

# Bioestatística

## Aula 3

Medidas de Dispersão ou Variabilidade


Prof. Tiago A. E. Ferreira



# Aspectos Gerais




- **Dispersão** ou **Variabilidade** nada mais é do que a diferença observada entre os valores de um conjunto de dados
  - A diversidade de valores contidos em dados observados irá depender do fenômeno gerador dos próprios dados.
    - Esta diversidade será então uma característica da população em estudo, sendo responsável pela dispersão ou variabilidade dos dados.
  - Questão: Como medir esta diversidade?



# Amplitude total




- Uma das formas mais diretas e simples de medir a dispersão é através da **Amplitude Total (AT)** do conjunto de dados.
  - Como já visto, sendo  $X = \{x_1, x_2, \dots, x_n\}$  com  $\{x_1 < x_2 < \dots < x_n\}$ , então:
    - Para dados simples:  $AT = x_n - x_1$ 
      - Para dados agrupados em tabelas:  $AT = Lsr_m - Lir_1$
      - onde:
        - »  $Lsr_m$  = limite superior real da classe m (última Classe)
        - »  $Lir_b$  = limite inferior real da classe 1



# Amplitude Total




- Desta forma, quanto maior a dispersão ou variabilidade dos valores no conjunto de dados, maior será a Amplitude Total, e vice-versa.
  - Apesar de sua simplicidade, a AT tem suas limitações:
    - A AT considera apenas dois pontos de todo o conjunto de dados, não sendo sensível aos “n-2” demais valores do conjunto de dados.
    - No caso de dados agrupados, se os limites forem abertos, como calcular AT?



# Problemas da Amplitude Total




- Dado os dois conjuntos exemplos:
  - $A = \{1, 7, 7, 8, 8, 8, 9, 9, 12, 15\}$
  - $B = \{3, 3, 4, 4, 8, 11, 13, 13, 14, 14\}$
- Segundo a medida AT, a dispersão é:
  - $\text{Dispersão}[A] = AT_A = 15 - 1 = 14$
  - $\text{Dispersão}[B] = AT_B = 14 - 3 = 11$ 
    - Será que estes resultados refletem a realidade?





# Problemas da Amplitude Total



- Conjunto A:  $AT_A = 14$



- Conjunto B:  $AT_B = 11$



# Soma dos Desvios Simples



- Uma alternativa à AT é calcular a diferença entre os dados do conjunto, dois a dois.
  - Este processo necessita de todas as combinações  $n 2 a 2$ .
  - Porém estas diferenças podem ser calculadas a partir de um valor central como referência, por exemplo a média.
  - Assim, a Soma dos Desvios Simples (SDS) é


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



# Soma dos Desvios Simples



- Contudo, já foi visto que, para qualquer conjunto de dados, SDS será sempre nulo!
  - A ideia do SDS está coerente, porém o SDS sempre se anula devido ao fato de que para toda variação negativa (desvios à esquerda da média) existirá uma variação positiva (desvios à direita da média)

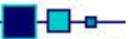


# Soma dos Desvios Absolutos



- Desta forma, se todos os desvios forem considerados de forma absoluta, é possível ter a Soma dos Desvios Absolutos (SDA):

$$SDA = \sum_{i=1}^n |x_i - \bar{x}|$$




# Desvio Médio



- A partir da Soma dos Desvios Absolutos ainda é possível se calcular a variabilidade em média!
  - Ou seja, em média quanto cada ponto do conjunto de dados está se afastando do valor médio.
- Define-se o Desvio Médio (DM)

$$DM = \frac{\sum_{i=1}^n |x_i - \bar{x}|}{n}$$




# Soma dos Quadrados dos Desvios



- Uma outra forma de resolver o problema da SDS é através da Soma dos Quadrados dos Desvios (SQD).
  - Uma vez que todo número quadrado é não negativos ( $\geq 0$ ).
- Define-se SQD como,


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



# SDA e SQD, Qual utilizar?



- Tanto a Soma dos Desvios Absolutos com a Soma Quadrada dos Desvios satisfazem os requisitos para serem medidas de dispersão ou variabilidade.
  - Porém a SQD tem maior capacidade de destringir os desvios em relação a SDA.
  - Desta forma, a SQD é preferida na grande maioria dos casos!




# Variância



- Também é possível se calcular o Desvio Quadrático Médio, conhecido comumente com **Variância** ( $\text{Var}[x]$ ):

$$\text{Var}[x] = \sigma_x^2 = \frac{\sum_{i=1}^n (x_i - \bar{x})^2}{n}$$

- Esta expressão é a Variância populacional




# Desvio Padrão



- A raiz quadrada da variância é o desvio padrão:

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

- O desvio padrão e variância são os dois indicadores de variabilidade mais utilizados




# Variância e Desvio Padrão Amostrais



- Quando se trata de amostras extraídas de uma população, a variância e o desvio padrão sofrem uma correção amostral, sendo representados por  $S^2$  e  $S$

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


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



# Variância e Desvio Padrão Amostrais



- Na prática, as expressões populacionais e amostrais só terão uma diferença significativa para amostras muito pequenas
  - Tipicamente amostras com menos de 30 elementos (ou valores)



# Cálculos Abreviados




- Variância populacional

$$\sigma^2 = \frac{\sum_{i=1}^n x_i^2 - \frac{\left(\sum_{i=1}^n x_i\right)^2}{n}}{n}$$

- Variância Amostral

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



# Cálculos Abreviados




- Desvio Padrão Populacional

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

- Desvio Padrão Amostral

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




# Dados Agrupados



- Variância populacional para dados agrupados em classes homogêneas

$$\sigma^2 = \left[ \frac{\sum_{i=1}^n (fa_i \cdot v_i)^2}{n} - \left( \frac{\sum_{i=1}^n fa_i \cdot v_i}{n} \right)^2 \right] \cdot c^2$$




# Dados Agrupados



- Variância populacional para dados agrupados em classes não homogêneas:

$$\sigma^2 = \frac{\sum_{i=1}^n fa_i \cdot (pm_i - \bar{x})^2}{\sum_{i=1}^n fa_i} = \frac{\sum_{i=1}^n fa_i \cdot (pm_i - \bar{x})^2}{n}$$



# Medida de Variabilidade Normalizada



- Como comparar duas grandezas diferentes?
  - Matematicamente (e até fisicamente) não há sentido em se comparar duas grandezas distintas
    - Como comparar, por exemplo, Kg com ml, ou seja, massa com volume?
    - Para se poder afirmar que uma dada grandeza é maior ou menor, ou ainda igual, a outra grandeza ambas devem ter a mesma unidade ou serem adimensionais.



# Medida de Variabilidade Normalizada



- Exemplo: Dada a tabela de comprimento e peso

Recém-Nascido	1	2	3	4	5	6	7	8	9	10
Comprimento (cm)	52	48	45	49	51	54	47	50	46	51
Peso (g)	3300	3200	2950	3150	3350	3450	2900	3300	3150	3250


- É possível calcular:
  - $\overline{\text{Comprimento}} = 49,3 \text{ cm}$
  - $\overline{\text{Peso}} = 3200\text{g}$
  - $s_H^2 = 7,24 \text{ cm}^2$        $s_P^2 = 26500,58 \text{ g}^2$
  - $s_H = 2,69 \text{ cm}$        $s_P = 162,79 \text{ g}$
- É possível, observando os resultados, afirmar qual grandeza tem a maior variabilidade?



# Medida de Variabilidade Normalizada



- Observe que as grandezas Peso (gramas) e Comprimentos (centímetros) têm unidades distintas!
  - Além deste fato, todos os cálculos são baseados em um fator de referência, no caso a média!
    - Assim, toda medida de variação vista tem como referência básica o valor da média.
    - Logo toda comparação deve ser feita em relação a média da grandeza.



# Coeficiente de Variação




- É possível definir o coeficiente de variação (grandeza adimensional):
  - Caso populacional:

$$CV = \frac{\sigma}{\bar{x}}$$

- Caso amostral:


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



# Coeficiente de Variação




- Desta forma, para o exemplo anterior:
  - $cv_H = 0,545$
  - $cv_P = 0,0509$ 
    - Com a utilização do coeficiente de variação é possível comparar qual grandeza teve efetivamente uma variabilidade maior!
    - Este coeficiente de variação também nos dá alguma noção de estabilidade, ou seja, qual é a ordem de grandeza da variabilidade em relação a média
      - Quanto mais  $cv$  se aproximar de zero maior a estabilidade do sistema!



# Medidas de Assimetria



- Como as medidas estudadas até então é possível determinarmos um valor típico (ou central) dos dados e o comportamento dos demais pontos em torno deste valor típico.



# Medidas de Assimetria





Fig. 4.7 Distribuições à esquerda e à direita.





# Medida de Assimetria





- Defini-se simetria a identidade de comportamento de curva a ambos os lados de um eixo ou plano de simetria



# Assimetria à Direita



# Assimetria à Esquerda




# Coeficiente de Assimetria



- Como medir a assimetria de um conjunto de dado?
  - **Coeficiente de Assimetria de Pearson**
    - Quanto maior a assimetria maior a diferença entre a média e a moda
      - Assimetria = Média – Moda
  - Este coeficiente pode ser melhorado se dividido pelo desvio padrão, tornando-se adimensional

$$P = \frac{\bar{x} - \tilde{x}}{\sigma}$$



# Coeficiente de Assimetria




- Dado:

$$P = \frac{\bar{x} - \tilde{x}}{\sigma}$$

– É interessante notar:

- Distribuição simétrica,  $P = 0$  (média = moda)
- Distribuição é à esquerda,  $P < 0$  (média < moda)
- Distribuição é à direita,  $P > 0$  (média > moda)
- Quanto maior a assimetria, maior  $|P|$



# Coeficiente Quartílico de Assimetria (Q)




- O coef. Quartílico de assimetria (Q) é calculado a partir dos valores dos quartis:

$$Q = \frac{(Q_3 - Q_2) - (Q_2 - Q_1)}{Q_3 - Q_1}$$

*ou*

$$Q = \frac{Q_3 - 2 \cdot Q_2 - Q_1}{Q_3 - Q_1}$$




# Coeficiente do Momento de Assimetria



- O coeficiente do momento de assimetria :


$$a_3 = \frac{\sum_{i=1}^n (x_i - \bar{x})^3}{n \sigma^3}$$




# Curtose



- O conceito de curtose é relativo ao “achatamento” ou “alongamento” de uma dada distribuição.
  - Distribuições achatadas: **platicúrtica**
  - Distribuições normais: **mesocúrticas**
  - Distribuições Alongadas: **leptocúrtica**



# Curtose



**Fig. 4.9** Tipos de distribuições quanto à curtose.

# Referências



- Livro Texto: Bioestatística. Teoria e Computacional (Héctor G. Arango). Guanaba
  - Seção 2, 3 e 4 – Capítulo 4
- Leituras Complementares:
  - Livro: Bioestatística. Princípios e Aplicações (Sidia M. Callegari-Jacques)
    - Capítulo 3.

