

Modelos Lineares

Medidas de tendência central e de variabilidade

Professora Ariane Ferreira



Instituto Politécnico
Campus Regional da UERJ
Nova Friburgo - RJ

Dados Empíricos


Os dados empíricos coletados de um processo devem formar a base para as decisões e ações.

Uma vez que os dados brutos tenham sido coletados, eles devem ser tabulados e convertidos em “informação” através do uso de métodos estatísticos.

Coleta de dados

População: corresponde ao sistema ou ao todo que se quer descrever. É um conjunto de elementos com características comuns.

- **Censo:** inspeciona todos os elementos de uma população.
 - **Parâmetros:** valor desconhecido associado a uma característica (média = μ , variância = σ^2)
- **Amostra:** é uma parte representativa da população.
 - **Estimador:** função que estima o valor de um Parâmetro baseando-se nas observações (média = \bar{x} , variância = s^2)



Amostra Representativa

- Cada indivíduo da População tem exatamente a mesma probabilidade de ser selecionado na amostra.
- O tamanho n da amostra é suficientemente elevado.
- Ele depende da homogeneidade da população e da precisão desejada.

↑ n ↑ p (detectar pequenas mudanças)

↑ frequência de amostragem ↑ p (detectar mudanças)

Ideal amostras grandes com alta frequência → não é viável economicamente

Dicotomia:

↓ n ↑ frequência

mais utilizado na indústria

↑ n ↓ frequência

Estratificação dos dados

Trabalha-se com dados classificados em agrupamentos:

- camadas ou estratos
- Tempo: os resultados são diferentes de manhã, à tarde ou a noite?
- Local: os resultados são diferentes nas linhas de produção?
- Tipo: os resultados obtidos são diferentes entre os fornecedores?
- Indivíduo: é possível comparar os operadores?

Tipos de dados

•Contínuos = Variáveis quantitativas

- Os valores são um conjunto infinito de \mathfrak{R}
- infinitos valores possíveis entre dois extremos
 - Tempo (1h:35min),
 - Pressão (1.013,105 KPa) ,
 - Dimensão (16,54 mm),
 - Temperatura (23,5°C)

•Discretos

- Os valores são um conjunto infinito de \mathbb{N}
- exemplo: número de filhos

•Categoricos = Variáveis qualitativas

- São conjuntos de valores finitos— numéricos (códigos e não quantidades)

•Textuais

- Letras, textos

Análise Exploratória dos Dados

- **Explorar a distribuição das Variáveis**
- **Verificar a confiabilidade das variáveis**
 - Valores incoerentes ou faltantes
 - Imputação ou supressão
- **Detectar valores extremos (outliers)**
 - Eliminar os valores aberrantes
- **Variáveis Contínuas**
 - Detectar a não monotia ou a não-linearidade (para discretização)
 - Testar a normalidade das variables (sobretudo para amostras de pequenos efetivos), transforma-las se necessario para aumentar a normalidade
 - facultativo: testar a **homoscédasticidade** (igualdade das variâncias-covariâncias)

Análise Exploratória dos Dados

•Variáveis discretas

- agrupar certas modalidades muito numerosas ou com efetivos muito pequenos (peso muito grande) valores incoerentes ou faltantes.

•Criar indicadores pertinentes à partir dos dados brutos:

- Conjunto das variáveis « produto P_i comprado (Oui/Non) » permite deduzir o número de produtos comprados
- Número e valor de compras \Rightarrow valor médio de uma compra
- datas de compras \Rightarrow frequência das compras

•Detectar as ligações entre as variáveis

- entre variáveis explicativas e a variável a ser explicada (bon)
- Nas variáveis explicativas entre si (multicolinearidade: ruim para certos métodos lineares)

Valores Faltantes

•Outras soluções :

- Supressão das observações (se elas são pouco numerosas)
- Trocar a variável por outra correlacionada, mas sem valores faltantes
- Tratar os valores faltantes
- Preencher os valores faltantes com auxílio de fonte externa

•Imputação estatística

- Usar a moda, a média ou a mediana
- Usar uma regressão ou árvore de regressão

A imputação não é jamais neutra:

- Os dados não são faltantes ao acaso;
- Deformação das variâncias e correlações

Descrição de uma variável quantitativa

Estudo de uma variável numérica X

- Seja uma variável numérica X com os valores $x_1, \dots, x_i, \dots, x_N$ na população e $x_1, \dots, x_i, \dots, x_n$ na amostra.
- Ela é resumida pelas estatísticas :
 - de tendência Central (média, mediana) e
 - de dispersão (variância, desvio-padrão, amplitude, quantis, distância entre quantis)
- A dispersão de X é visualizada através de
 - Box plot
 - histograma.
- Ajustamento de uma lei de probabilidade conhecida aos dados.

Description d'une variable quantitative

Étude d'une variable numérique X

- Une variable numérique X prend des valeurs $x_1, \dots, x_i, \dots, x_N$ sur une population et $x_1, \dots, x_i, \dots, x_n$ sur un échantillon.
- Elle est résumée par des statistiques :
 - de tendance centrale (moyenne, médiane) et
 - de dispersion (variance, écart-type, étendue, quartiles, distance interquartiles)
- La dispersion de X est visualisée par
 - la boîte-à-moustache et
 - l'histogramme.
- Ajustement d'une loi de probabilité connue aux données.


Variável Quantitativa

- 1) Medidas de tendência central
- 2) Medidas de variabilidade
- 3) Histograma
- 4) Boxplot
- 5) Distribuição de probabilidade Normal
- 6) Gráfico de normalidade

Variável Quantitativa Medidas de Tendência Central

A tendência central é uma medida do centro de um conjunto de dados segundo uma regra estabelecida a priori (média aritmética, geométrica, harmônica, ponderada, etc.)

- Média aritmética
- Mediana
- Moda



Variável Quantitativa Medidas de Tendência Central

Média aritmética $\bar{x} = \frac{1}{n} \sum_{i=1}^n x_i$

- Anotamos a temperatura de uma pessoa de 1 em 1 hora, durante 8 horas. Qual a média da temperatura?
- Valores observados: 37, 37, 38, 39, 37, 39, 39°C.
- O tamanho da amostra é $n = 7$

$$\bar{x} = \frac{37 + 37 + 38 + 39 + 37 + 39 + 39}{7} = 38^{\circ}\text{C}$$

A média amostral é bom um estimador da média populacional. Quanto maior n melhor a estimativa.

Variável Quantitativa Medidas de Tendência Central

$$\text{Mediana} \quad \tilde{x} = \begin{cases} x_{((n+1)/2)} & n \text{ ímpar} \\ \frac{x_{(n/2)} + x_{(n/2+1)}}{2} & n \text{ par} \end{cases}$$

- Ela é não é influenciada pelos dados atípicos
- Deve-se ordenar os dados em ordem crescente
- Qual a mediana da temperatura?
- Valores observados: 37, 37, 38, 39, 37, 39, 39°C.
- Valores ordenados: 37, 37, 37, 38, 39, 39, 39°C
- $n = 7$ é ímpar – mediana valor central $\tilde{x} = 38^\circ\text{C}$

Variável Quantitativa Medidas de Tendência Central

Moda: observação que ocorre com mais frequência


- Qual a moda da temperatura?
- Valores observados: 37, 37, 37, 38, 39, 39, 39°C
- Duas modas: 37 e 39°C

Variável Quantitativa Medidas de Tendência Central

Relação entre média e mediana → fornece a forma da dispersão

A	Distribuição simétrica	10 12 14 16 18	$\bar{x} = 14 = \tilde{x} = 14$
B	Distribuição assimétrica à direita	10 12 14 16 23	$\bar{x} = 15 > \tilde{x} = 14$
C	Distribuição assimétrica à esquerda	05 12 14 16 18	$\bar{x} = 13 < \tilde{x} = 14$


Mediana tem maior robustez a dados atípicos do que a média



Variável Quantitativa Medidas de Tendência Central

Para distribuições simétricas a média, a mediana e a moda coincidem aproximadamente.

Para distribuições assimétricas observa-se o seguinte:



Variável Quantitativa Medidas de Tendência Central

Média Geométrica (G)

É a raiz de ordem n do produto dos valores da amostra:

$$G = \sqrt[n]{X_1 X_2 \dots X_n}$$

Exemplo

A média geométrica de 12 14 16 é:

$$G = \sqrt[3]{12 \times 14 \times 16} = 13,90$$

Variável Quantitativa Medidas de Tendência Central

Média Harmônica (H)

É o inverso da média aritmética dos inversos das observações.

$$H = \frac{1}{\frac{1}{n} \sum \frac{1}{X_i}} = \frac{n}{\sum \frac{1}{X_i}}$$

Exemplo

A média harmônica de 12 14 16 é:

$$H = \frac{3}{\frac{1}{12} + \frac{1}{14} + \frac{1}{16}} = 13.81$$

Variável Quantitativa Medidas de Tendência Central

Relação entre Média Aritmética, Geométrica e Harmônica:

A média geométrica e a média harmônica são menores, ou no máximo igual, à média aritmética.

A igualdade só ocorre no caso em que todos os valores da amostra são idênticos.

Quanto maior a variabilidade, maior será a diferença entre as médias harmônica e geométrica e a média aritmética.

$$H \leq G \leq \bar{X}$$

Exemplo: Para a amostra 12 14 16 tem-se

$$H = 13,81 < G = 13,90 < \bar{X} = 14,00$$

Variável Quantitativa Medidas de Variabilidade

Amplitude: $R = X_{\max} - X_{\min}$

Exemplo: 8,5 8,7 8,9 10,1 10,5 10,7 11,5 11,9

$$R = 11,9 - 8,5 = 3,4$$

- A amplitude é fácil de calcular e fornece uma idéia da magnitude da faixa de variação dos dados.
- Não informa a respeito da dispersão dos valores que caem entre os dois extremos.
- Ela é influenciada pelos dados atípicos
- Quando $n < 10$ pode resultar em uma medida de variação bastante satisfatória.

Variável Quantitativa Medidas de Variabilidade

Quartis

É qualquer um dos três valores que divide o conjunto ordenado de dados em quatro partes iguais, e assim cada parte representa $1/4$ da amostra ou população. Ela não é influenciada pelos dados atípicos

- **1º quartil ou quartil inferior (Q1)** = valor aos 25% da amostra ordenada
- **2º quartil ou mediana (Q2)** = valor até ao qual se encontra 50% da amostra ordenada
- **3º quartil ou quartil superior (Q3)** = valor a aos 75% da amostra ordenada

Variável Quantitativa Medidas de Variabilidade

Exemplo

Amostra: 36, 40, 7, 41, 15, 39

Amostra ordenada: 7, 15, 36, 39, 40, 41

$$Q1 = 15$$

$$Q2 = (39+36)/2 = 37,5$$

$$Q3 = 40$$

Intervalo inter-quartil: $Q3-Q1$ ($40 - 15 = 25$)

Regra para descobrir os quartis

- 1) use a mediana para dividir os dados ordenados em duas metades, não inclua a mediana nas metades
- 2) o quartil inferior (ou superior) é a mediana da metade inferior (ou superior).

Variável Quantitativa Medidas de Variabilidade

Variância

Quadrado da distância de todos os valores x_i em relação a sua média

$$\sigma^2 = \frac{\sum_{i=1}^N (x_i - \mu)^2}{N}$$

Desvio-padrão

A raiz quadrada da variância (é expresso na unidade original dos dados)

$$\sigma = \sqrt{\frac{\sum_{i=1}^N (x_i - \mu)^2}{N}}$$

Variável Quantitativa Medidas de Variabilidade

Nem sempre se conhece a variância e o desvio padrão populacional. Desta forma, deve-se usar um estimador a partir de uma amostra

$$\sigma^2 = \frac{\sum_{i=1}^N (x_i - \mu)^2}{N} \quad \text{populacional}$$

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

$$\sigma = \sqrt{\frac{\sum_{i=1}^N (x_i - \mu)^2}{N}} \quad \text{populacional}$$

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

A correção de Bessel (eliminando 1 grau de liberdade para $n < 30$) torna a variância amostral um estimador da variância populacional não-viesado.

Variável Quantitativa Medidas de Variabilidade

Exemplo

Amostra: 10 12 14 16 18 (*meses*)

A média é 14 cm, a variância e o desvio-padrão são:

$$s^2 = \frac{(10-14)^2 + (12-14)^2 + (14-14)^2 + (16-14)^2 + (18-14)^2}{5-1} = 9,98 \text{ meses}^2$$


$$s = \sqrt{9,98 \text{ cm}^2} = 3,16 \text{ meses}$$

Os desvios de cada valor em relação à média totalizam zero pois a média é o valor central

A média e o desvio padrão possuem a mesma unidade de medida

Variável Quantitativa Medidas de Variabilidade

Seja um processo com média 28,4 e desvio-padrão $S = 0,2$



Variável Quantitativa Medidas de Variabilidade

Coeficiente de variação $CV = \frac{s}{\bar{x}} \times 100$

- Um desvio padrão pode ser considerado grande ou pequeno dependendo da ordem de grandeza da média da variável.
- Quanto menor o CV mais homogêneo é o conjunto de dados.
- Medida adimensional, útil para comparar resultados de amostras cujas unidades podem ser diferentes.