

Estadística Descriptiva (I)

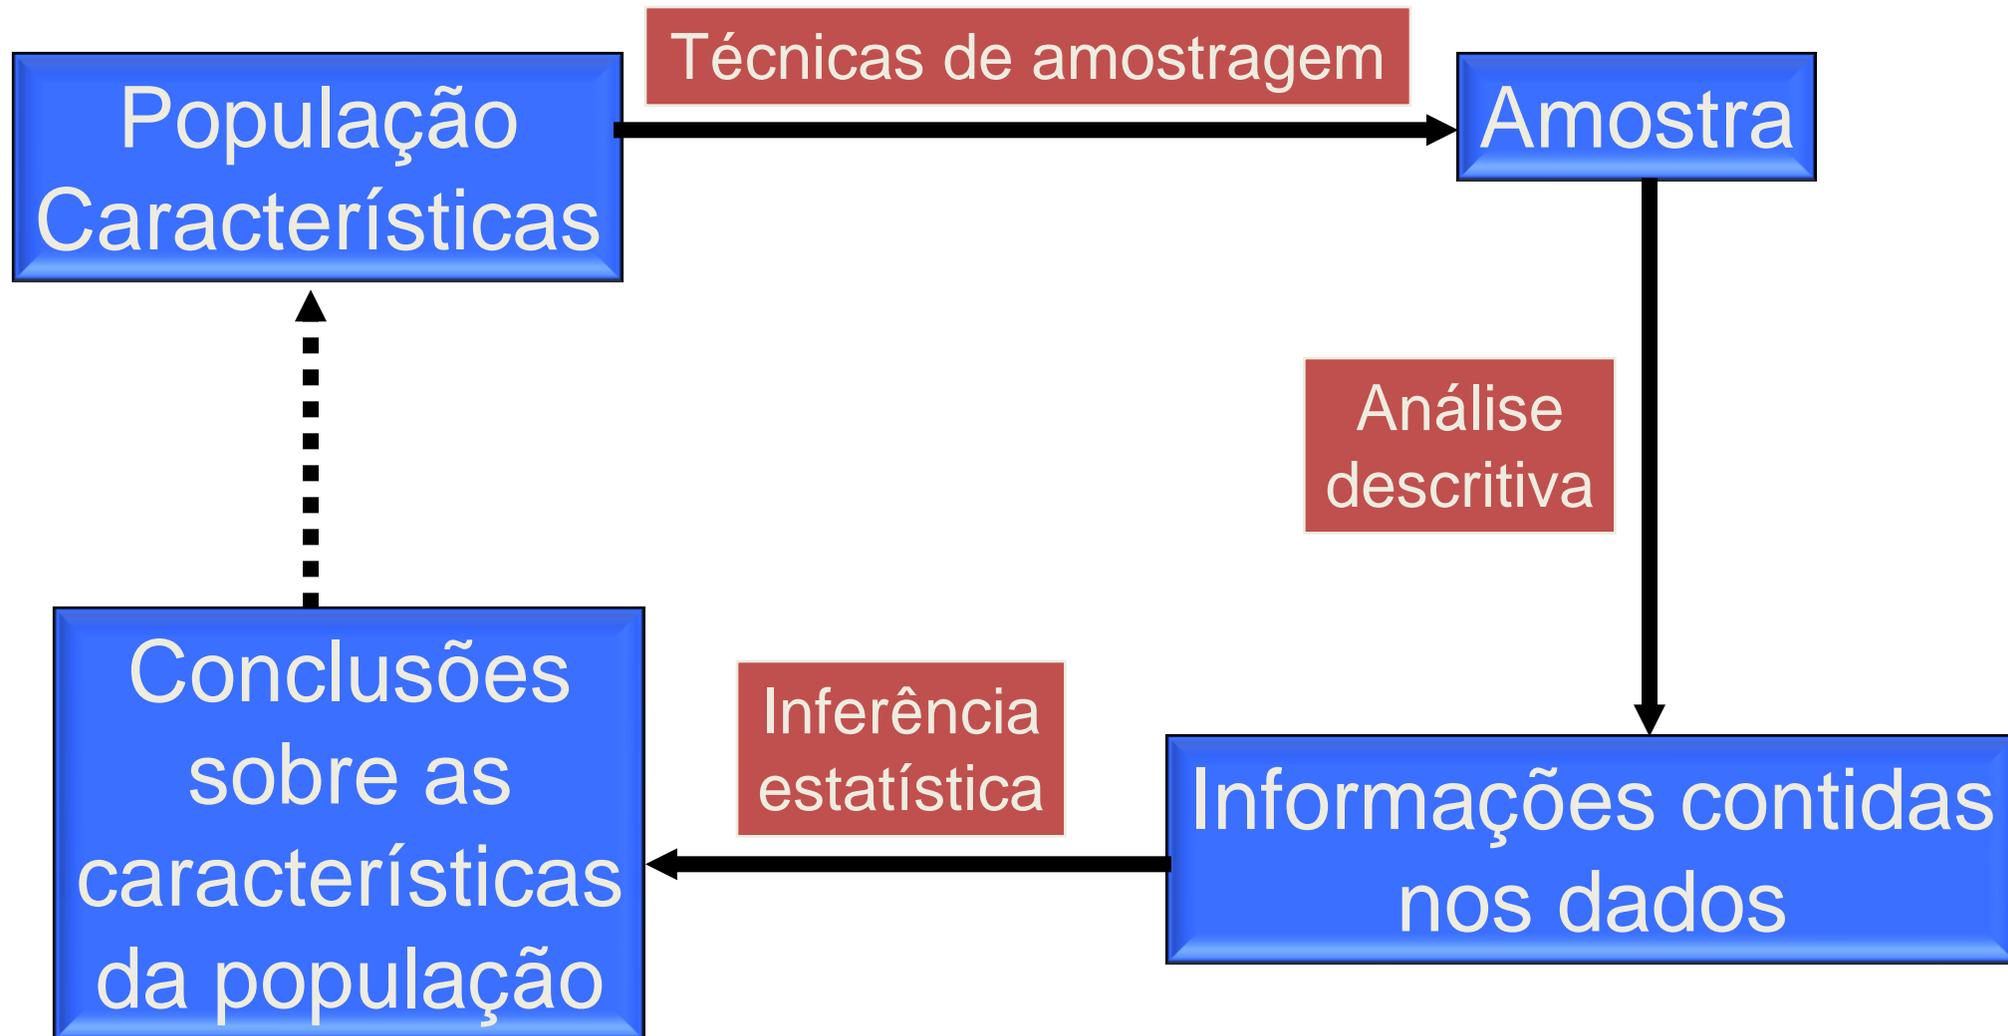
O que é Estatística

- Origem relacionada com a coleta e construção de tabelas de dados para o governo.
- A situação evoluiu: a coleta de dados representa somente um dos aspectos da Estatística.
- No século XIX, o desenvolvimento do cálculo de probabilidade e outras metodologias matemáticas, tais como a técnica de *Mínimos Quadrados*, foram fundamentais para o desenvolvimento da Estatística.

O que é Estatística

- No século XX a Estatística desenvolve-se como uma área específica do conhecimento a partir do desenvolvimento da *Inferência Estatística*, metodologia que faz uso da *Teoria das Probabilidades* e com ampla aplicação em ciências experimentais.
- A Estatística hoje consiste em uma metodologia científica para obtenção, organização e análise de dados oriundos das mais variadas áreas das ciências experimentais, cujo objetivo principal é auxiliar a tomada de decisões em situações de incerteza.

Estatística



Amostragem

Associada à coleta de dados, a tecnologia da amostragem desenvolveu um conjunto de técnicas para obtenção de amostras convenientemente obtidas da população de interesse.

Exemplos de uso:

- Pesquisas de mercado
- Pesquisas de opinião pública
- Ensaios clínicos
- Estudos Experimentais

Estadística Descritiva

Etapa inicial da análise utilizada para descrever, organizar e resumir os dados coletados.

A disponibilidade de uma grande quantidade de dados e de métodos computacionais muito eficientes revigorou esta área da Estatística.

Probabilidade

A teoria das probabilidades auxilia na modelagem de fenômenos aleatórios, ou seja, aqueles em que está presente a incerteza.

É uma ferramenta fundamental para a inferência estatística.

Inferência Estatística

Conjunto de técnicas que permite, a partir de dados amostrais, tirar conclusões sobre a população de interesse, controlando erros.

Exemplo 1:

Numa pesquisa eleitoral, um instituto de pesquisa tem como objetivo prever o resultado da eleição, utilizando uma amostra da população.

Considere o Candidato “A”:

Denomine por p a proporção de pessoas (na população) que votarão em “A” na eleição.

Denomine por \hat{p} a proporção de pessoas no levantamento de opinião que expressam intenção de voto em “A”.

Estimação: Podemos usar o valor de \hat{p} para *estimar* a proporção p da população.

Em anos de eleições, os institutos de pesquisa de opinião colhem periodicamente amostras de eleitores para obter as estimativas de intenção de voto da população. As estimativas são fornecidas com um valor e uma margem de erro.

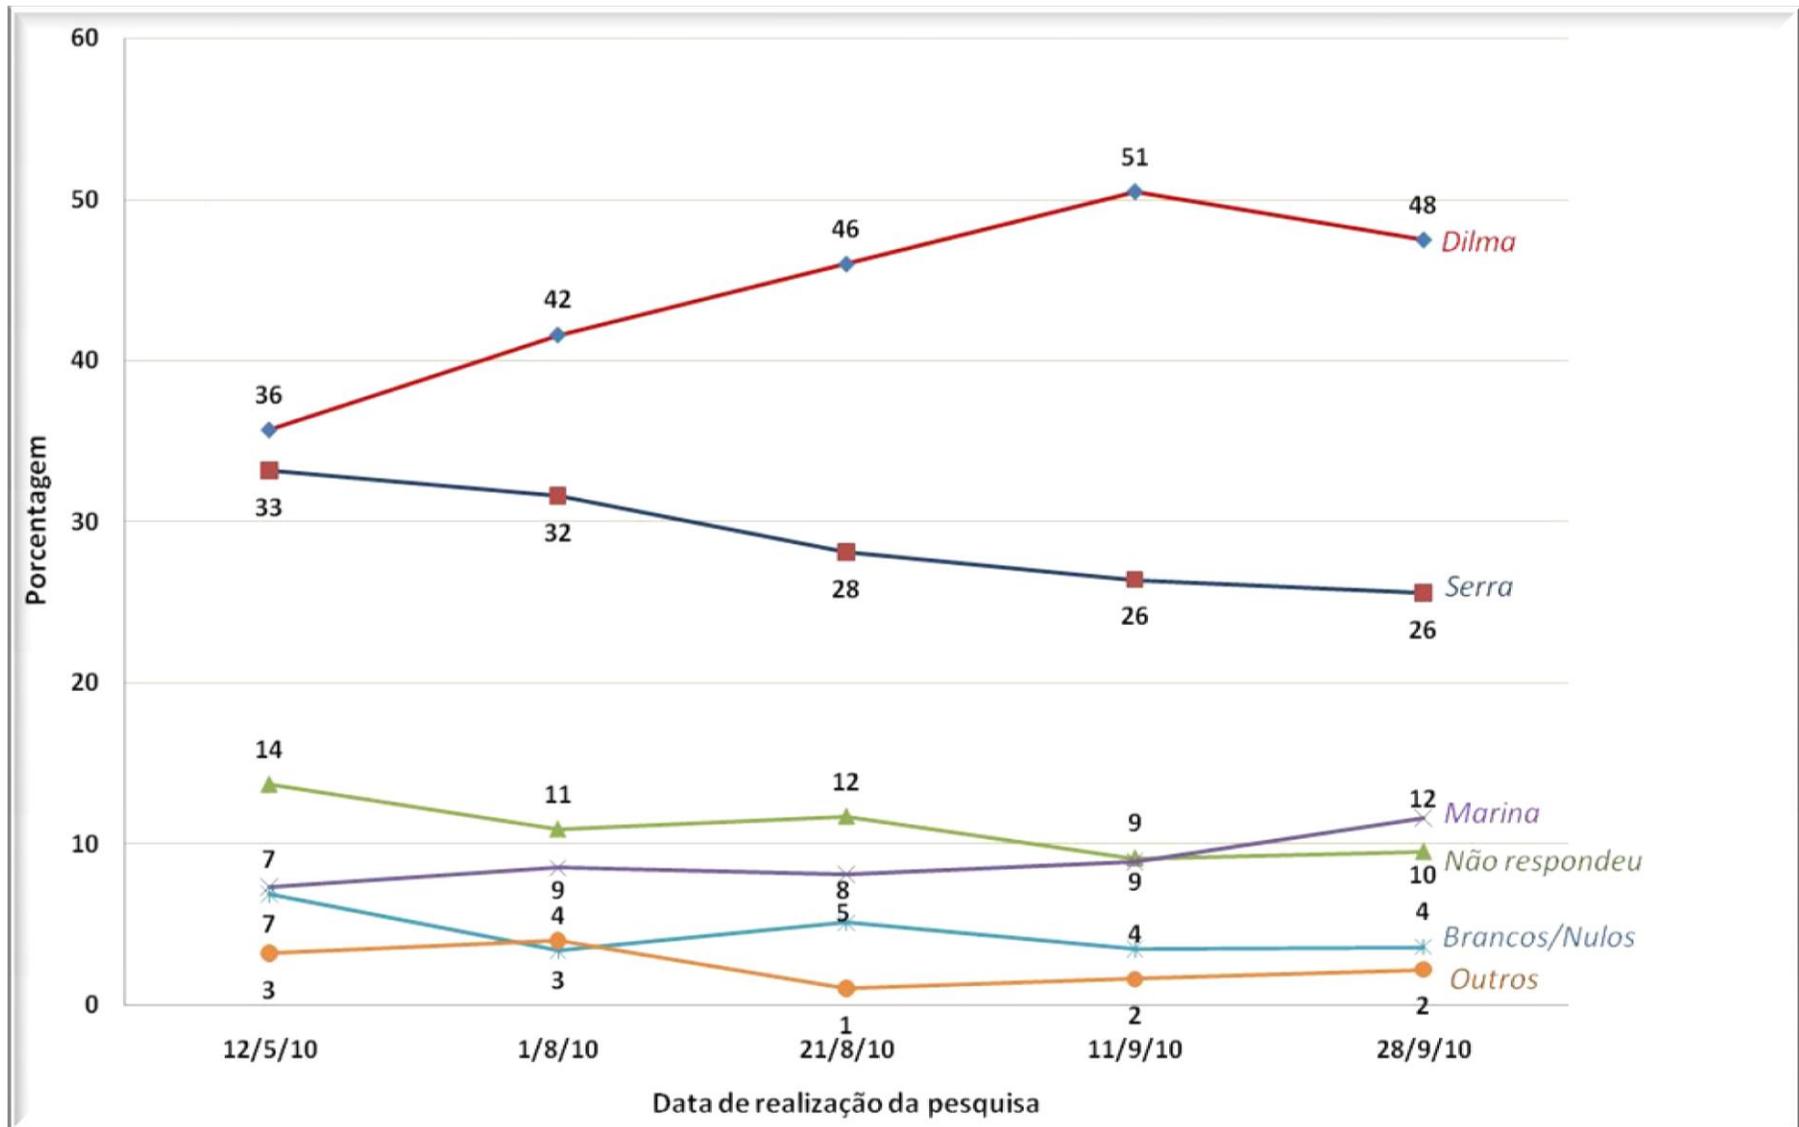
Pesquisa Sensus

Os quadros apresentados a seguir referem-se à intenção de voto para presidente do Brasil para o primeiro e segundo turnos das eleições de 2010.

A resposta foi estimulada e única.

Pergunta realizada: *Se a eleição para presidente fosse hoje e os candidatos fossem estes, em quem o(a) Sr.(Sra) votaria?*

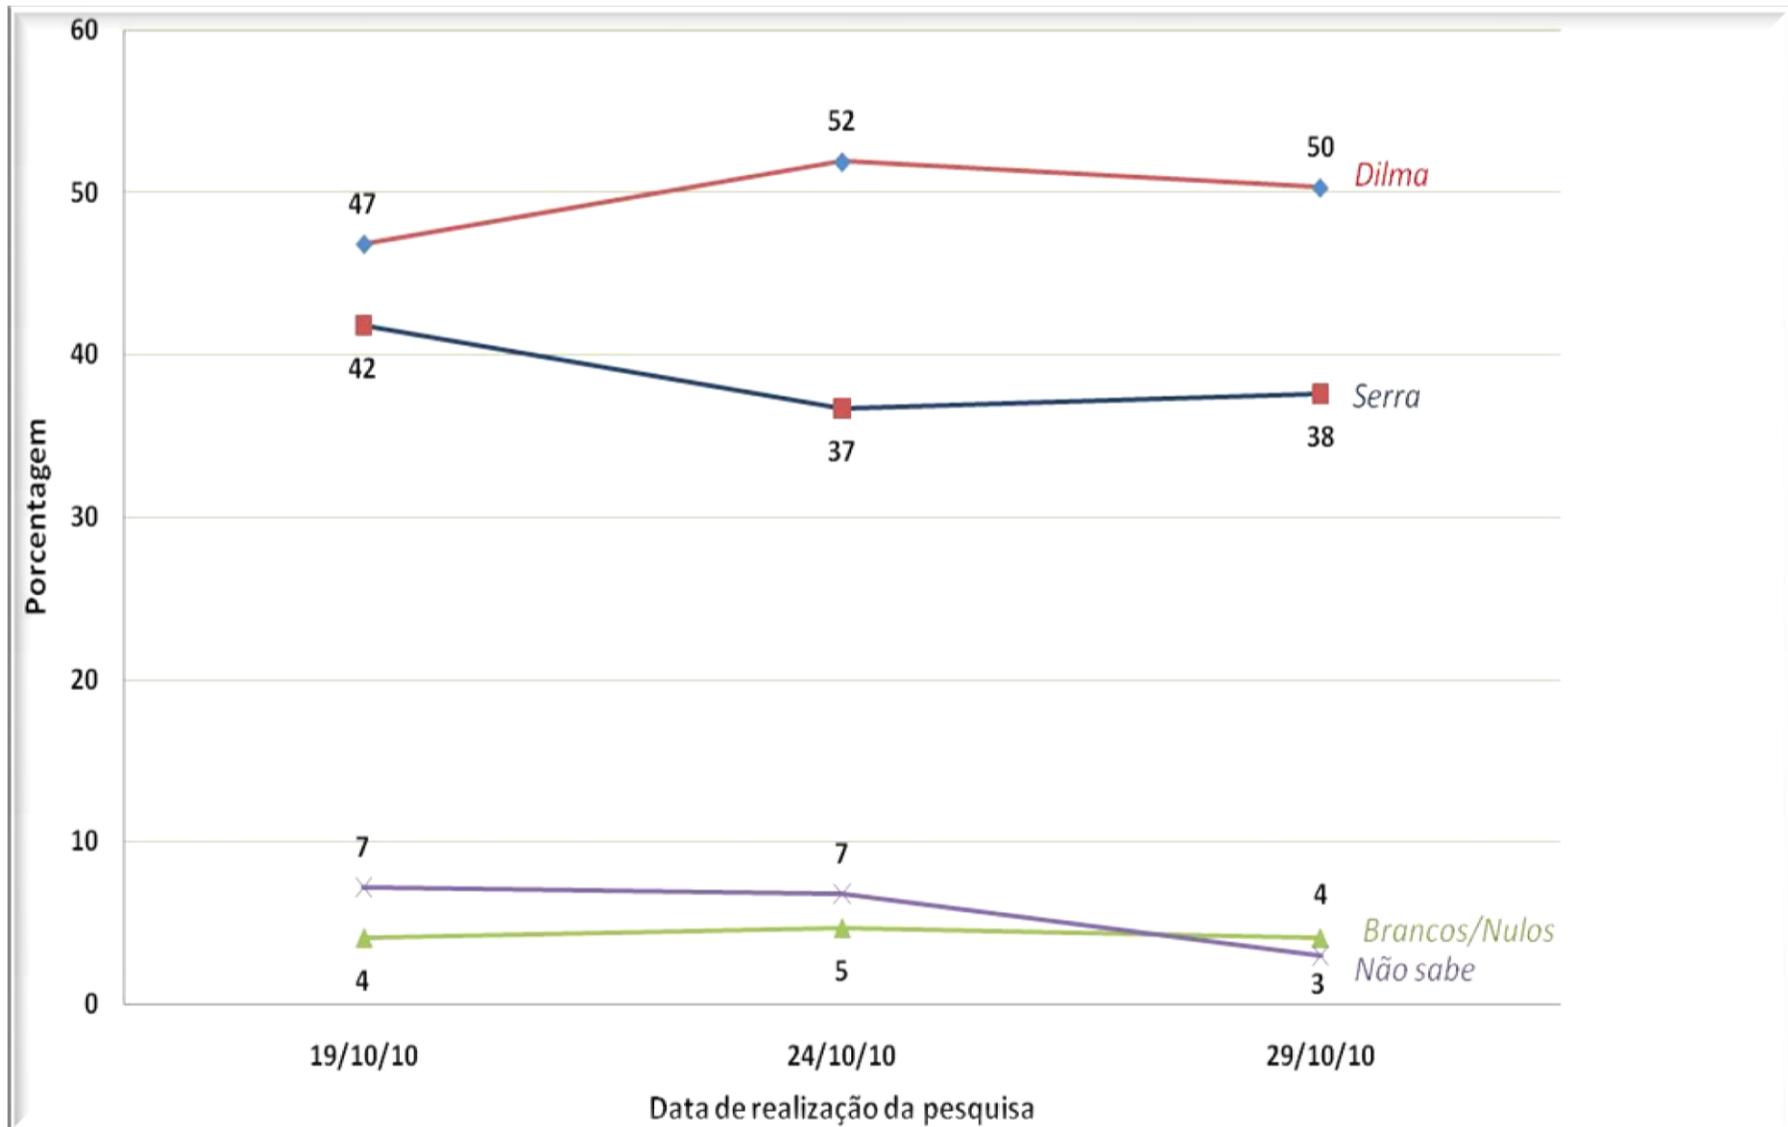
Intenção de voto para presidente do Brasil, 1º Turno – 2010



Pesquisa Sensus, em % do total de votos.

2.000 eleitores - Margem de erro de 2,2% com 95% de confiança.

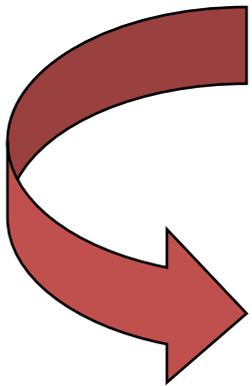
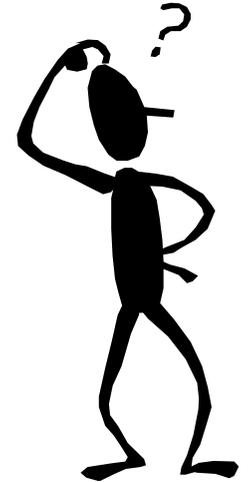
Intenção de voto para presidente do Brasil, 2º Turno – 2010



**Pesquisa Sensus, em % do total de votos.
2.000 eleitores - Margem de erro de 2,2% com 95% de confiança.**

Estatística Descritiva

O que fazer com as observações
que coletamos?



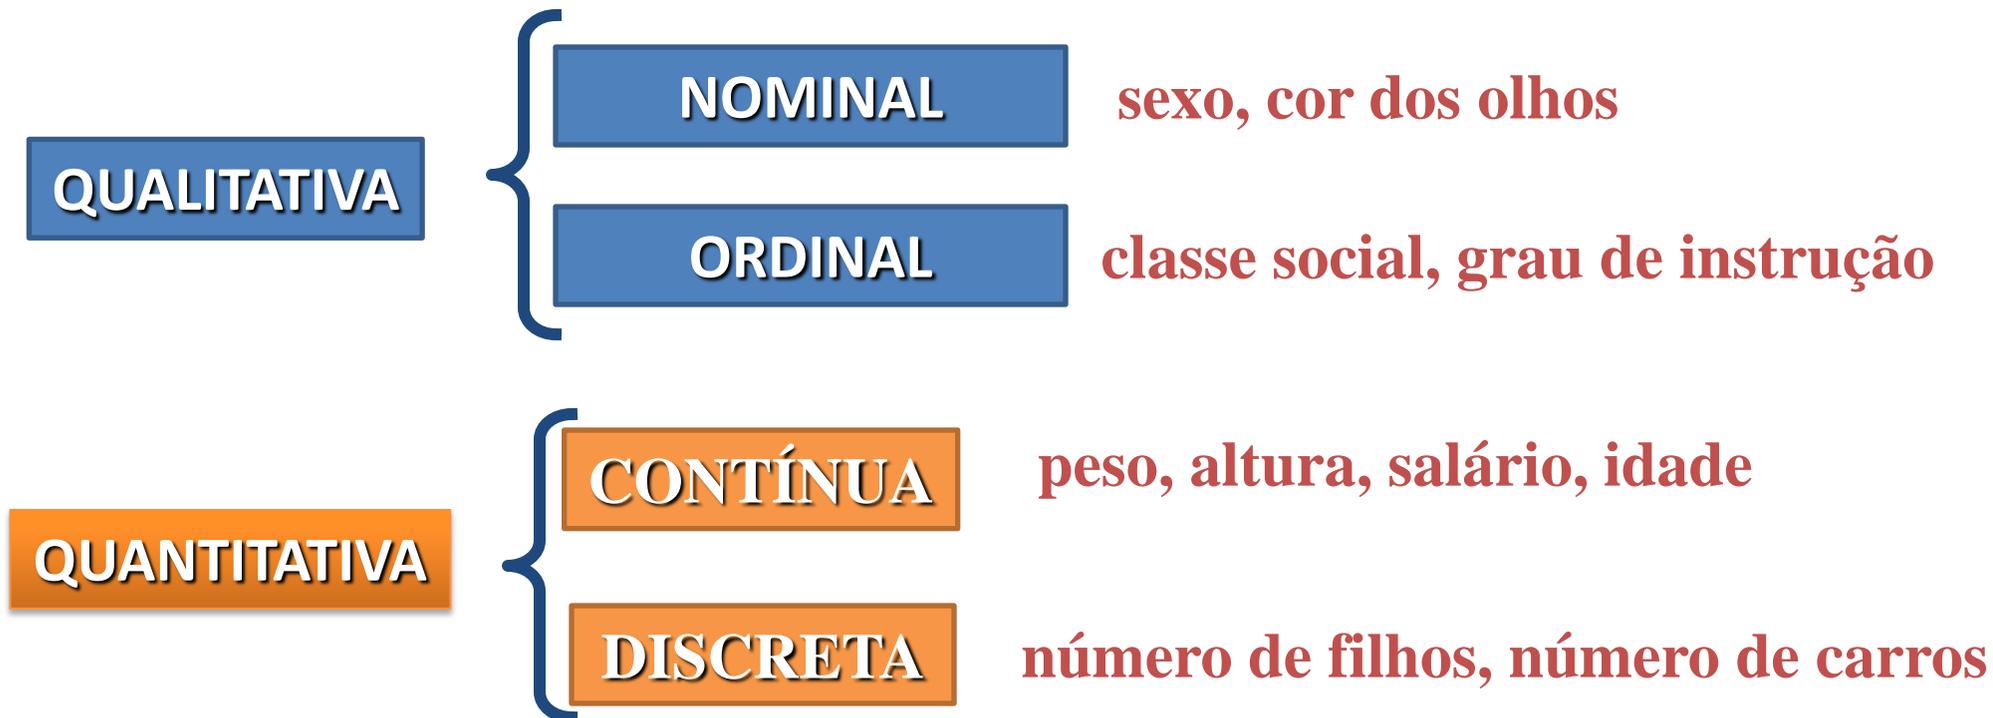
Primeira Etapa:

Resumo dos dados = Estatística descritiva

Variável:

Qualquer característica associada a uma população.

Classificação das variáveis:



Variáveis Quantitativas

MEDIDAS DE POSIÇÃO:

Mínimo, Máximo, Moda, Média, Mediana, Percentis

MEDIDAS DE DISPERSÃO:

Amplitude, Intervalo-Interquartil, Variância, Desvio Padrão, Coeficiente de Variação.

Medidas de Posição

- **Máximo (max)**: a maior observação
- **Mínimo (min)**: a menor observação
- **Moda (mo)**: é o valor (ou atributo) que ocorre com maior frequência.

Dados: 4, 5, 4, 6, 5, 8, 4

$$\text{max} = 8$$

$$\text{min} = 4$$

$$\text{mo} = 4$$

• Média:

$$\bar{x} = \frac{x_1 + x_2 + x_3 + \dots + x_n}{n} = \frac{\sum_{i=1}^n x_i}{n}$$

Dados: 2, 5, 3, 7, 8

$$\bar{x} = \frac{2+5+3+7+8}{5} = 5$$

- **Mediana:**

A mediana é o valor da variável que ocupa a posição central de um conjunto de n dados ordenados.

Posição da mediana: $\frac{n+1}{2}$

Exemplos:

Dados: 2, 6, 3, 7, 8 $\Rightarrow n = 5$ (ímpar)

Dados ordenados: 2 3 6 7 8 $\Rightarrow \frac{5+1}{2} = 3 \Rightarrow Md=6$

Posição da Mediana \uparrow

Dados: 4, 8, 2, 1, 9, 6 $\Rightarrow n = 6$ (par)

Dados ordenados: 1 2 4 6 8 9 $\Rightarrow \frac{6+1}{2} = 3,5$

\uparrow
Md

$$Md = (4 + 6) / 2 = 5$$

Percentis:

O percentil de ordem $p \times 100$ ($0 < p < 1$), em um conjunto de dados de tamanho n , é o valor da variável que ocupa a posição $p \times (n + 1)$ do conjunto de dados ordenados.

Casos particulares:

percentil 50 = mediana ou segundo quartil (Md)

percentil 25 = primeiro quartil (Q_1)

percentil 75 = terceiro quartil (Q_3)

percentil 10 = primeiro decil

Dados: 1,9 2,0 2,1 2,5 3,0 3,1 3,3 3,7 6,1 7,7 $\Rightarrow n=10$

Posição de Md : $0,5(n+1) = 0,5 \times 11 = 5,5 \Rightarrow Md = (3 + 3,1)/2 = 3,05$

Posição de $Q1$: $0,25 (11) = 2,75 \Rightarrow Q_1 = (2 + 2,1)/2 = 2,05$

Posição de $Q3$: $0,75 (11) = 8,25 \Rightarrow Q_3 = (3,7 + 6,1)/2 = 4,9$

$$Md = 3,05$$

$$Q_1 = 2,05$$

$$Q_3 = 4,9$$

Dados: 0,9 1,0 1,7 2,9 3,1 5,3 5,5 12,2 12,9 14,0 33,6

$\Rightarrow n=11$

$$Md = 5,3$$

$$Q1 = 1,7$$

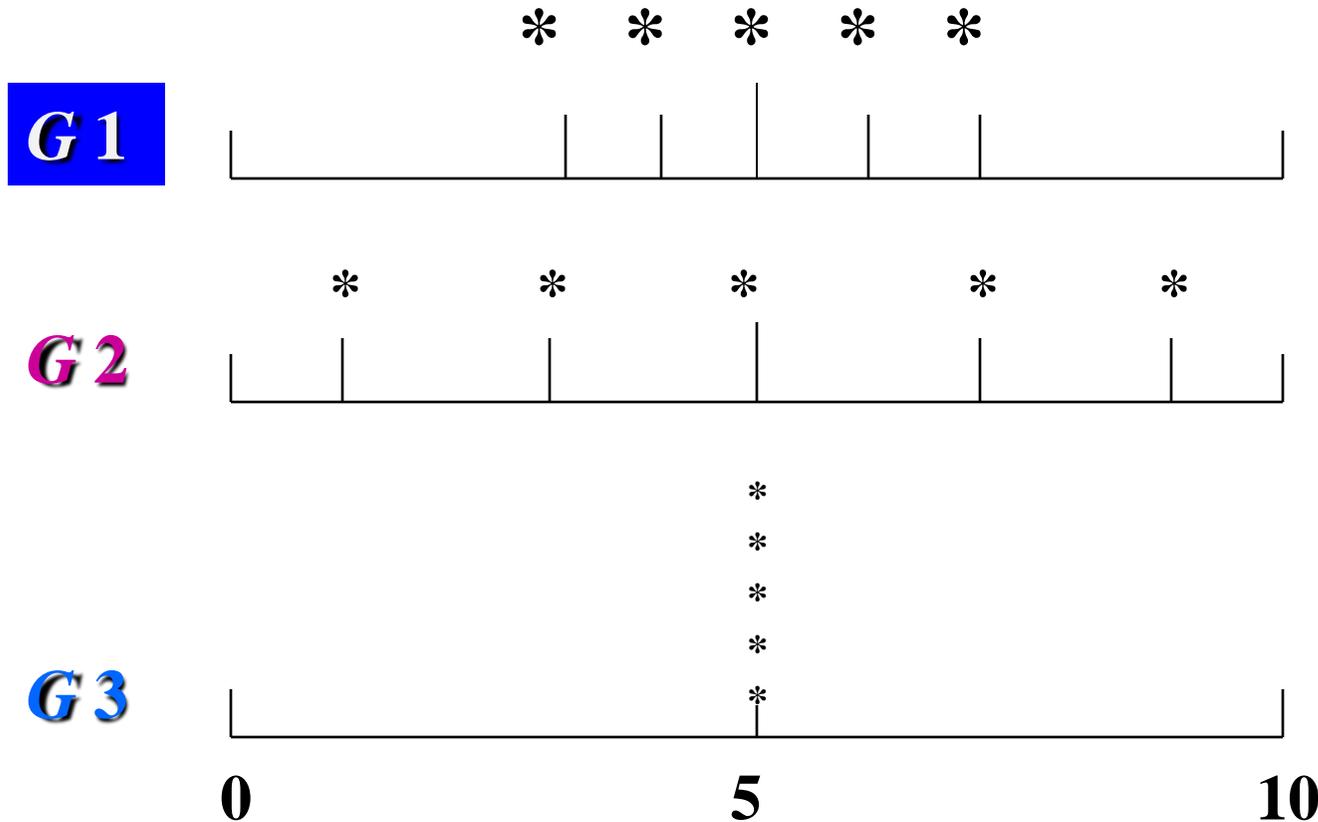
$$Q3 = 12,9$$

Exemplo 2: Considere as notas de um teste de 3 grupos de alunos

Grupo 1: 3,4,5,6,7

Grupo 2: 1, 3, 5, 7, 9

Grupo 3: 5,5,5,5,5



Temos: $\bar{x}_1 = \bar{x}_2 = \bar{x}_3 = 5$ e $md_1 = md_2 = md_3 = 5$

Medidas de Dispersão

Finalidade: encontrar um valor que resuma a variabilidade de um conjunto de dados

- Amplitude (A):

$$A = \textit{máx} - \textit{min}$$

Para os grupos anteriores, temos:

$$\text{Grupo 1, } A = 4$$

$$\text{Grupo 2, } A = 8$$

$$\text{Grupo 3, } A = 0$$

•Intervalo-Interquartil:

É a diferença entre o terceiro quartil e o primeiro quartil, ou seja, $Q3 - Q1$.

Dados: 1,9 2,0 2,1 2,5 3,0 3,1 3,3 3,7 6,1 7,7

$$Q1 = 2,05 \quad e \quad Q3 = 4,9$$

$$Q3 - Q1 = 4,9 - 2,05 = 2,85$$

• Variância:

$$\text{Variância} = s^2 = \frac{(x_1 - \bar{x})^2 + (x_2 - \bar{x})^2 + \dots + (x_n - \bar{x})^2}{n-1} = \sum_{i=1}^n \frac{(x_i - \bar{x})^2}{n-1}$$

• Desvio padrão:

$$\text{Desvio Padrão} = s = \sqrt{\text{Variância}}$$

Cálculo para os grupos:

$$G1: s^2 = \frac{(3-5)^2 + (4-5)^2 + (5-5)^2 + (6-5)^2 + (7-5)^2}{4}$$

$$\Rightarrow s^2 = 10/4 = 2,5 \quad \Rightarrow s = 1,58$$

$$G2: s^2 = 10 \Rightarrow s = 3,16$$

$$G3: s^2 = 0 \Rightarrow s = 0$$

Fórmula alternativa:

$$S^2 = \frac{\sum_{i=1}^n X_i^2 - n\bar{X}^2}{(n-1)}$$

Em **G1**: $\sum X_i^2 = 9 + 16 + 25 + 36 + 49 = 135$

$$\Rightarrow S^2 = \frac{135 - 5 \times (5)^2}{4} = 2,5$$

• Coeficiente de Variação (*CV*)

- é uma medida de dispersão relativa
- elimina o efeito da magnitude dos dados
- exprime a variabilidade em relação à média

$$CV = \frac{s}{\bar{x}} \times 100\%$$

Exemplo 3:

Altura e peso de alunos

	Média	Desvio Padrão	Coef. de Variação
Altura	1,50m	0,05m	3,3%
Peso	50 kg	3.5kg	7%

Conclusão: Os alunos são, aproximadamente, duas vezes mais dispersos quanto ao peso do que quanto à altura.

Exemplo 4:

Altura (em *cm*) de uma amostra de recém-nascidos e de uma amostra de adolescentes

	Média	Desvio padrão	Coef. de variação
Recém-nascidos	50	6	12%
Adolescentes	160	16	10%

Conclusão: Em relação às médias, as alturas dos adolescentes e dos recém-nascidos apresentam variabilidade quase iguais.