


CURSO SOBRE MEDIDAS DESCRITIVA

Adriano Mendonça Souza
Departamento de Estatística
- UFSM -



“O intelecto faz pouco na estrada que leva à descoberta. Acontece um salto na consciência, chame-o você de intuição ou do que quiser; e a solução lhe ocorre, e você não sabe como, nem por quê.”

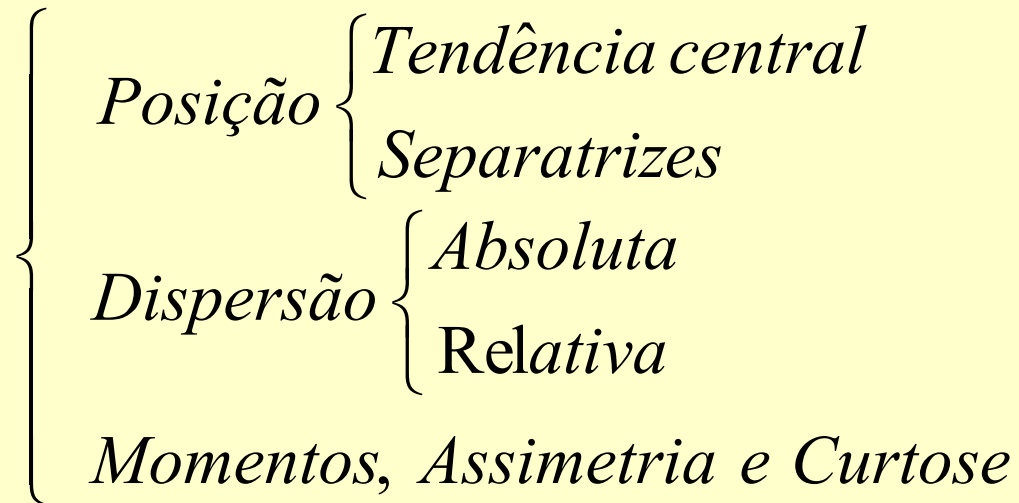
Albert Einstein

Medidas descritivas

Descrever um conjunto de dados de forma organizada e compacta por meio de suas estatísticas, o que não significa que estes cálculos e conclusões possam ser levados para a população.

As medidas descritivas básicas mais importantes são as de **posição** e as de **variabilidade**.

Classificação das medidas descritivas



Medidas de tendência central

Médias: Aritmética - Geométrica - Harmônica

Separatrizes: Mediana - Quartis - Decis - Centis

Modas: Bruta - Czuber - King - Pearson

Medidas de tendência Central

Quando se trabalha com dados numéricos observa-se uma tendência destes de se agruparem em torno de um valor central. Isto indica que algum valor central é a característica dos dados e que o mesmo pode ser usado para representá-los.

Média - Mediana - Moda

Média Aritmética

$$\begin{cases} \mu \rightarrow \text{população} \\ \bar{X} \rightarrow \text{amostra} \end{cases}$$

$$\bar{X} = \frac{\sum_{i=1}^n X_i}{n}$$

Dados não tabelados

$$\bar{X} = \frac{\sum_{i=1}^n X_i f_i}{n}$$

Dados tabelados

onde: X_i é o ponto médio da classe i ;
 f_i é a frequência absoluta da classe i .

É uma das mais utilizadas para descrever resumidamente um conjunto de dados, e sempre considera os seus valores extremos.

Propriedades da média aritmética


- ⚡ A soma dos desvios em relação a média é nula;
- ⚡ A média de uma constante é igual à constante;
- ⚡ A média do produto de uma constante por uma variável é igual ao produto da constante pela média da variável;
- ⚡ A soma dos quadrados dos desvios em relação a média é um mínimo.

Mediana (Md ou \tilde{X})

A Md divide em duas partes iguais os dados.
A Md é o elemento que ocupa o valor central.

Dados não agrupados

- ✓ Colocam-se os dados em ordem (rol) e se o número de elementos “n”;
- ✓ for **ímpar**, a Md será o elemento **central** do rol;
- ✓ for **par**, a Md será a **média** entre os dois elementos centrais do rol.



Dados tabelados

Distribuição por ponto

Calcula-se a posição Md :

$$P_{Md} = \frac{n}{2} \quad (\text{n par}) \quad \text{ou}$$

$$P_{Md} = \frac{n}{2} + 1 \quad (\text{n ímpar});$$

onde: $n = \sum f_i$ = número total de observações;

P_{Md} = posição da mediana.

**Divide um conjunto
de dados
em partes iguais, 50%
antes da Md e
50% após ela.**

A **Md** será o valor de X_i correspondente à primeira

$$Fac_i \geq P_{Md}$$

Dados tabelados

Distribuição por classe

✗ Calcula-se a posição Md: $P_{Md} = \frac{n}{2}$

✗ A Md estará localizada na classe onde, pela primeira vez,
 $Fac_i \geq P_{Md}$;

✗ Para encontrar o valor da mediana aplica-se a fórmula:

$$Md = \ell_i + \frac{\left(\frac{n}{2} - Fac_{anterior} \right) \cdot h}{f_i(Md)}$$

Moda (Mo ou \hat{X})

Mo é o valor mais freqüente de uma série de dados

Podendo ser classificando de:

amodal
unimodal
bimodal
multimodal

Moda de Czuber (*Moc*)

Dados não agrupados:

A **Mo** será o valor mais mais freqüente do conjunto de dados;

Dados agrupados:

Distribuição por ponto: É o valor de freqüência máxima;

Distribuição por classe: Identificar a classe modal e aplicar:

$$Moc = \ell_{i(Mo)} + \left(\frac{\Delta_1}{\Delta_1 + \Delta_2} \right) \cdot h$$

$$\Delta_1 = f_{Mo} - f_{ant}$$

$$\Delta_2 = f_{Mo} - f_{post}$$

Notas importantes

A ***média*** é a mais utilizada, principalmente quando não há valores aberrantes, sendo a medida mais conveniente para cálculos posteriores;

A ***Md*** deve ser usada, sempre que possível, como medida representativa de distribuições fortemente assimétricas, pois o seu valor não é afetado por valores extremos;

A **Mo** é usada quando há interesse em saber o ponto de concentração do conjunto ou o tipo de distribuição que se está analisando, sendo que o seu valor, em se tratando de dados agrupados, é fortemente afetado pela maneira como as classes são constituídas.

Medidas Separatrizes

São valores de posição, que dividem o rol em partes iguais

Mediana - Quartis - Decis - Centis ou Percentis


Quartis (Q_i): dividem um conjunto de dados em quatro partes iguais;

Decis (D_i): dividem os dados em 10 (dez) partes iguais;

Percentis (P_i): dividem os dados em 100 partes iguais.

Quartis (Q_i)

Dividem um conjunto de dados em quatro partes iguais



Para dados não-tabelados

- Colocam-se os dados em ordem (rol);
- Calcula-se a posição do quartil através da fórmula: $P_{Q_i} = i \cdot \frac{n}{4}$;
- O quartil será o valor que ocupa, no rol, a posição calculada anteriormente.

Para dados tabelados

Distribuição por ponto

- Calcula-se a posição do quartil através da fórmula: $P_{Q_i} = i \cdot \frac{n}{4}$;
- O quartil será o valor de X_i correspondente à primeira $Fac_i \geq P_{Q_i}$.

Distribuição por classe

- Calcula-se a posição do quartil $P_{Q_i} = i \cdot \frac{n}{4}$;
- O quartil estará localizado na classe onde, pela primeira vez, $Fac_i \geq P_{Q_i}$; e para encontrar o seu valor, aplica-se:

$$Q_i = L_{\text{inf.}} + \frac{h(P_{Q_i} - Fac_{\text{ant.}})}{f_{Q_i}}$$

Decis (D_i)

Dividem um conjunto de dados em dez partes iguais

Encontra-se o valor do decil desejado, procedendo-se como no caso dos quartis, sendo a posição do decil, encontrada por:

$$P_{Di} = i \cdot \frac{\sum f_i}{10} = i \cdot \frac{n}{10}$$

O valor do decil para os dados agrupados em classe:

$$D_i = L_{\text{inf.}} + \frac{h (P_{Di} - Fac_{\text{ant.}})}{f_{Di}}$$

Percentil (P_i)

Dividem um conjunto de dados em cem partes iguais

Procede-se como no caso dos quartis, sendo que para o cálculo da posição do percentil, a fórmula será:

$$Pp_i = i \cdot \frac{\sum f_i}{100} = i \cdot \frac{n}{100}$$

O valor do percentil para os dados agrupados em classe:

$$P_i = L_{\text{inf.}} + \frac{h (P_{Pi} - Fac_{\text{ant.}})}{f_{Pi}}$$

Medidas de dispersão

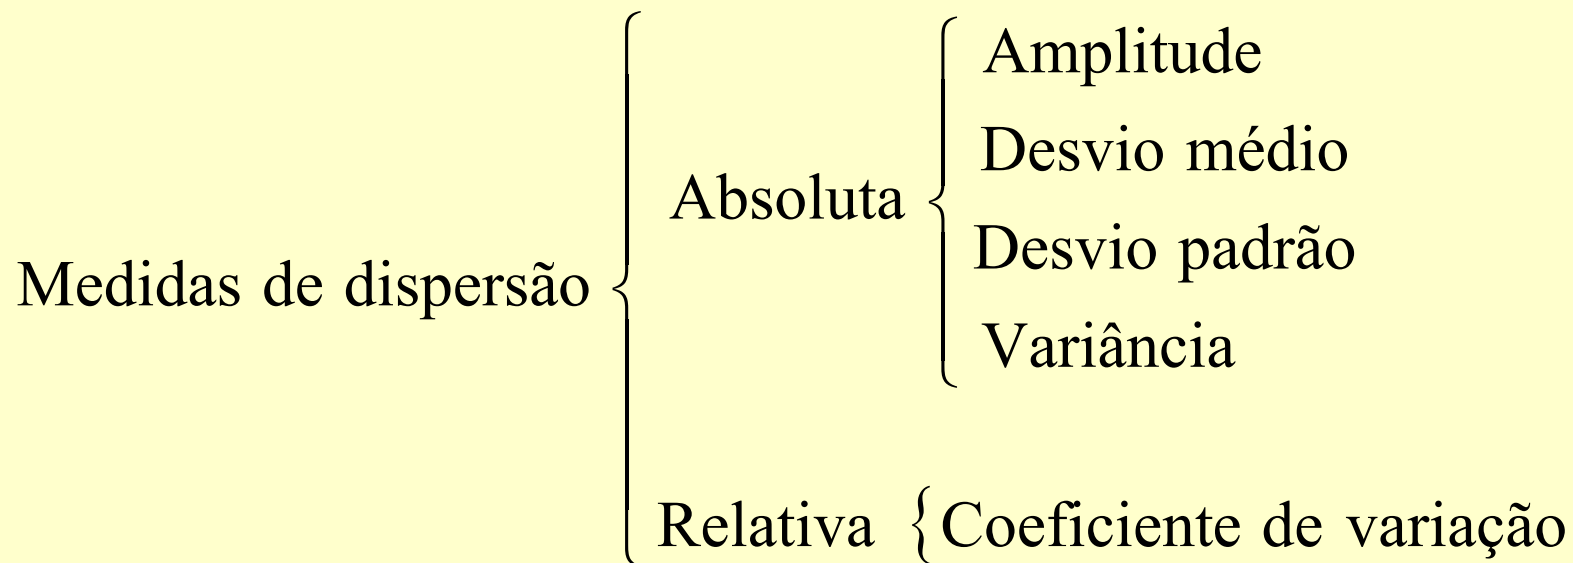
As medidas de dispersão visam descrever os dados no sentido de informar o grau de afastamento dos valores observados em torno de um valor central.

Elas indicam se um conjunto é **homogêneo** ou **heterogêneo**.

Um conjunto de dados, fica mais explicado quando se utiliza uma medida de tendência central e uma medida de dispersão, pois é comum encontrar-se séries que, apesar de apresentarem a mesma média, são compostas de maneiras diferentes.

Só as medidas de tendência central são insuficientes para descrever adequadamente um conjunto de dados.

Classificação das medidas de dispersão



Amplitude de variação (H)

É a diferença entre o maior e o menor valor do conjunto, sendo a mais simples das medidas de dispersão e de grande instabilidade, porque considera somente os valores extremos do conjunto. Também é chamada de desvio extremo.

$$H = X_{\text{máx.}} - X_{\text{mín.}}$$

Desvio médio (D_m)

É a média aritmética dos valores absolutos dos desvios tomados em relação à média ou à mediana.

$$|di| = |Xi - \bar{X}|$$

$$\sum di = 0$$

$$Dm = \frac{\sum |Xi - \bar{X}|}{n} = \frac{\sum |di|}{n}$$

O desvio médio é preferido em relação ao desvio padrão, quando esse for indevidamente influenciado pelos desvios extremos.

Soma de quadrados (SQ)

A soma de quadrados refere-se a soma dos quadrados dos desvios em relação a média.

$$SQ = \sum (X_i - \bar{X})^2 = (X_1 - \bar{X})^2 + (X_2 - \bar{X})^2 + \dots + (X_n - \bar{X})^2$$

$$SQ = \sum X_i^2 - \frac{(\sum X_i)^2}{n}$$

Variância populacional

$$\begin{cases} \sigma^2 \rightarrow \text{população} \\ s^2 \rightarrow \text{amostra} \end{cases}$$

A variância populacional (σ^2)
é a SQ dividida pelo número de observações N.

$$\sigma^2 = \frac{SQ}{N} = \frac{\sum (X_i - \bar{X})^2}{N} = \frac{\sum X_i^2 - \frac{(\sum X_i)^2}{N}}{N}$$

Quando a variância é calculada a partir de uma amostra para fins de estimação, o denominador passa a ser (n - 1), o que fornece uma estimativa imparcial da variância populacional.

Variância amostral

$$\begin{cases} \sigma^2 \rightarrow \text{população} \\ s^2 \rightarrow \text{amostra} \end{cases}$$

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

Dados não tabelados

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

Dados tabelados

O denominador (n - 1) é denominado de "graus de liberdade" dessa estimativa.

A variância mostra o grau de dispersão ou o afastamento dos valores observados em torno de um valor central.

Propriedades da variância

A variância de uma constante é zero; $s^2(k) = 0$;

A variância da soma ou diferença de uma constante k com uma variável é igual a variância da variável; $s^2(k + X) = s^2(X)$;

A variância da soma de variáveis independentes é igual a soma das variâncias das variáveis; $s^2(X + Y) = s^2(X) + s^2(Y)$;

A variância do produto de uma constante por uma variável é igual ao produto do quadrado da constante pela variância da variável; $s^2(k \cdot X) = k^2 \cdot s^2(X)$;

Desvio padrão

$$\begin{cases} \sigma \rightarrow \text{população} \\ s \rightarrow \text{amostra} \end{cases}$$

S é uma das medidas mais úteis da variação, pois como ela é expressa na mesma unidade dos dados, sua interpretação é direta.

$$s = \sqrt{s^2}$$

Especialmente para ($n \geq 30$):

68% das observações estarão entre $\bar{X} \pm s$

95% das observações estão entre $\bar{X} \pm 2s$

100% praticamente estão entre $\bar{X} \pm 3s$

Coeficiente de Variação de Pearson (CV)

O **CV** é uma medida relativa que determina o grau de concentração dos dados em relação a média.

$$CV = \frac{s}{\bar{X}}$$

$$CV\% = \frac{s}{\bar{X}} \cdot 100$$

*Menor o CV
mais representativa
será a média
do processo.*

Útil para se comparar conjuntos de dados com diferentes unidades de medição e/ou tamanhos diferentes, independentemente da unidade de medida dos dados.

Momentos, assimetria e curtose

Complementam
as medidas de posição e de dispersão,
proporcionando uma descrição e
compreensão mais completa das
distribuições de frequências.

Estas medidas nos informam quanto a forma
da distribuição dos dados.

Momentos

São medidas de caráter mais geral e dão origem às demais medidas descritivas, como as de tendência central, dispersão, assimetria e curtose.

Conforme a potência considerada tem-se a ordem ou o grau do momento calculado.

Momentos simples ou centrados na origem (m_r)

$$m_r = \frac{\sum X_i^r}{n}$$

dados não tabelados

$$m_r = \frac{\sum X_i^r f_i}{\sum f_i}$$

dados tabelados

r é um número
inteiro
positivo
e define
a ordem do
momento.

$$m_0 = 1$$

$$m_1 = \text{média aritmética}$$

Momentos centrados na média (M_r)

$$M_r = \frac{\sum (X_i - \bar{X})^r}{n} = \frac{\sum d_i^r}{n}$$

dados não tabelados

$$M_r = \frac{\sum (X_i - \bar{X})^r f_i}{\sum f_i} = \frac{\sum d_i^r f_i}{n}$$

dados tabelados

$$M_0 = 1$$

$$M_1 = 0$$

$$M_2 = \text{variância (s}^2\text{)}$$

Momentos abstratos (α_r)

$$\alpha_r = \frac{M_r}{S_r}$$

s = desvio padrão

Assimetria

Assimetria é o grau de desvio, afastamento da simetria ou grau de deformação de uma distribuição de frequências

Esta medida nos mostra como os dados se comportam em relação a ordenada máxima.

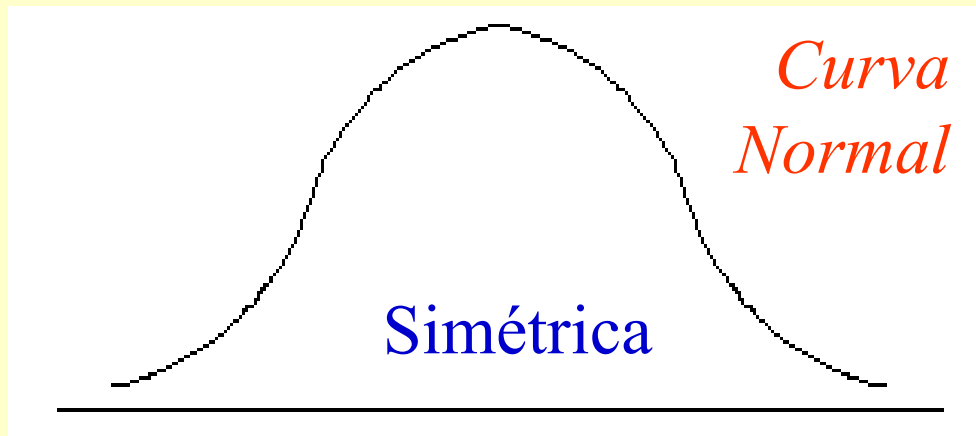
Tipos de curvas

Simétricas

Assimétrica positiva

Assimétrica negativa.


Tipos de curvas (assimetria)



Curva Normal

Simétrica


$$\bar{X} \equiv Mo \equiv Md$$



A maioria dos dados estão a direita da moda

Assimétrica positiva

$$Mo < Md < \bar{X}$$



A maioria dos dados estão a esquerda da moda

Assimétrica negativa

$$\bar{X} < Md < Mo$$

Como medir a assimetria?

Coeficiente de assimetria de Pearson

$$As = \frac{\bar{X} - Mo}{s}$$

Se $As < 0$ a curva será assimétrica negativa

Se $As > 0$ a curva será assimétrica positiva

Se $As = 0$ a curva será simétrica

Coeficiente momento de assimetria (α_3)

$$\alpha_3 = \frac{M_3}{s^3}$$

Se $|\alpha_3| < 0,2$ a curva será simétrica

Se $0,2 < |\alpha_3| < 1,0$ a curva será assimétrica fraca

Se $|\alpha_3| > 1,0$ a curva será assimetria forte.

- 1 ≤ Coeficiente de assimetria ≤ +1

Curtose

Medidas de Curtose ou de Achatamento, mostram até que ponto uma distribuição é a mais aguda ou a mais achatada do que uma curva normal, de altura média.

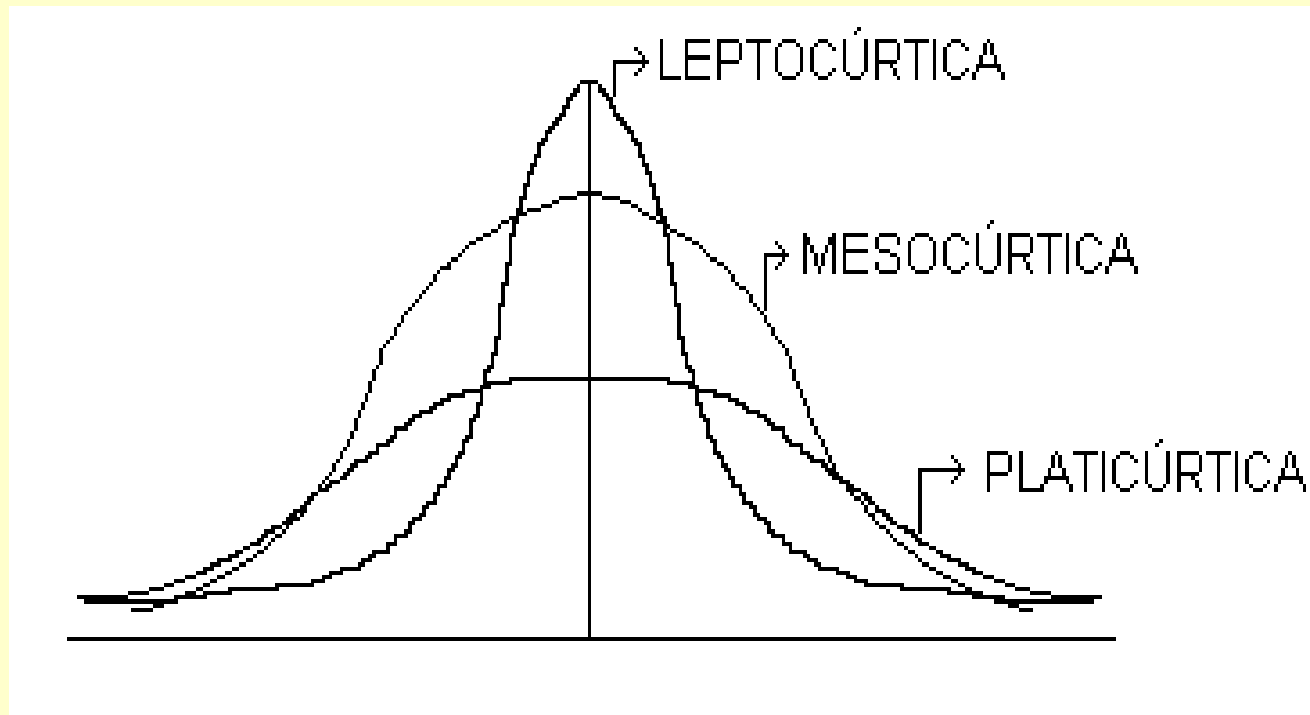
Tipos de curvas

Platicúrtica

Mesocúrtica

Leptocúrtica

Tipos de curvas (Curtose)



A curtose está relacionada com a altura da curva de distribuição em relação a ordenada.

Como medir a curtose?

Pelo coeficiente centílico de curtose

$$K = \frac{Q_3 - Q_1}{2(D_9 - D_1)}$$

Se $K = 0,263$ a curva será mesocúrtica

Se $K < 0,263$ a curva será leptocúrtica

Se $K > 0,263$ a curva será platicúrtica

Pelo coeficiente momento de curtose (α_4)


$$\alpha_4 = \frac{M_4}{S^4}$$

Se $\alpha_4 = 3$ curva mesocúrtica

Se $\alpha_4 < 3$ curva platicúrtica;

Se $\alpha_4 > 3$ curva leptocúrtica.

Desafio !!!



- Colete um conjunto de dados;
- Construa a distribuição de frequência;
- Faça o seu histograma;
- Calcule a sua média, desvio padrão e coeficiente de variação de Pearson;
- Interprete os resultados.