

# Estatística para Cursos de Engenharia e Informática

Pedro Alberto Barbetta / Marcelo Menezes Reis / Antonio Cezar Bornia  
São Paulo: Atlas, 2004

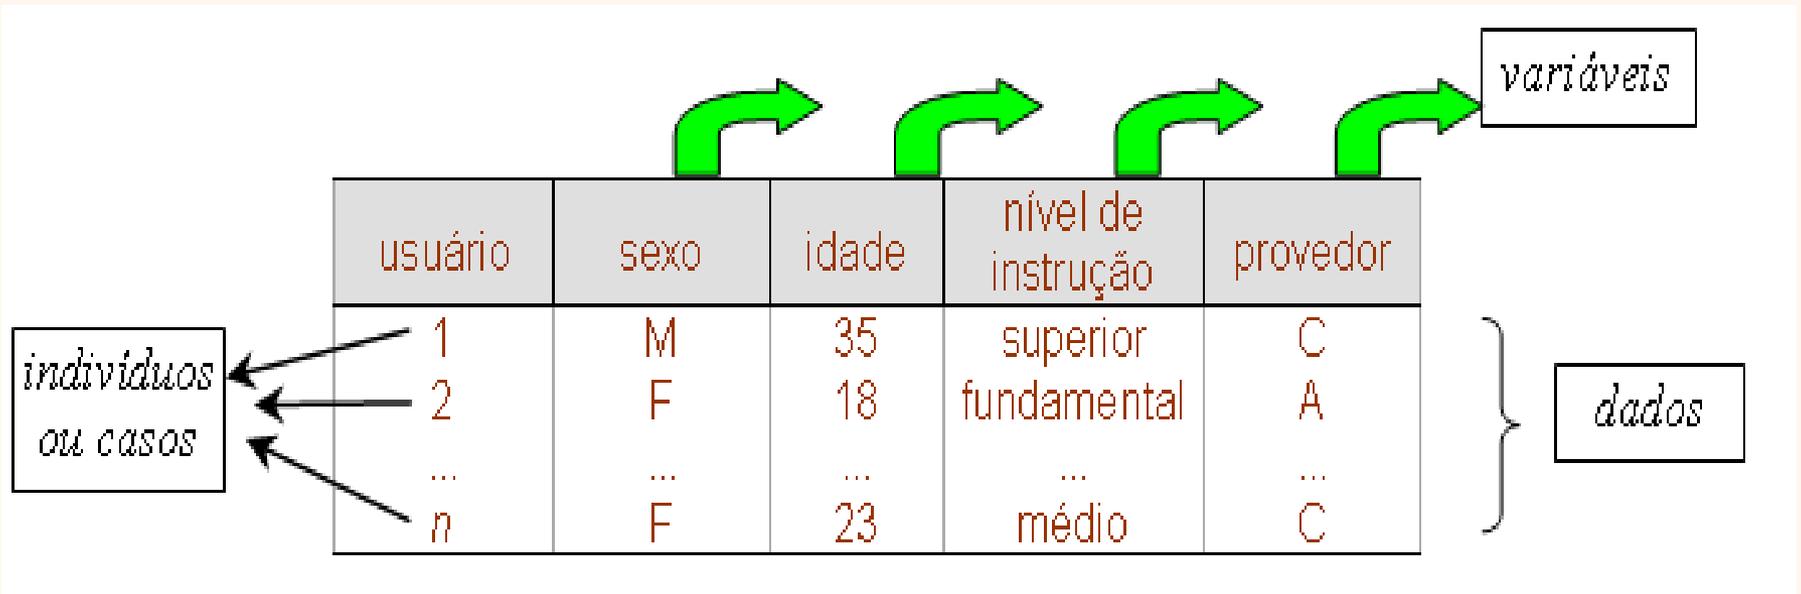
## Cap. 3 – Análise exploratória de dados

APOIO:

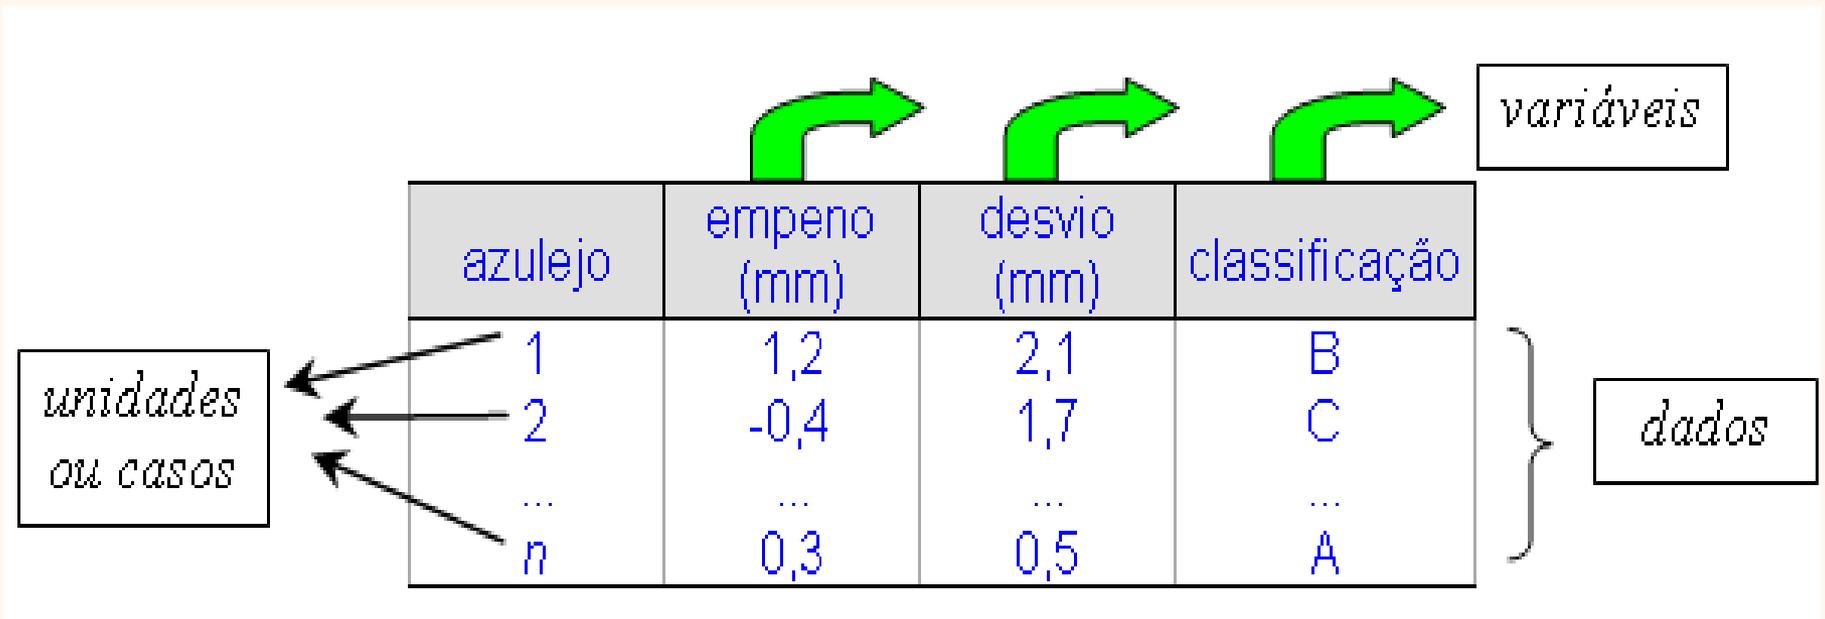
Fundação de Apoio à Pesquisa Científica e Tecnológica do Estado de Santa Catarina (FAPESC)

Departamento de Informática e Estatística – UFSC (INE/CTC/UFSC)

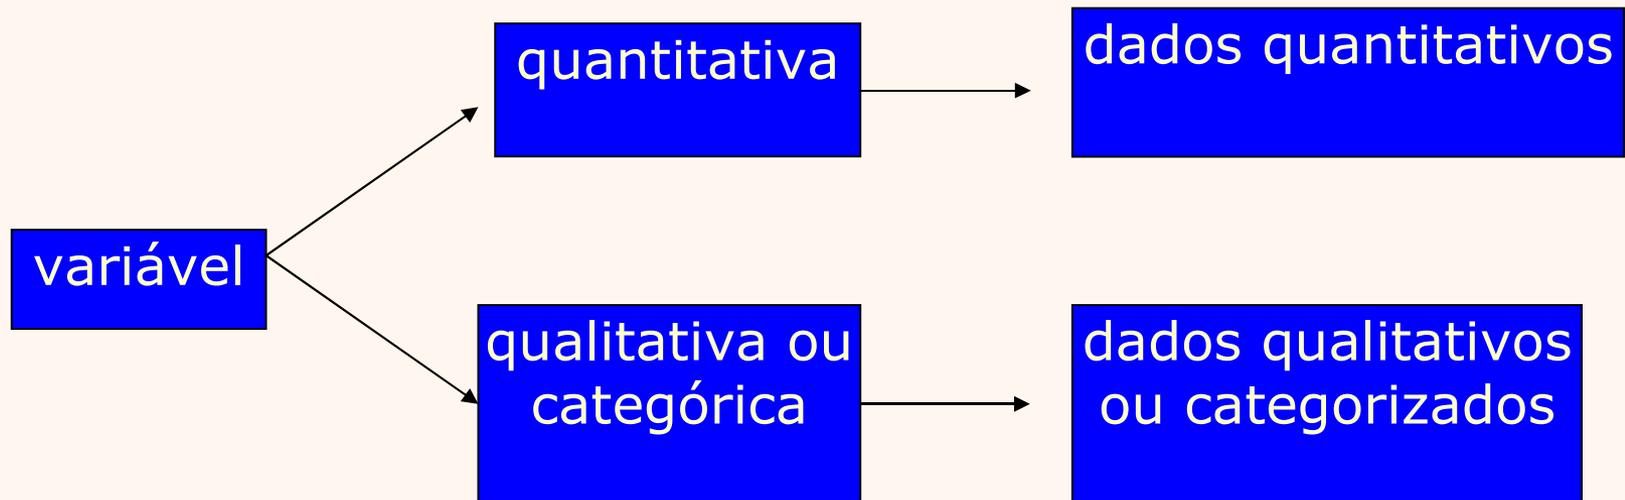
# Dados e variáveis



# Dados e variáveis



# Dados e variáveis



# Distribuição de frequências

- A **distribuição de frequências** consiste na organização dos dados de acordo com as ocorrências dos diferentes resultados observados.
- Pode ser apresentada em **tabela** ou **gráfico**.

# Dados

## Provedor usado por cada usuário

indivíduo	provedor	indivíduo	provedor	indivíduo	provedor	indivíduo	provedor
1	C	11	C	21	B	31	A
2	A	12	A	22	A	32	A
3	B	13	B	23	A	33	B
4	B	14	D	24	B	34	C
5	C	15	A	25	A	35	B
6	B	16	B	26	A	36	D
7	D	17	B	27	B	37	B
8	B	18	C	28	D	38	B
9	B	19	D	29	D	39	B
10	A	20	B	30	C	40	C

# Distribuição de freqüências para variáveis qualitativas

**Tabela.** Distribuição de freqüências do provedor usado pelo visitante do *site*.

Provedor	Freqüência	Percentagem
A	10	25,0
B	17	42,5
C	7	17,5
D	6	15,0
Total	40	100,0

# Distribuição de freqüências para variáveis qualitativas

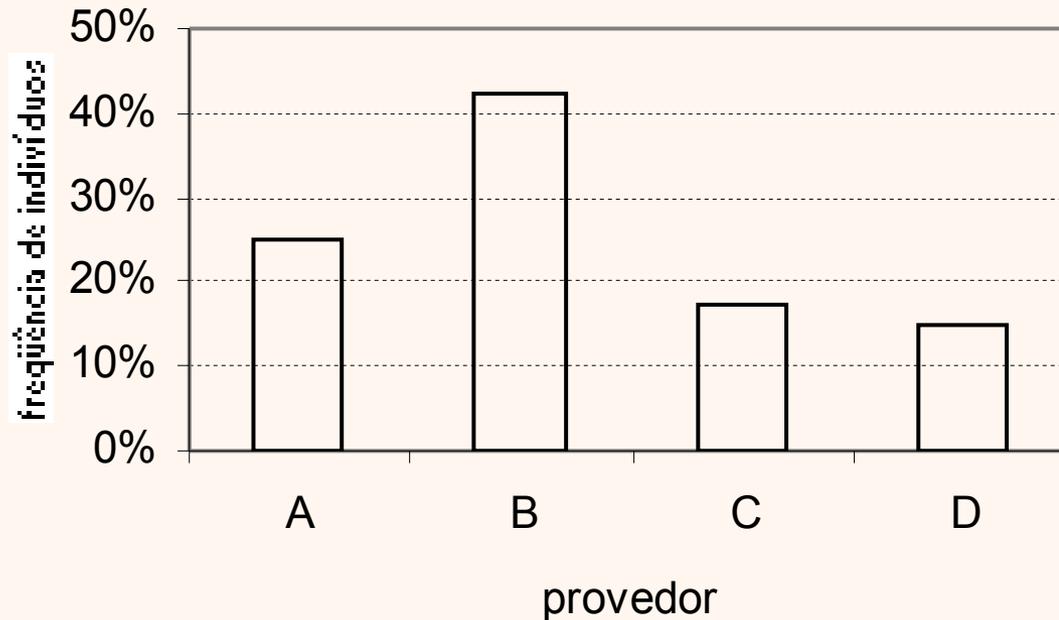


Gráfico de colunas para a apresentação da distribuição de freqüências do provedor usado pelo visitante do *site*.

# Distribuição de freqüências para variáveis qualitativas

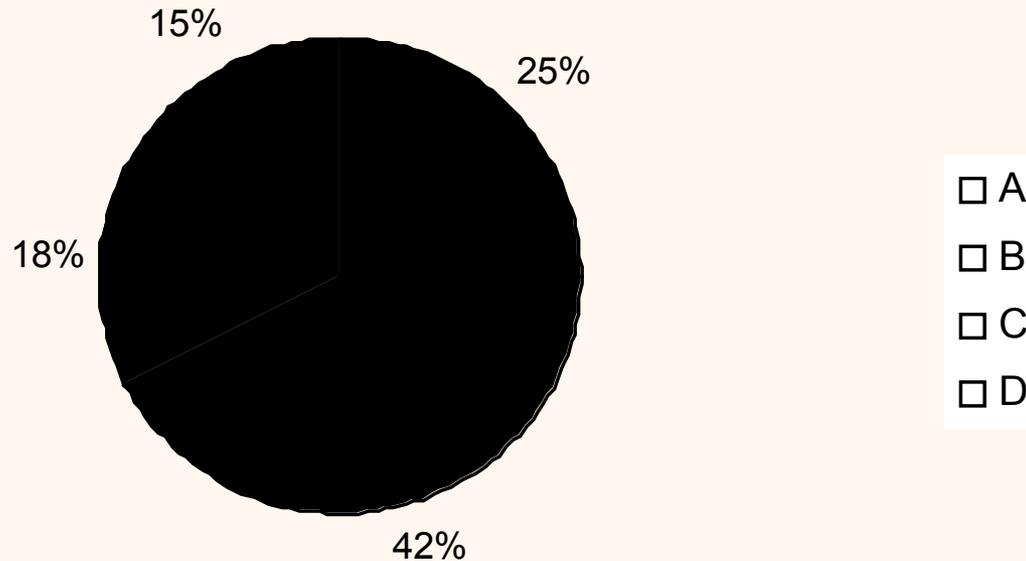
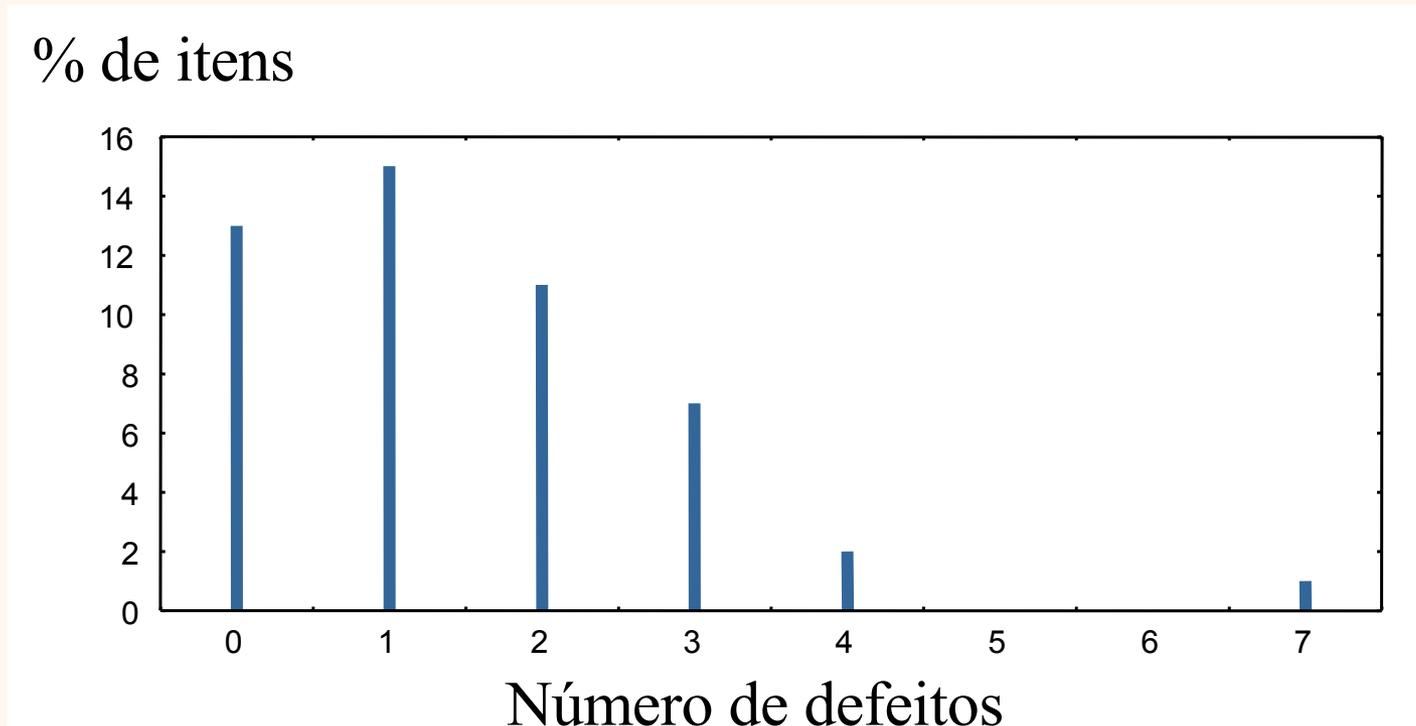


Gráfico de setores para a apresentação da distribuição de freqüências do provedor usado pelo visitante do *site*.

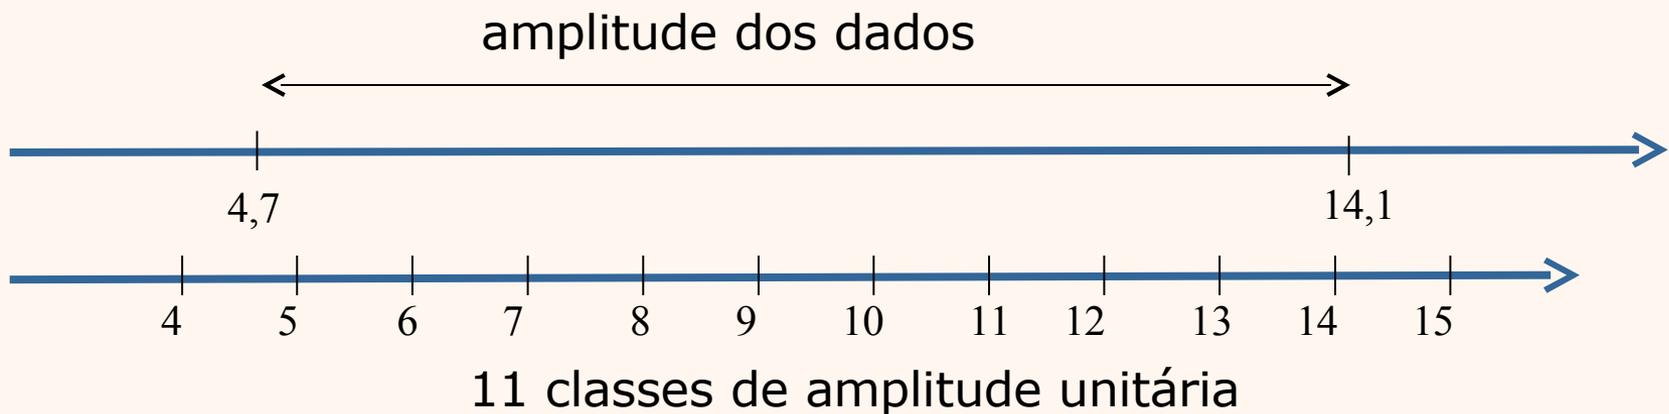
# Distribuição de freqüências para variáveis quantitativas discretas



# Variáveis contínuas

## Construção da distribuição de freqüências

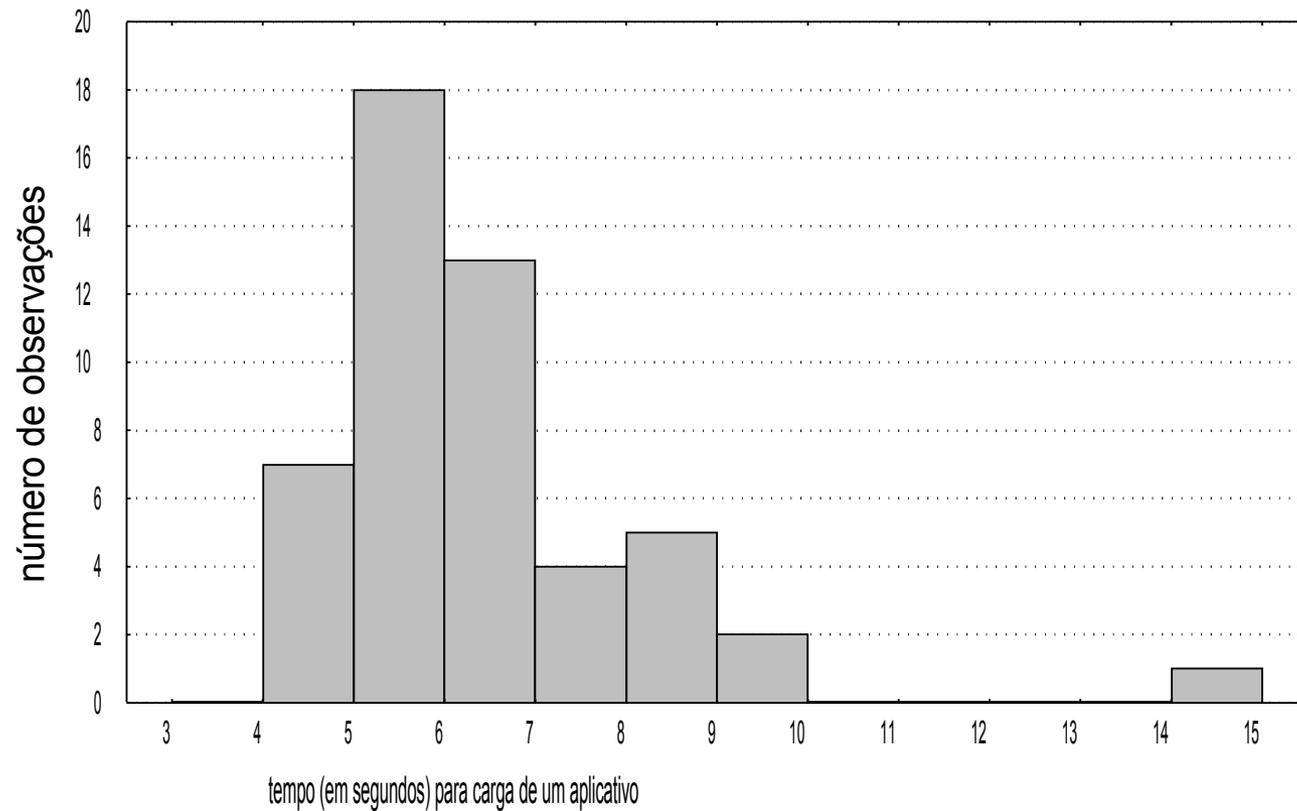
5,2	6,4	5,7	8,3	7,0	5,4	4,8	9,1	
5,5	6,2	4,9	5,7	6,3	5,1	8,4	6,2	8,9
7,3	5,4	4,8	5,6	6,8	5,0	6,7	8,2	7,1
4,9	5,0	8,2	9,9	5,4	5,6	5,7	6,2	4,9
5,1	6,0	4,7	14,1	5,3	4,9	5,0	5,7	6,3
6,0	6,8	7,3	6,9	6,5	5,9			



# Tabela de freqüências: variável contínua

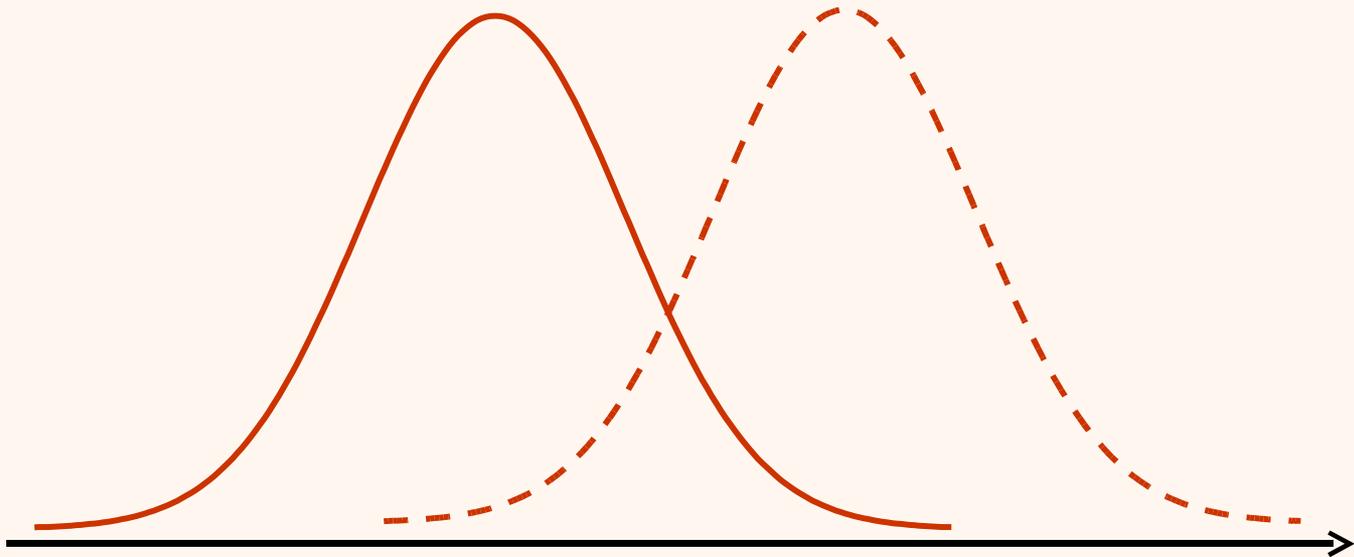
Classes de tempo	Ponto médio	Número de observações $n_j$	Percentagem de observações $100f_j$	Percentagem acumulada $100F_j$
4  — 5	4,5	7	14	14
5  — 6	5,5	18	36	50
6  — 7	6,5	13	26	76
7  — 8	7,5	4	8	84
8  — 9	8,5	5	10	94
9  — 10	9,5	2	4	98
10  — 11	10,5	0	0	98
11  — 12	11,5	0	0	98
12  — 13	12,5	0	0	98
13  — 14	13,5	0	0	98
14  — 15	14,5	1	2	100
Total	-	50	100	-

# Histograma



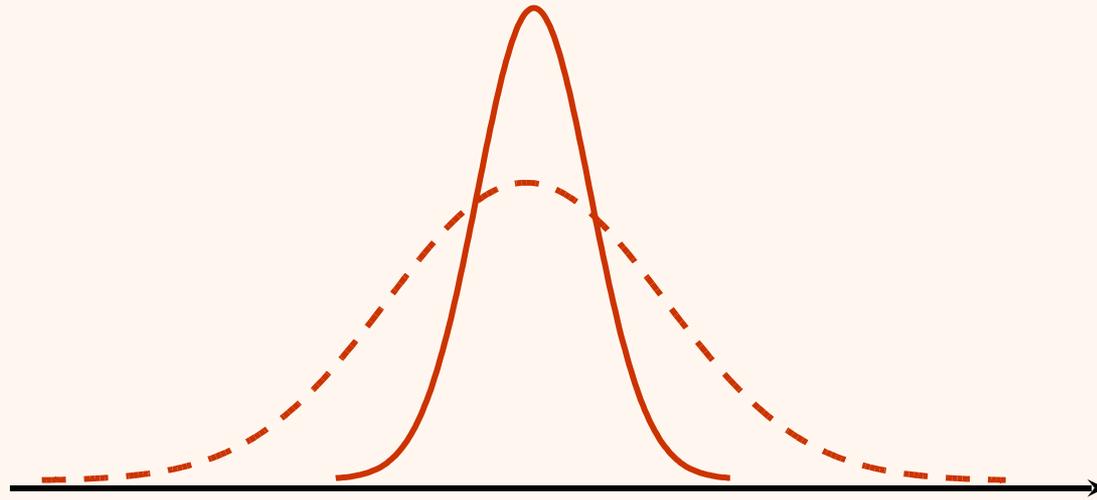
# Formas de uma distribuição de freqüências

- Distribuições diferentes em termos da posição central



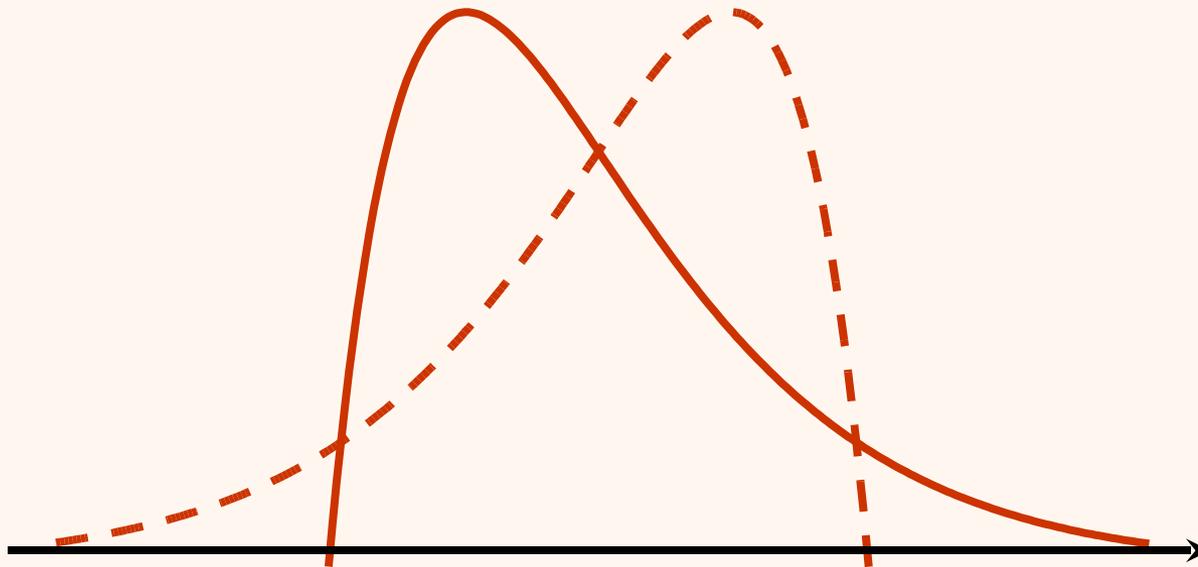
# Formas de uma distribuição de freqüências

- Distribuições diferentes quanto à dispersão



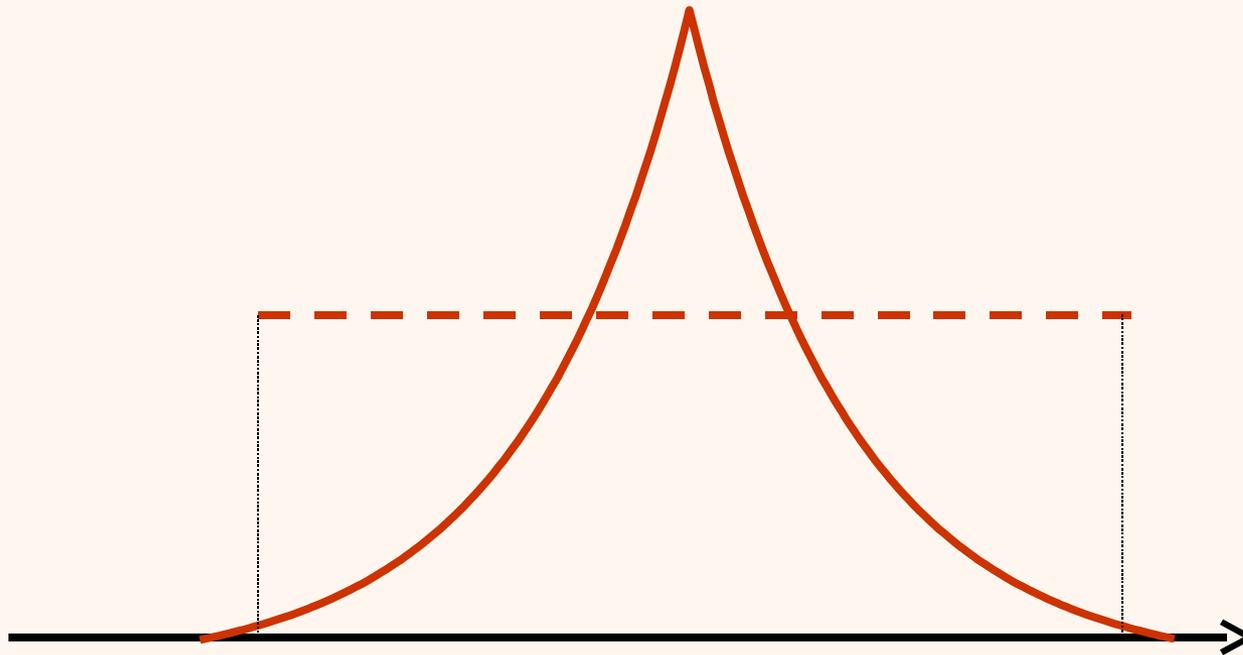
# Formas de uma distribuição de freqüências

- Distribuições diferentes quanto à assimetria



# Formas de uma distribuição de freqüências

- Distribuições diferentes quanto à curtose



# Medidas descritivas

- A média aritmética: uma medida de posição central.

$$\bar{X} = \frac{X_1 + X_2 + \dots + X_n}{n} = \frac{1}{n} \sum_{i=1}^n X_i$$

# Exemplo

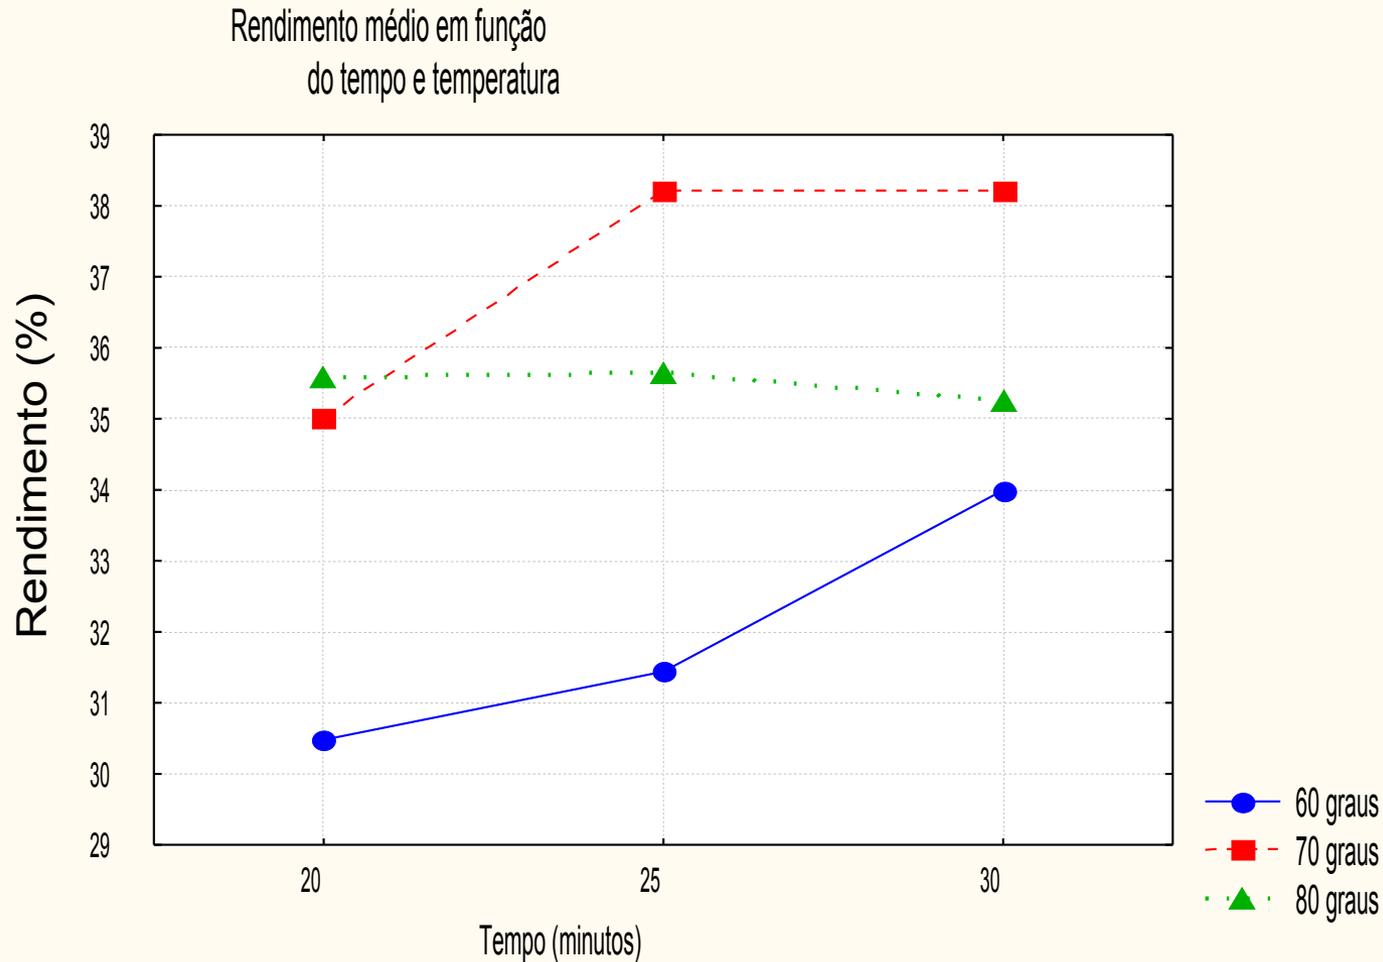
Temperatura (°C)	Tempo (minutos)								
	20			25			30		
<b>60</b>	29,7	28,7	30,2	31,0	30,6	32,8	32,9	32,7	34,8
	31,3	31,2	31,7	31,9	31,2	31,2	34,9	33,8	34,9
<b>70</b>	36,6	35,7	35,3	35,7	40,4	41,7	34,8	36,8	37,4
	35,1	30,2	37,2	36,9	34,5	40,0	38,9	38,7	42,5
<b>80</b>	40,2	33,6	33,4	37,0	34,4	29,8	36,0	31,3	36,6
	35,2	38,1	33,0	33,9	43,2	35,5	32,5	39,2	35,9

# Exemplo

Médias aritméticas do rendimento, para diferentes níveis de temperatura e tempo de reação, num processo químico.

Temperatura (°C)	Tempo (minutos)		
	20	25	30
60	30,5	31,4	34,0
70	35,0	38,2	38,2
80	35,6	35,6	35,3

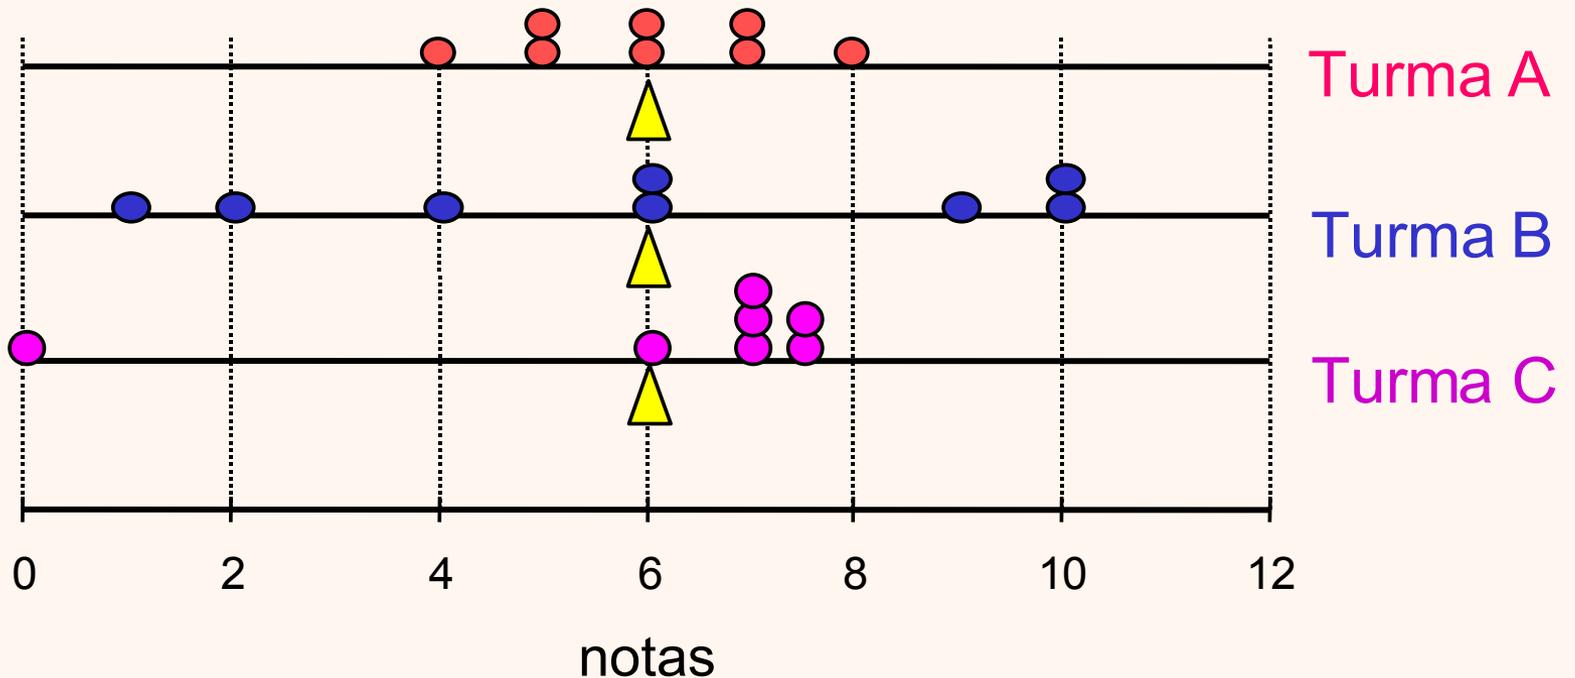
# Exemplo



## Exemplo: notas dos alunos de três turmas

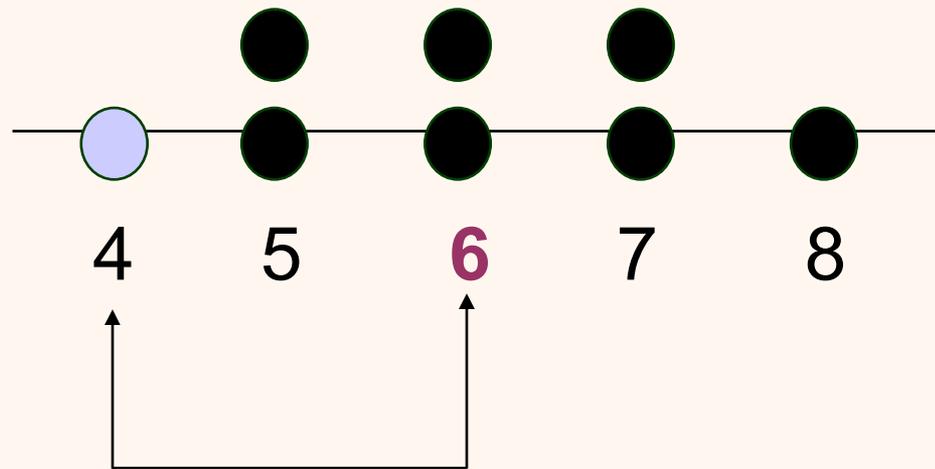
Turma	Notas dos alunos								Média da turma
A	4	5	5	6	6	7	7	8	6,00
B	1	2	4	6	6	9	10	10	6,00
C	0	6	7	7	7	7,5	7,5		6,00

# Exemplo: notas dos alunos de três turmas



# Como medir a dispersão?

Exemplo: Turma A (4 5 5 6 6 7 7 8)



distância (desvio) em relação à média

# Como medir a dispersão?

Descrição	notação	resultados numéricos
Valores (notas dos alunos)	$x_i$	4 5 5 6 6 7 7 8
Média	$\bar{X}$	6
Desvios em relação à média	$X_i - \bar{X}$	-2 -1 -1 0 0 1 1 2
Desvios quadráticos	$(x_i - \bar{x})^2$	4 1 1 0 0 1 1 4

Variância (da amostra):

$$s^2 = \frac{1}{n-1} \sum_{i=1}^n (x_i - \bar{x})^2$$

$$s^2 = \frac{4 + 1 + 1 + 0 + 0 + 1 + 1 + 4}{8 - 1} = 1,71$$

# Como medir a dispersão?

Descrição	notação	resultados numéricos
Valores (notas dos alunos)	$x_i$	4 5 5 6 6 7 7 8
Média	$\bar{X}$	6
Desvios em relação à média	$X_i - \bar{X}$	-2 -1 -1 0 0 1 1 2
Desvios quadráticos	$(x_i - \bar{x})^2$	4 1 1 0 0 1 1 4

Desvio padrão (da amostra): 
$$s = \sqrt{\frac{1}{n-1} \sum_{i=1}^n (x_i - \bar{x})^2}$$

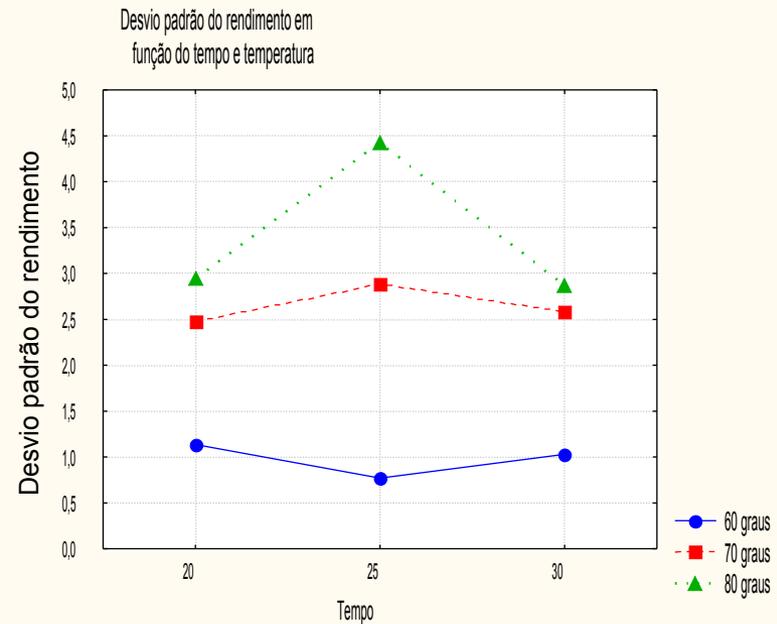
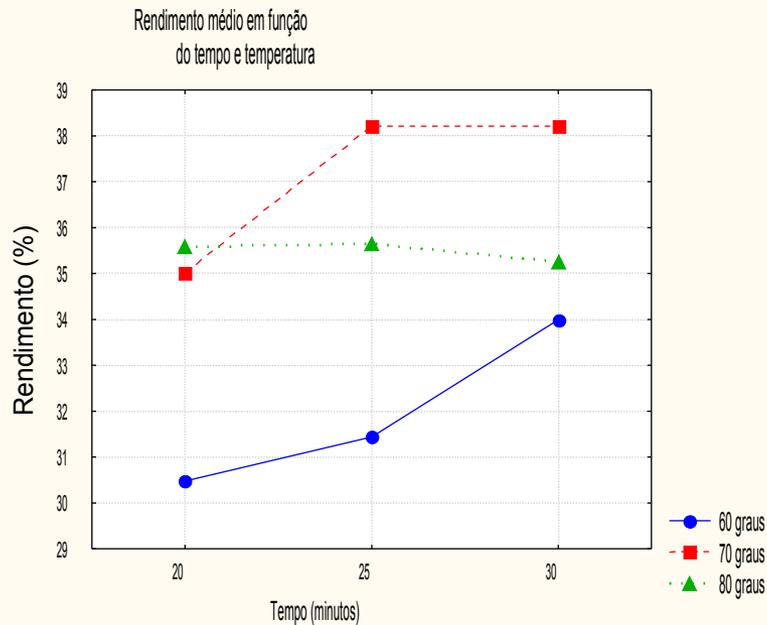
$$s = \sqrt{\frac{4 + 1 + 1 + 0 + 0 + 1 + 1 + 4}{8 - 1}} = \sqrt{1,71} = 1,31$$

# Medidas descritivas das notas finais dos alunos de três turmas.

Turma	Número de alunos	Média	Desvio padrão
A	8	6,00	1,31
B	8	6,00	3,51
C	7	6,00	2,69

Interprete.

# Ex: Rendimento de um processo químico



Interprete.

# Outra forma de calcular o desvio padrão

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

Valores

$x_i$ : 4 5 5 6 6 7 7 8

Valores ao quadrado

$x_i^2$ : 16 25 25 36 36 49 49 64

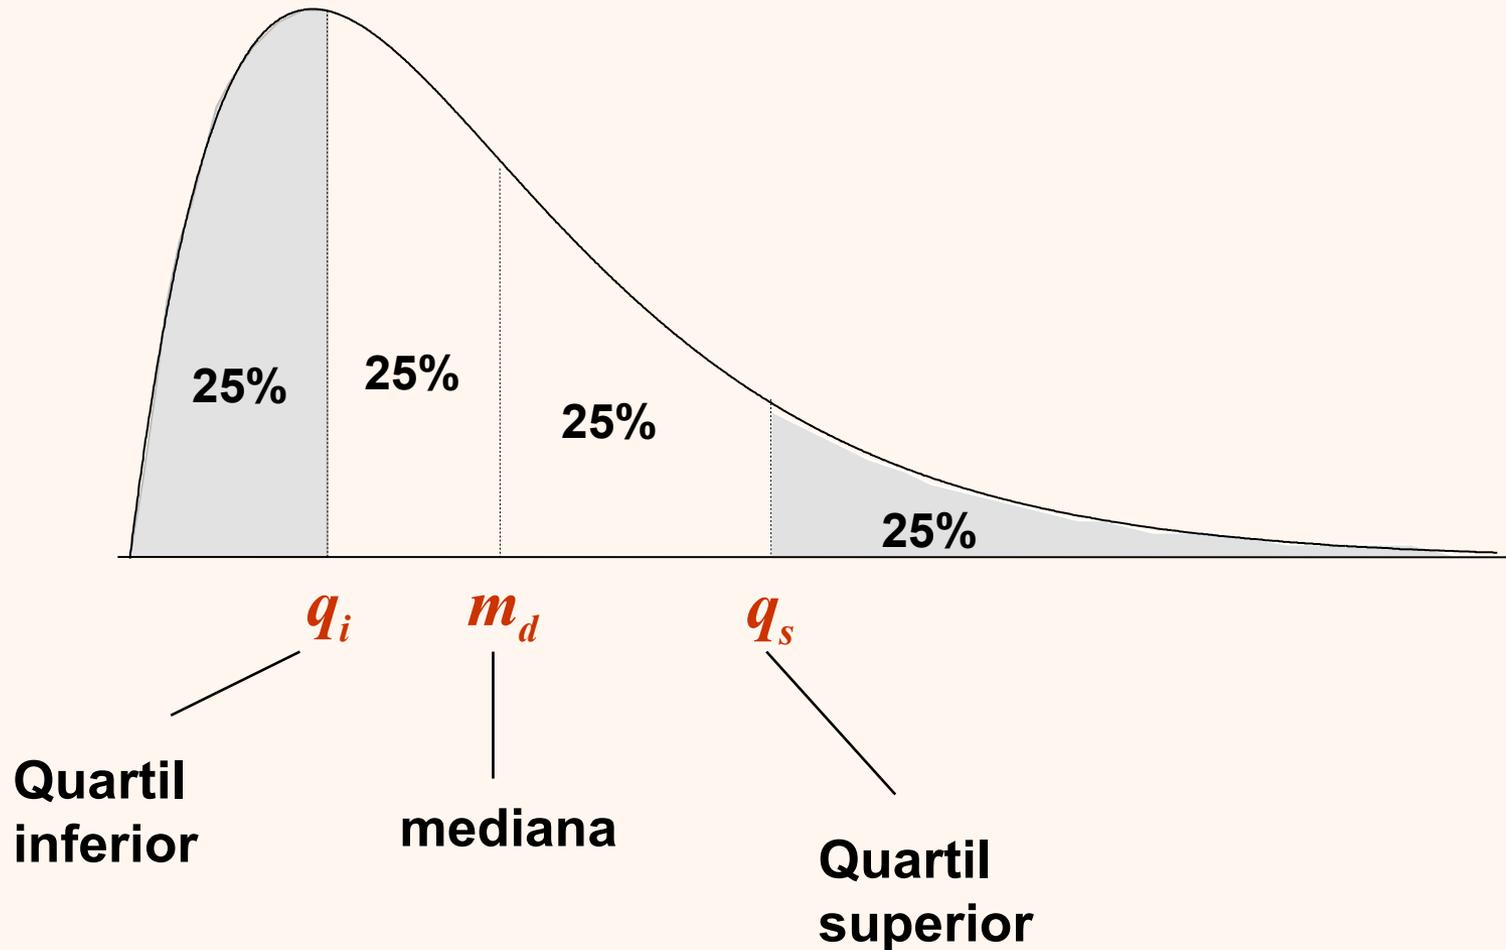
$$\sum_{i=1}^n x_i = 48$$

$$\bar{x} = 6$$

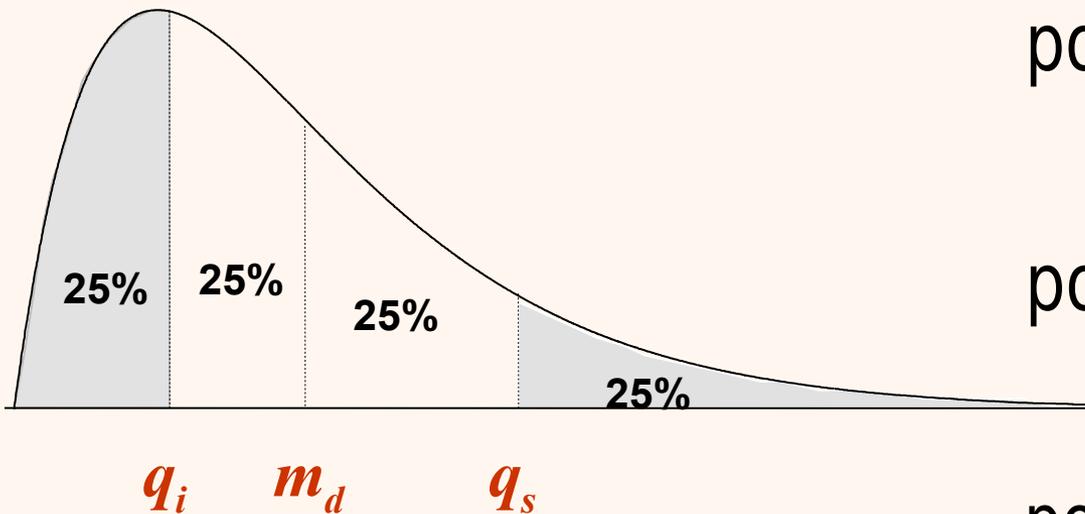
$$\sum_{i=1}^n x_i^2 = 300$$

$$s = \sqrt{\frac{300 - 8 \cdot (6)^2}{7}} = \sqrt{\frac{300 - 288}{7}} = \sqrt{\frac{12}{7}} = 1,31$$

# Medidas baseadas na ordenação dos dados



# Medidas baseadas na ordenação dos dados



Dados ordenados:

$$\text{posição de } q_i: \frac{n+1}{4}$$

$$\text{posição de } m_d: \frac{n+1}{2}$$

$$\text{posição de } q_s: \frac{3(n+1)}{4}$$

Se fracionário → interpolação linear

# Exemplo

Observações: 15, 18, 5, 7, 9, 11, 3, 5, 6, 8, 12.

Ordenando:

**3** **5** **5** **6** **7** **8** **9** **11** **12** **15** **18**

$n = 11$

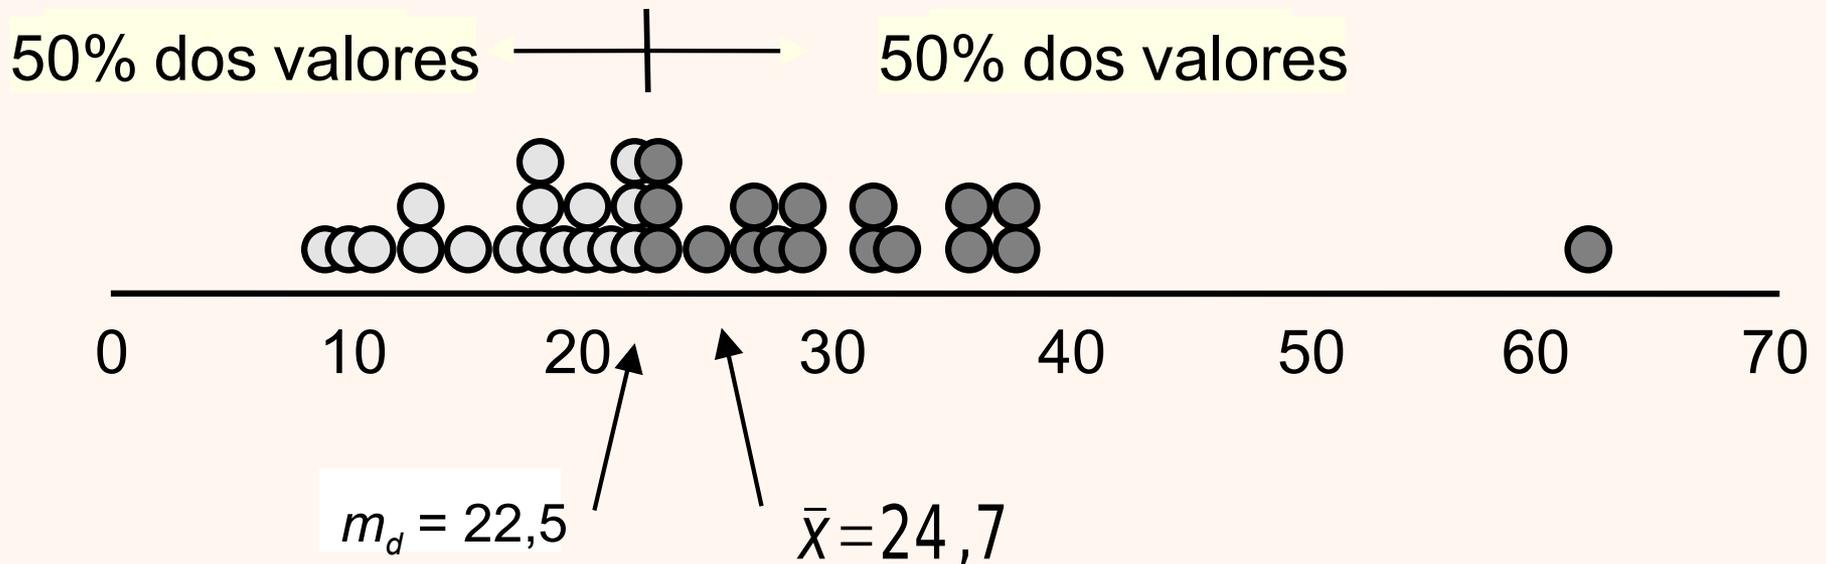
posição de  $q_i$ :  $\frac{n+1}{4} = 3$    $q_i = 5$

posição de  $m_d$ :  $\frac{n+1}{2} = 6$    $m_d = 8$

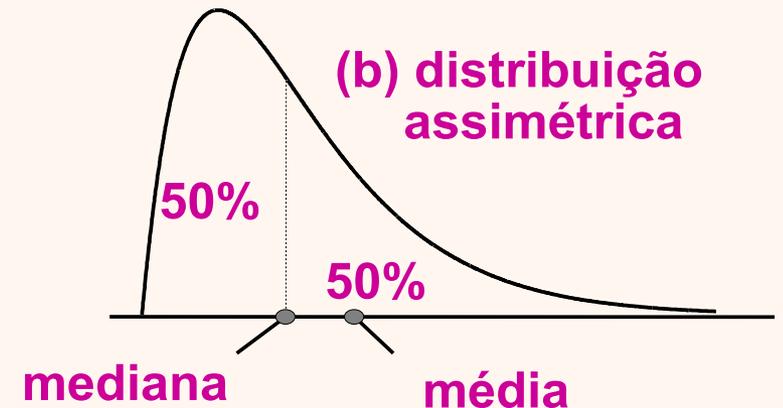
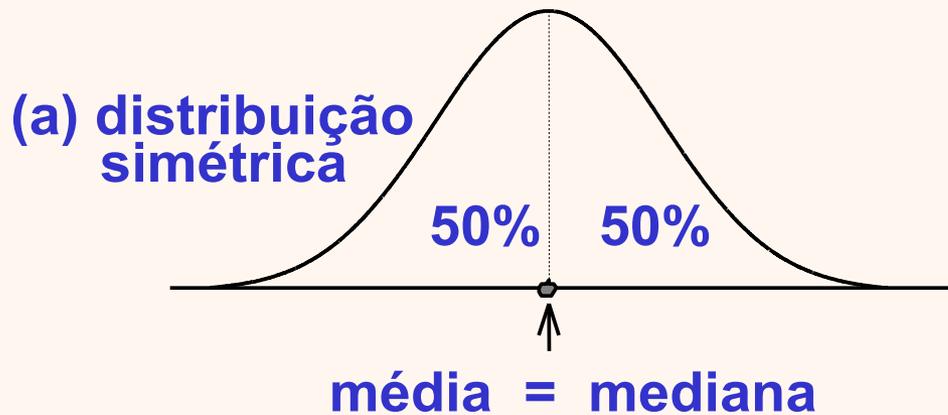
posição de  $q_s$ :  $\frac{3(n+1)}{4} = 9$    $q_s = 12$

# Comparação entre média e mediana

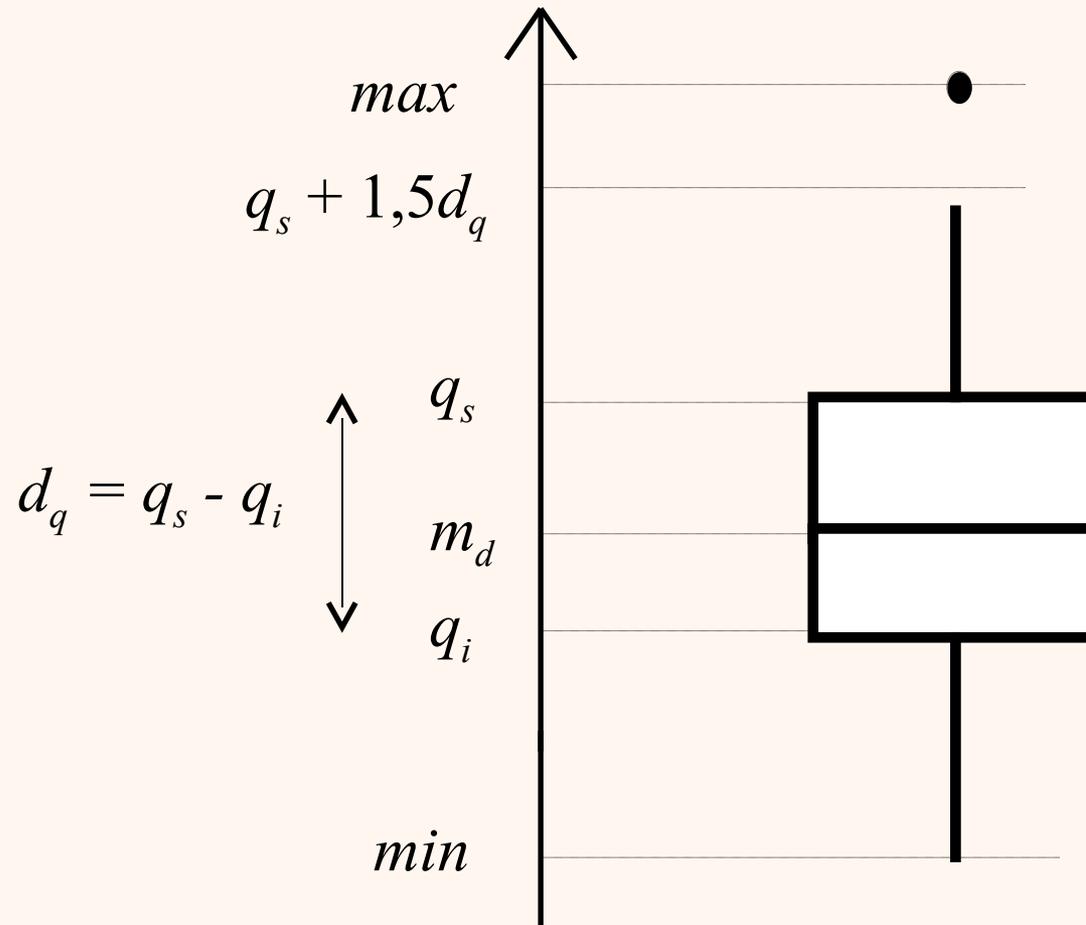
- A média é mais influenciada por valores discrepantes.



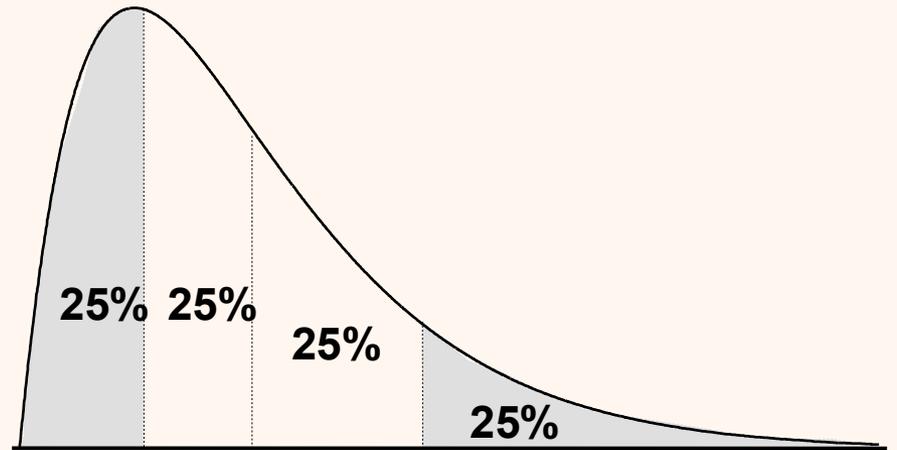
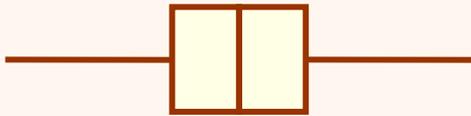
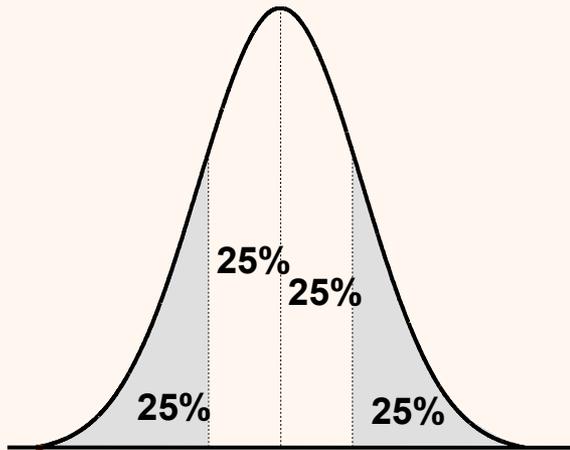
# Comparação entre média e mediana



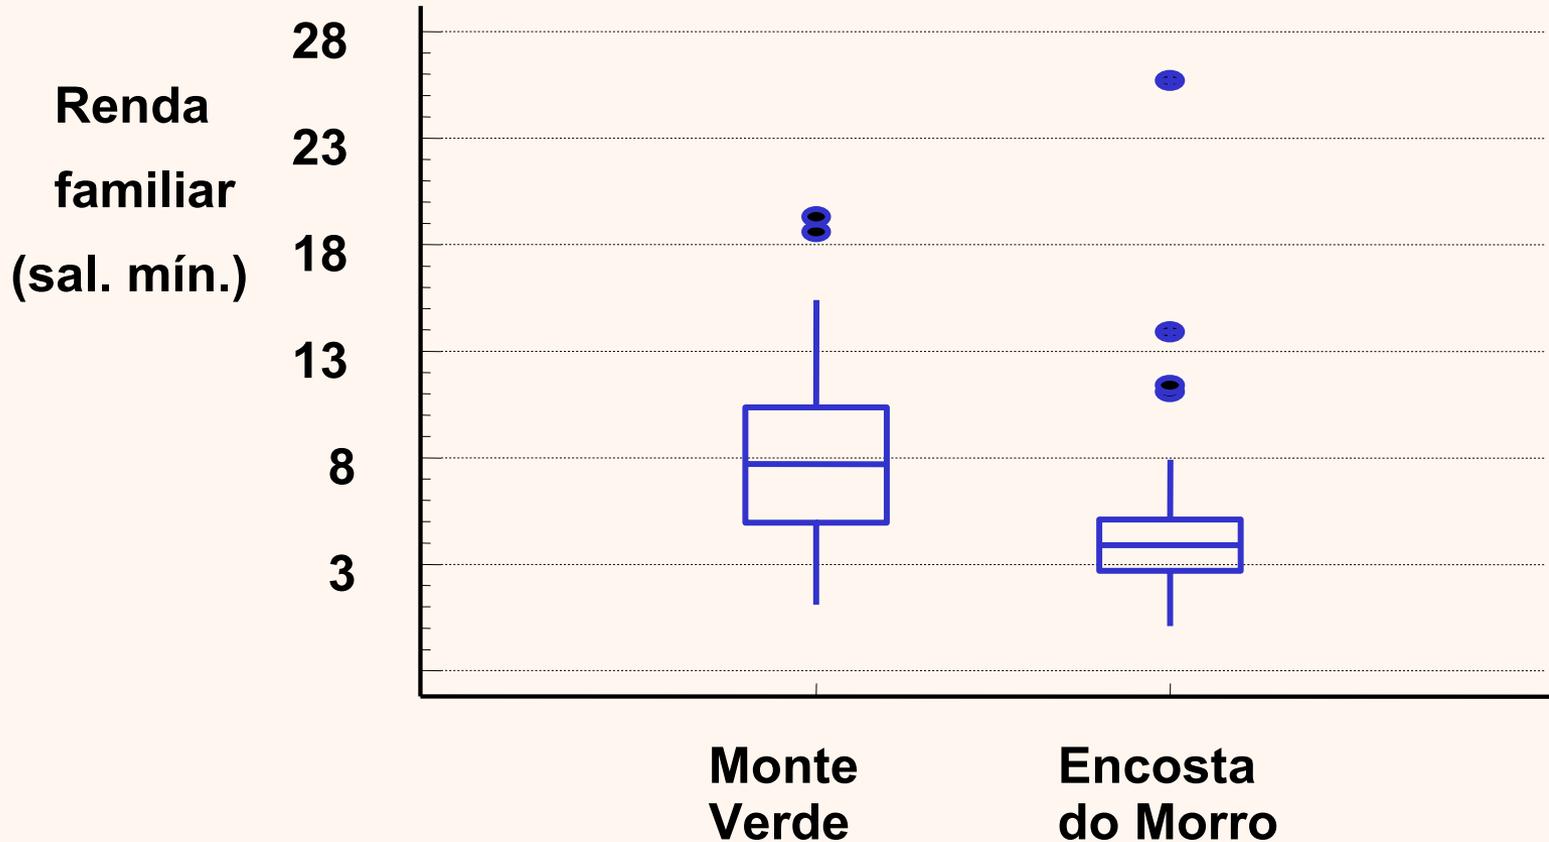
# Diagrama em caixas



# Diagrama em caixas e forma da distribuição



# Interprete o gráfico

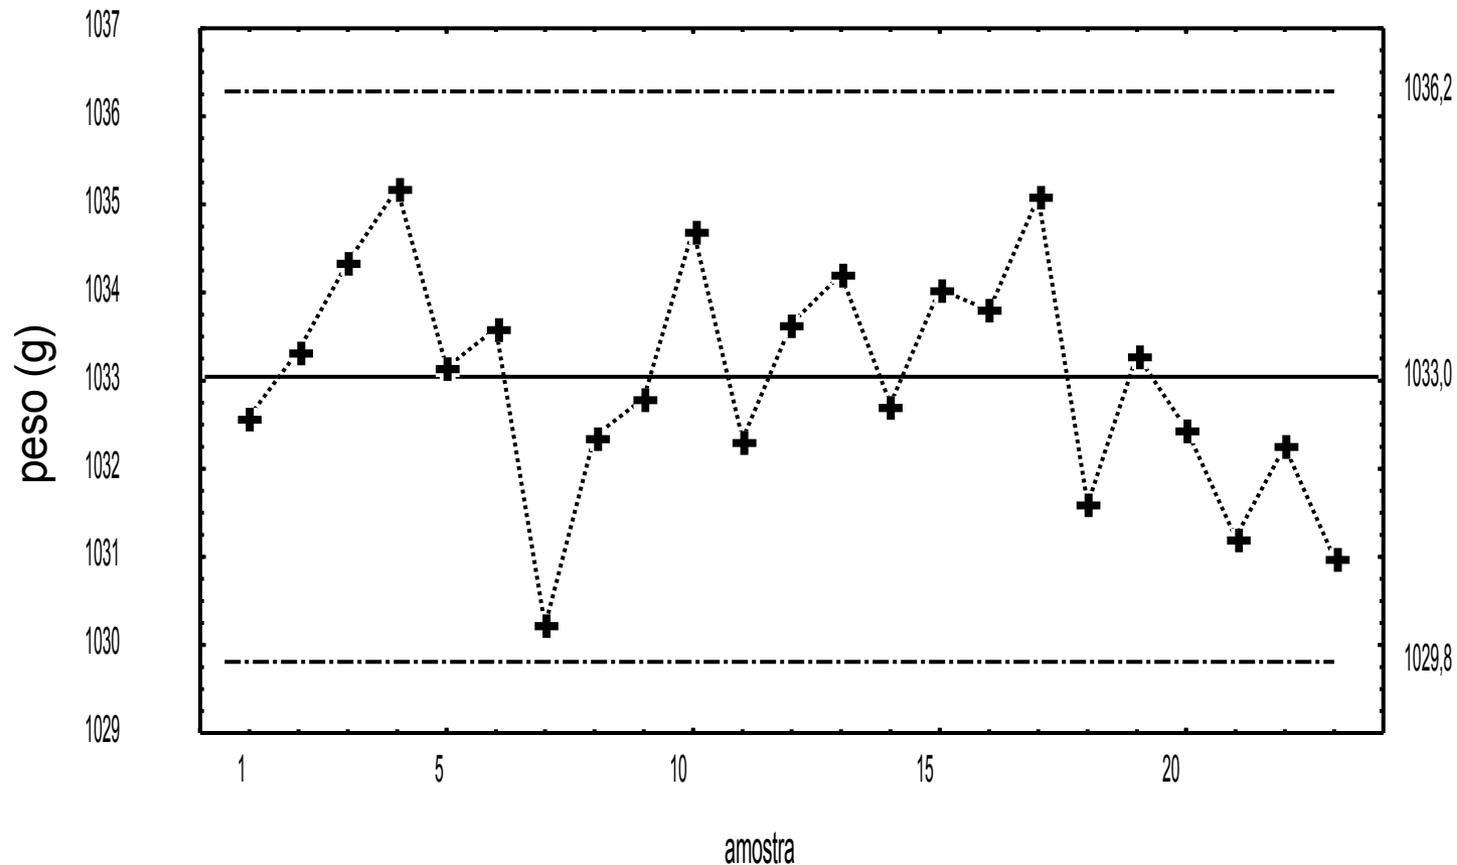


# Observações ao longo do tempo

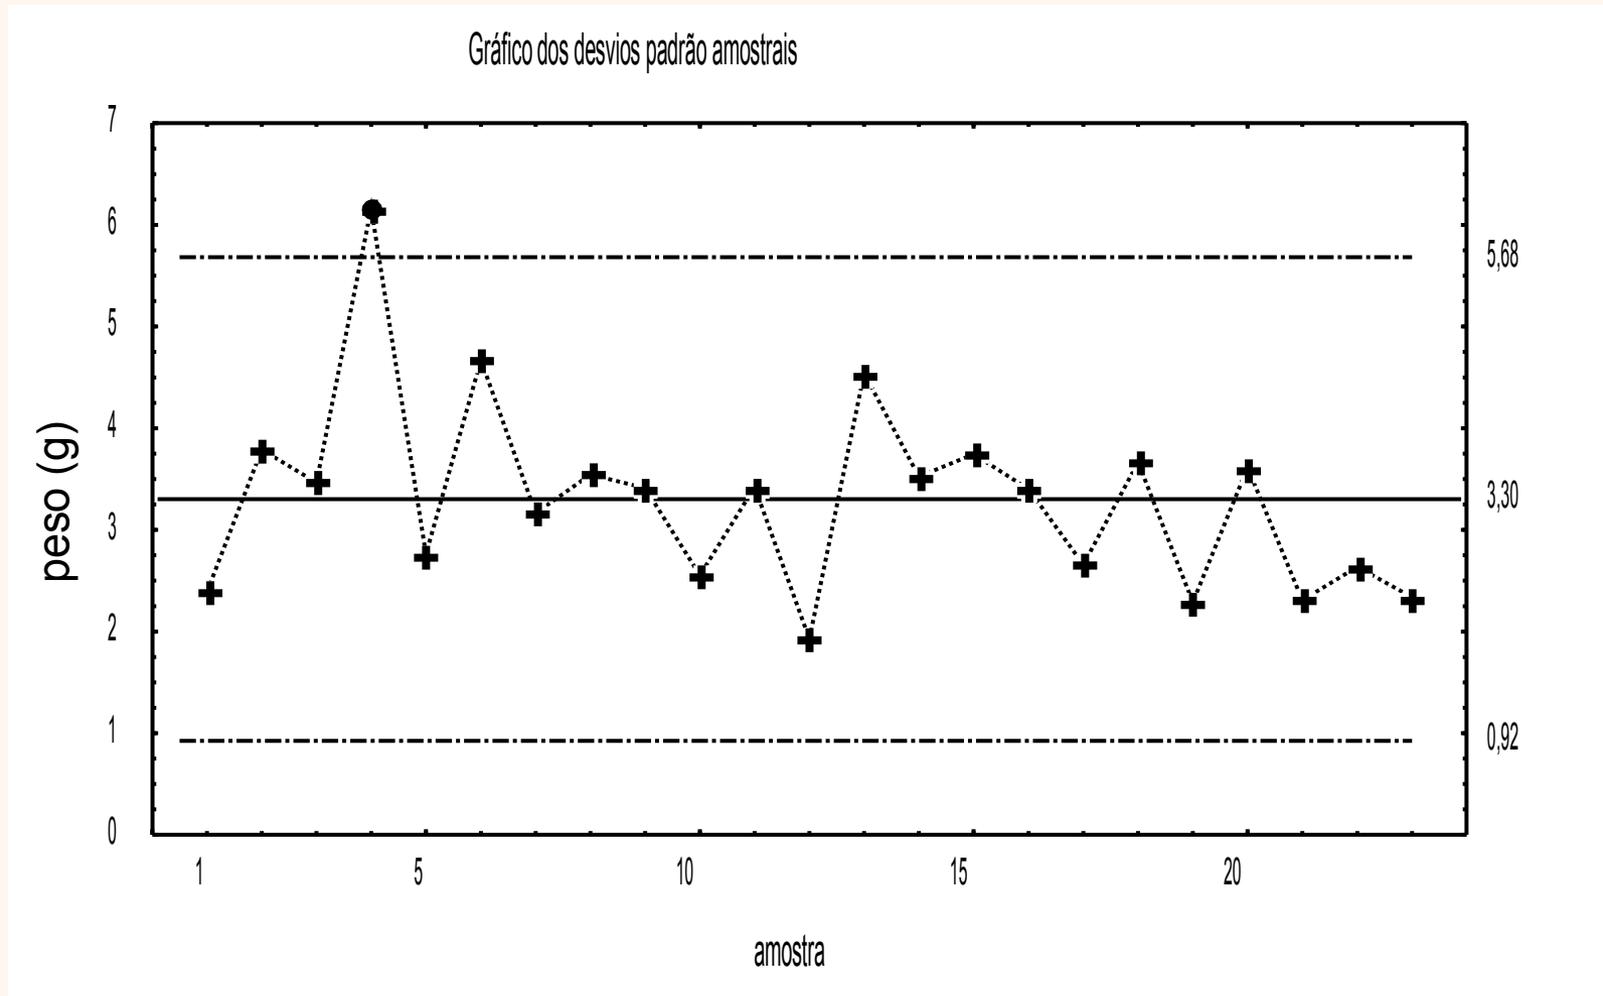
- EXEMPLO: todos os dias é retirada uma amostra de dez sacos de leite de um laticínio, durante 23 dias.
- Quer-se acompanhar o nível e a variabilidade do peso.

# Observações ao longo do tempo

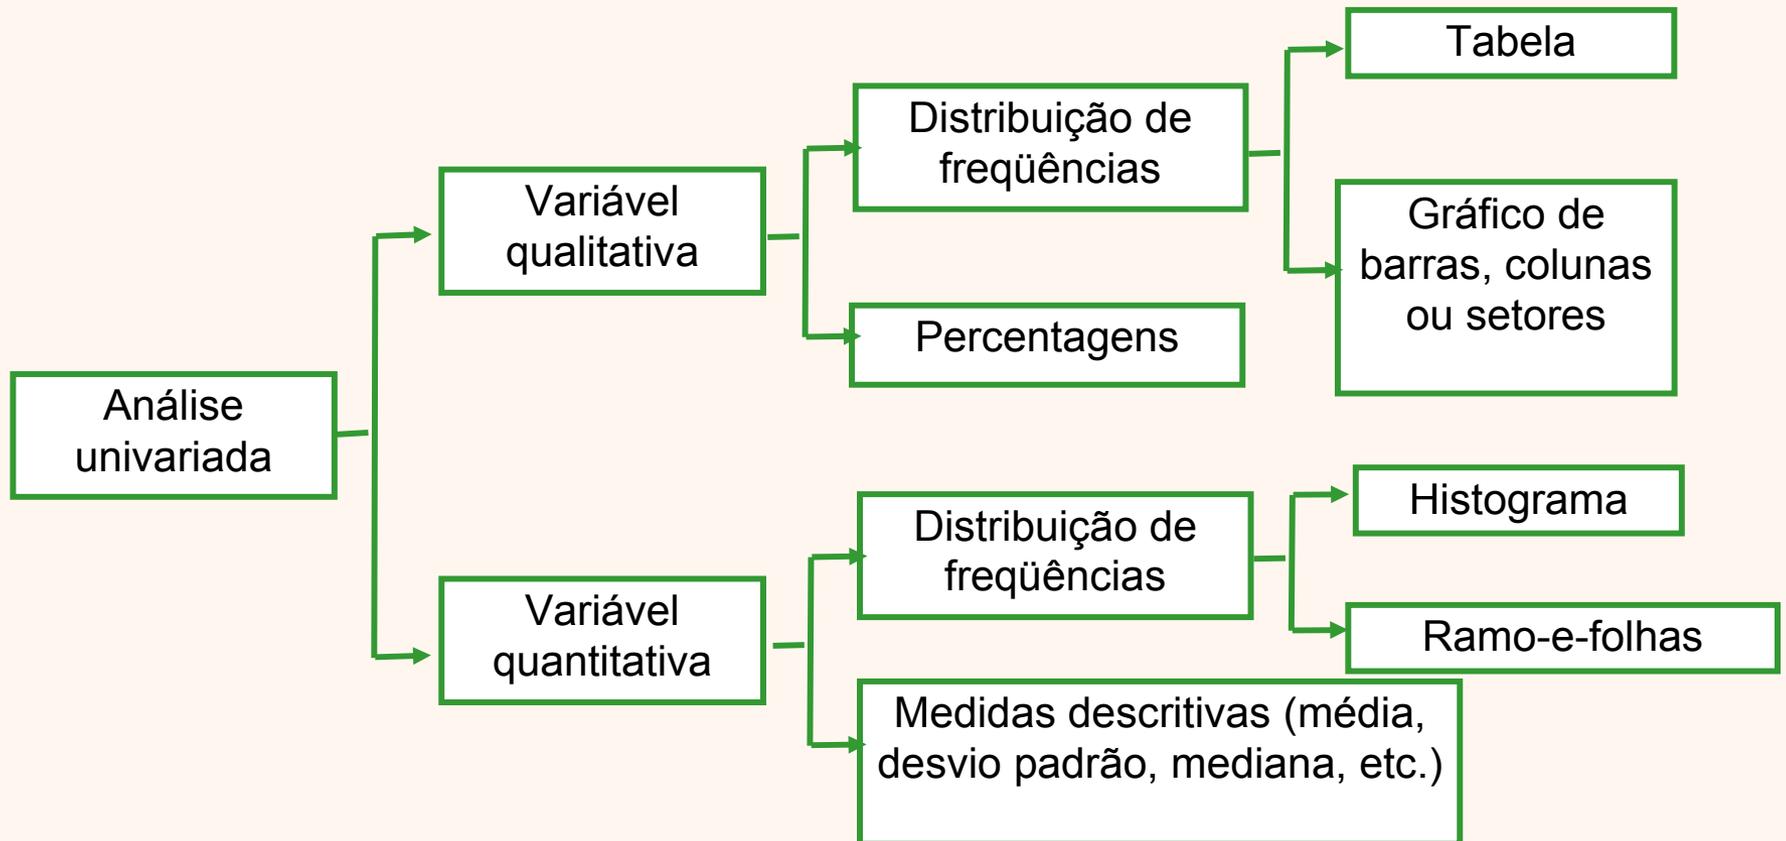
Gráfico das médias amostrais



# Observações ao longo do tempo



# Orientação geral para análise exploratória de dados não temporais



# Orientação geral para análise exploratória de dados não temporais

