum_{i=1}^n (x_i - x_0) = 0. \quad \text{Logo, } x_0 = \bar{x}.$$

Pela simetria,  $M = x_0$ .

**Exemplo.** (24, 26, 26, 32, 40, 60, 68, 74, 74, 76) é simétrico em relação a  $x_0 = 50$ .

Medidas de assimetria. Quantificação da **falta de simetria** de  $x_1, x_2, \dots, x_n$ .


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

Assume valores reais. Medida = 0: **indicativo** de simetria.


**Obs.** Dados obtidos de uma **variável aleatória X simétrica não necessariamente são simétricos**.

# Assimetria em conjuntos de dados



## Aproximadamente simétrico



## Assimetria positiva



## Assimetria negativa





## 6.1.1. Medida de assimetria de Pearson

Utiliza a relação entre moda, mediana e média em distribuições unimodais.

$$g = \frac{\bar{x} - \text{Mo}}{s}.$$

Requer o cálculo da moda (Mo). É adimensional.

**Momentos.** Dados:  $x_1, x_2, \dots, x_n$ .

Momento de ordem  $k$  em relação à origem ou momento não central (*raw* ou *crude moment*):

$$m_k^l = \frac{1}{n} \sum_{i=1}^n x_i^k, \quad k = 0, 1, 2, \dots, \quad \text{sendo que } m_0^l = 1 \text{ e } m_1^l = \bar{x}.$$

Momento central de ordem  $k$  (*central moment*):

$$m_k = \frac{1}{n} \sum_{i=1}^n (x_i - \bar{x})^k, \quad k = 0, 1, 2, \dots, \quad \text{sendo que } m_0 = 1 \text{ e } m_1 = 0.$$

Obs.  $m_2 = (n - 1) s^2 / n$ .

Relação entre os momentos:

$$m_2 = m_2^l - \bar{x}^{-2},$$

$$m_2^l = m_2 + \bar{x}^{-2},$$

$$m_3 = m_3^l - 3m_2^l \bar{x} + 2\bar{x}^{-3} \quad \text{e}$$

$$m_3^l = m_3 + 3m_2 \bar{x} + \bar{x}^{-3} \quad \text{e}$$

$$m_4 = m_4^l - 4m_3^l \bar{x} + 6m_2^l \bar{x}^{-2} - 3\bar{x}^{-4}.$$

$$m_4^l = m_4 + 4m_3 \bar{x} + 6m_2 \bar{x}^{-2} + \bar{x}^{-4}.$$

Se uma **variável aleatória**  $X$  tem distribuição **simétrica**, seus **momentos centrais** de ordem  $k$  **ímpar**, se **existirem**, são todos nulos:

$E[(X - \mu)]^k = 0$ , sendo que  $\mu = E(X)$ .

Sendo assim, podemos utilizar o **3º** momento **central** para propor uma medida de assimetria.

Obs.  $E[(X - \mu)]^3 = 0$  **não implica** que a distribuição de  $X$  é **simétrica**.

## 6.1.2. Assimetria (*skewness*)

$$g_1 = \frac{m_3}{m_2^{3/2}} = \frac{\frac{1}{n} \sum_{i=1}^n (x_i - \bar{x})^3}{\left[ \frac{1}{n} \sum_{i=1}^n (x_i - \bar{x})^2 \right]^{3/2}}.$$

Propriedades. (1)  $g_1$  é **adimensional** e (2)  $g_1$  é um número **real**.


## 6.2. Medidas de curtose

Em distribuições **unimodais**, a curtose (*kurtosis*) está associada ao **afilamento** ou ao **achatamento** da distribuição.

Característica do “pico” da distribuição (*degree of peakedness*).

No caso de uma **variável aleatória contínua unimodal**, a curtose diz respeito à forma de  $f(x)$  em torno de sua **moda** (que pode coincidir com a média e a mediana).


## Distribuições **simétricas** com **médias** e **variâncias** iguais:




Diferenças quanto ao **afastamento** em relação à **média**, mas que **não** são captadas pela **variância**.

Este fato sugere utilizarmos o 4º momento **central** para quantificar estas diferenças.

# Distribuições platicúrticas, mesocúrticas e leptocúrticas



Platicúrtica (*platykurtic*):  
caudas **curtas** ou **leves** (*short*  
ou *light* ou *thin*).



Leptocúrtica (*leptokurtic*):  
caudas **longas** ou **pesadas**  
(*long* ou *heavy* ou *thick* ou *fat*).

Fonte. Bulmer, M. G. (1979), *Principles of Statistics*, Dover: New York.

Mesocúrtica (*mesokurtic*): caudas **neutras** (nem curtas e nem longas).

## Curtose (*kurtosis*)

$$g_2 = \frac{m_4}{m_2^2} = \frac{\frac{1}{n} \sum_{i=1}^n (x_i - \bar{x})^4}{\left[ \frac{1}{n} \sum_{i=1}^n (x_i - \bar{x})^2 \right]^2}.$$

**Propriedades.** (1)  $g_2$  é adimensional e (2)  $g_2 > 0$ .

**Obs.** Se  $X \sim N(\mu, \sigma^2)$ , então  $E[(X - \mu)^4] / \{E[(X - \mu)^2]\}^2 = E[(X - \mu)^4] / \sigma^4 = 3$ .


Muitas vezes a curtose é expressa como  $g_{2e} = g_2 - 3$  (*excess*).

Platicúrtica:  $g_{2e} < 0$ .

Mesocúrtica:  $g_{2e} = 0$ .

Leptocúrtica:  $g_{2e} > 0$ .

# Distribuições simétricas com médias e variâncias iguais:



# Momentos em R

Pacote `moments`

```
> library(moments)
```

**Exemplo.** 1, 0, 2,7, -1,4 e 13 são os momentos **centrais** até ordem 4 de um conjunto de dados com **média = 3,8**.

```
> momc = c(1, 0, 2.7, -1.4, 13)
```

```
> xb = 3.8
```

```
> (mom0 = central2raw(momc, xb))
```

```
[1] 1.0000 3.8000 17.1400 84.2520 434.1616 (momentos não centrais)
```

**Função `raw2central`:** converte momentos não centrais em centrais.

```
> mom0 = c(1.0, 1.5, 3.1, 8.4, 27.0)
```

```
> (momc = raw2central(mom0))
```

```
[1] 1.0000 0.0000 0.8500 1.2000 3.2625 (momentos centrais)
```




# Momentos em R

## 40 observações

```
x = c(21.88, 22.61, 23.28, 25.19, 19.73, 22.50, 26.35, 22.09, 24.63,  
19.79, 23.61, 29.91, 29.12, 23.17, 23.38, 21.75, 18.77, 20.38,  
20.45, 28.23, 18.17, 30.15, 20.60, 19.99, 24.56, 25.59, 20.66,  
23.76, 23.35, 22.77, 21.52, 20.54, 20.30, 23.45, 27.69, 24.82,  
24.30, 21.97, 20.82, 22.78)
```

```
> boxplot(x, horizontal = TRUE,  
xlab = "X")
```

```
> rug(x)
```



Momento **não central** de ordem 3:

```
> moment(x, order = 3, central = FALSE)
```

```
[1] 12960.19
```

Qual o resultado de  
 $\text{mean}(x^3)$  ?

Momentos **centrais** até ordem 4:

```
> (mom4 = all.moments(x, order.max = 4, central = TRUE))
```

```
[1] 1.000000e+00 4.440892e-16 8.521595e+00 1.843078e+01 2.206282e+02
```

```
k =      0      1      2      3      4
```

# Assimetria e curtose em R

Pacote `moments`

```
> skewness(x)
```

```
[1] 0.7409046
```

Qual o resultado de  $\text{mom4}[4] / \text{mom4}[3]^1.5$ ?

```
> kurtosis(x)
```

```
[1] 3.03822
```

Qual o resultado de  $\text{mom4}[5] / \text{mom4}[3]^2$ ?


```
> kurtosis(x) - 3
```

```
[1] 0.03822
```

```
> hist(x, main = "", xlab =  
"x", freq = FALSE, ylab =  
"Densidade")
```

```
> rug(x)
```

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



## Dados faltantes (*missing data*) em R

Observações **indisponíveis** por algum motivo.

Em R: **NA** (*not available*).

40 (?) observações

```
x = c(21.88, NA, 23.28, 25.19, 19.73, 22.50, 26.35, 22.09, 24.63,  
19.79, 23.61, 29.91, 29.12, 23.17, 23.38, 21.75, NA, 20.38, 20.45,  
28.23, 18.17, 30.15, 20.60, 19.99, 24.56, 25.59, 20.66, 23.76,  
23.35, NA, 21.52, 20.54, 20.30, 23.45, 27.69, 24.82, 24.30, 21.97,  
20.82, 22.78)
```

```
> summary(x)
```

```
Min. 1st Qu.  Median    Mean 3rd Qu.    Max.      NA's  
18.17  20.66   23.17   23.26  24.63   30.15      3.00
```

```
> mean(x)          > mean(x, na.rm = TRUE)
```

```
[1] NA              [1] 23.25568
```

```
> kurtosis(x)     > kurtosis(x, na.rm = TRUE)
```

```
[1] NA              [1] 2.891447
```

Substituição dos faltantes pela média:

```
> is.na(x) = mean(x, na.rm = TRUE)
```

```
> which(is.na(x))
```

```
[1]  2 17 30
```