

# Bioestatística

## Aula 2

### Medidas de Tendência Central

Prof. Tiago A. E. Ferreira



# Introdução



- Como já visto na aula anterior, estamos interessados em estudar algum fenômeno sobre uma dada população.
  - Dada uma população, gera-se uma amostra para a caracterização das informações da população!
    - Assim, procura-se, a partir da amostra, características centrais da população.
    - **Medidas de tendência Central** são uma primeira caracterização dos conjuntos populacionais ou amostrais

# Média Aritmética



- Dado um conjunto de **n** valores da variável aleatória **X**,  $X = \{x_1, x_2, \dots, x_n\}$ , a média aritmética de **X**,  $\bar{X}$  é

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

# Média Aritmética



- Exemplo:

- Dado um estudo foram medidas as concentrações percentuais GC de trechos de igual tamanho de seqüenciamentos genéticos, dados por:

seqüência	1	2	3	4	5	6	7	8	9
GC (%)	56,3	45,5	46,7	49,8	54,2	42,1	56,6	44,7	61,2

- Pergunta-se: Qual a concentração percentual média de GC do Estudo?

$$\overline{sequência} = \frac{1}{9} \sum_{i=1}^9 sequênci a_i = 50,79$$

# Média Ponderada



- Dado que um certo experimento gere os seguintes dados:

Valores	Frequência
2	11
4	24
5	43
Total:	78

- Pode-se notar que foram gerados 78 dados, ou seja,  $n=78$ . Assim, a média aritmética seria:

$$\bar{x} = \frac{\overbrace{2+2+\dots+2}^{11 \text{ vezes}} + \overbrace{4+4+\dots+4}^{24 \text{ vezes}} + \overbrace{5+5+\dots+5}^{43 \text{ vezes}}}{78} = 4,269$$

# Média Ponderada



- No exemplo anterior, é equivalente:

$$\bar{x} = \frac{11 \cdot 2 + 24 \cdot 4 + 43 \cdot 5}{11 + 24 + 43} = 4,269$$

- Desta forma, a frequência de cada valor representa a importância que cada fator tem no cálculo da média

$$\bar{x} = \frac{\sum_{i=1}^{qtd.\text{valores}} x_i \cdot f_i}{\sum_{j=1}^{qtd.\text{valores}} f_j} = \frac{\sum_{i=1}^{qtd.\text{valores}} x_i \cdot f_i}{n}$$

# Média Ponderada



- Desta forma, é possível adotar pesos para os valores dos dados.
  - Quanto maior a importância de uma dada observação (ou valor) maior o seu peso.
  - Define-se a **Média Ponderada**

$$\bar{x}_p = \frac{\sum_{i=1}^n x_i \cdot p_i}{\sum_{j=1}^n p_j}$$

- onde  $p_i$  é o peso para o valor  $i$

# Propriedades da Média Aritmética



- A soma dos desvios de um conjunto  $X$ , com  $N$  números, em relação a sua média aritmética é sempre nula!

$$\sum_{i=1}^n (x_i - \bar{x}) = 0$$

- Prova Matemática?



# Propriedades da Média Aritmética



- A soma dos quadrados dos desvios de um conjunto de números  $x_i$ , em relação a qualquer número  $A$ , é um mínimo quando  $A = \bar{x}$  e somente neste caso

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

# Propriedades da Média Aritmética



- Se  $f_1$  números têm média  $m_1$ ,  $f_2$  números têm média  $m_2$ , ...,  $f_k$  números têm média  $m_k$ , então a média global pode ser calculada por:

$$\bar{x} = \frac{\sum_{i=1}^k m_i \cdot f_i}{\sum_{j=1}^k f_j} = \frac{\sum_{i=1}^k m_i \cdot f_i}{n}$$

# Propriedades da Média Aritmética



- A média aritmética de números é também igual à média de cada um destes números menos (ou mais) uma constante, somada depois a essa mesma constante.

$$\bar{x} = \frac{\sum_{i=1}^n x_i}{n} = \frac{\sum_{i=1}^n (x_i \mp A)}{n} \pm A$$

- Esta propriedade também está afirmando que somar ou subtrair uma constante a um conjunto de valores numéricos, estamos somando ou subtraindo esta constante ao valor médio do conjunto!

# Média Geométrica



- A Média Geométrica é definida por,

$$G = \left[ \prod_{i=1}^n x_i \right]^{\frac{1}{n}} \quad \text{ou} \quad G = \sqrt[n]{x_1 \cdot x_2 \cdot \dots \cdot x_n}$$

- Aplicando o logaritmo na base  $b$  a esta expressão, é possível mostrar que,

$$G = b^{\overline{\log_b x}} \quad \text{onde} \quad \overline{\log_b x} = \frac{\sum_{i=1}^n \log_b x_i}{n}$$

# Exemplo de Média Geométrica



- A média geométrica é utilizada para casos onde a escala de referência é não linear, em particular, exponencial.
  - Imagine que uma experiência com 25 indivíduos consistiu em determinar a **Concentração Mínima Inibitória (CMI)** de um certo antibiótico.

CMI (µg/ml)	Número de Indivíduos
1,00000	1
0,50000	2
0,25000	6
0,12500	4
0,06250	3
0,03125	9
Total	25

# Exemplo de Média Geométrica



- Observe que escala não é linear, logo deve-se aplicar a média geométrica.

$$\overline{\log x} = \frac{1 \cdot \log 1 + 2 \cdot \log 0,5 + 6 \cdot \log 0,25 + \dots + 9 \cdot \log 0,03125}{25} = -0,9994$$

- Logo,

$$G = 10^{\overline{\log x}} = 10^{-0,9994} \therefore G = 0,1001$$

# Média Harmônica



- A média harmônica ( $h$ ) é dada por:

$$H = n \cdot \left[ \sum_{i=1}^n (x_i)^{-1} \right]^{-1} = \frac{n}{\frac{1}{x_1} + \frac{1}{x_2} + \dots + \frac{1}{x_n}}$$

# Mediana



- A mediana é outra forma para selecionar um valor representativo e central de uma conjunto numérico.
  - Dado que um conjunto de observações esteja ordenado (crescente ou decrescente), o valor que ocupar a posição equidistante dos extremos é um valore representativo central deste conjunto.
    - **Este valor é a mediana:**  $\hat{x}$



# Mediana



- Matematicamente:

$$X = \{x_1, x_2, \dots, x_n\}$$

$$\text{com, } \{x_1 < x_2 < \dots < x_n\}$$

$$\text{tem-se, } \hat{x} = \begin{cases} x_{\left(\frac{n+1}{2}\right)}, & \text{se } n \text{ for ímpar} \\ \frac{x_{\left(\frac{n}{2}\right)} + x_{\left(\frac{n}{2}+1\right)}}{2}, & \text{se } n \text{ for par} \end{cases}$$

# Mediana



- Exemplo:
  - Dado os conjuntos de pontos:
    - $X = \{2, 8, 3, 5, 4\}$
    - $Y = \{2, 8, 3, 5, 4, 0\}$Calcule as respectivas medianas
  - Resposta:

$$\hat{x} = 4$$

$$\hat{y} = 3,5$$

# Mediana



- A medida da Média é influenciada diretamente pelos valores do conjunto.
  - Ou seja, se houver um valor atípico (muito grande ou muito pequeno) a medida da média poderá ser bastante modificada
- Já o cálculo da mediana não irá depender dos valores extremos
  - Desta forma, a mediana é bem mais robusta quando há valores atípicos nos dados.

# Quartis, Decis e Percentis




- A mediana é uma separatriz de um conjunto
  - 50% dos valores estão abaixo da mediana e 50% estão acima!
  - Ou seja, o conjunto foi dividido em 2 parte
- Podem ser definidas outras separtrizes
  - Tal que o conjunto seja dividido em:
    - 4 partes – Quartis
    - 10 partes – Decis
    - 100 partes - Percentis

# Quartis, Decis e Percentis



- Quartis:  $Q_1$ ,  $Q_2$ ,  $Q_3$  e  $Q_4$



- De forma análoga:
  - Decis:  $D_1, D_2, \dots, D_9, D_{10}$
  - Percentis:  $P_1, P_2, \dots, P_{99}, P_{100}$

# Determinando as Separatrizes



- Forma geral para a determinação de separatrizes:

$$R_i = (N + 1) \frac{i}{C}, \quad \text{com } i = 1, 2, \dots, C - 1$$

– Onde:

- $R_i$  é a ordem do número que separa a  $i$ -ésima separatriz
- $i$  é a separatriz desejada
- $C$  é o número de divisões do conjunto

# Determinando as Sepatarizes



- Nos casos específicos:

- Quartis: 
$$R_i = (n + 1) \frac{i}{4}$$

- Com  $i=1, 2$  e  $3$  (o quarto quartil é o último elemento!)

- Decis: 
$$R_i = (n + 1) \frac{i}{10}$$

- Com  $i=1, 2, \dots, 9$  (o décimo decil é o último elemento!)

- Percentis: 
$$R_i = (n + 1) \frac{i}{100}$$

- Com  $i=1, 2, \dots, 99$  (o centésimo percentil é o último elemento!)

# Exemplos:



- Dado o conjunto de dados:
  - $X = \{2, 2, 3, 5, 6, 6, 6, 7, 7, 7, 7, 8, 8, 9, 10, 12, 12, 15, 18, 25, 27, 28, 29, 30, 33\}$
  - Determine os Quartis, o Decil 9 e o Percentil 95.



# Moda



- A **Moda** é outra forma para selecionar um valor representativo e central de uma conjunto numérico.
  - A moda de um conjunto de dados é o seu valor mais frequente
    - Ou seja, é o elemento que aparece o maior número de vezes.
    - Assim, dado um conjunto de valores,  $x_1, x_2, \dots, x_k$ , com as respectivas frequências  $f_1, f_2, \dots, f_k$
    - Então defini-se a moda por:



$$\tilde{x} = x_i \mid f_i > f_1, f_2, \dots, f_k$$

# Moda





- Dado um conjunto de dados, este pode gerar distribuições:
  - Amodais
    - Quando todas as frequências são iguais
  - Unimodal
    - Quando há apenas uma frequência máxima
  - Bimodais
    - Quando existem duas frequências máximas
  - Multimodais
    - Quando existem mais de duas frequências máximas



# Distribuição Amodal



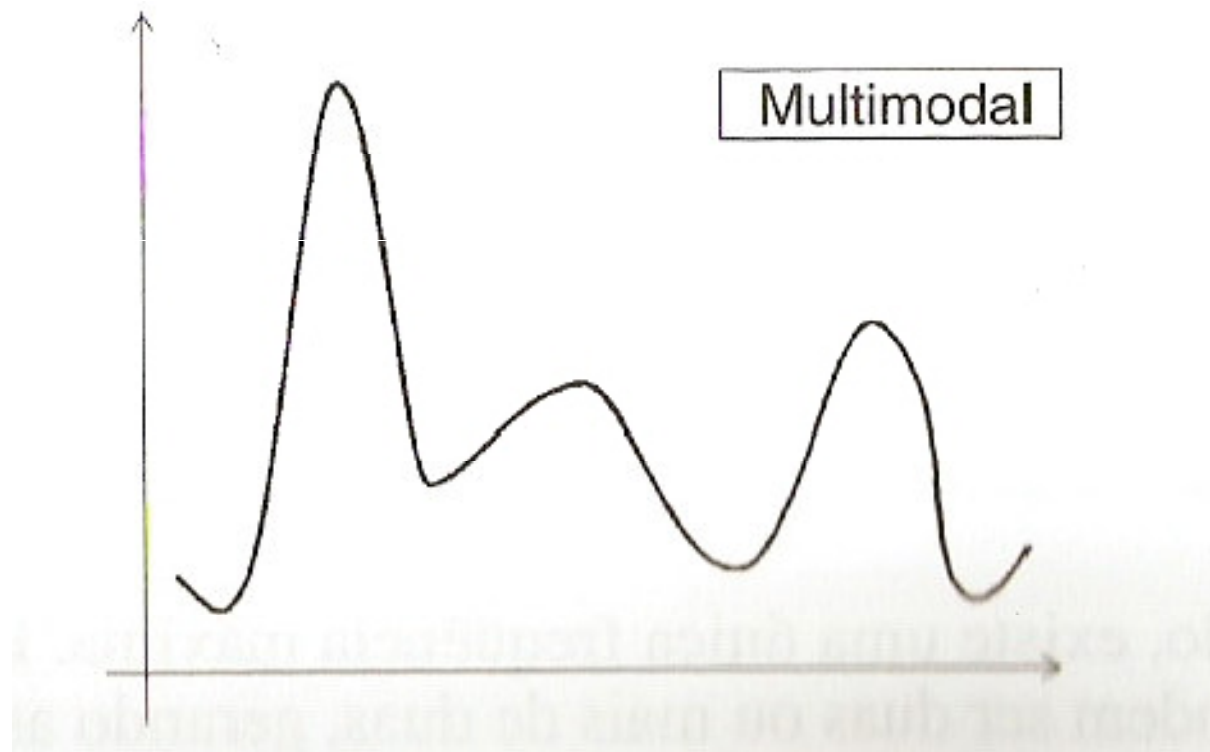

# Distribuição Unimodal



# Distribuição Bimodal



# Distribuição Multimodal



# Moda e as Demais Medidas



- Imagine um doença que verifica-se na infância e na velhice.
  - Tipicamente a sua distribuição será:




Fig. 4.3 Medidas de tendência central em distribuições bimodais.

- Como calcular as idades normais da doença?

# Tratamento de Dados Agrupados



- Se os dados são obtidos de forma agrupada, como calcular sua médias?
  - Suponha, por exemplo, que tenha-se uma tabela

Classes	PM	fa
$Li_1 - Ls_1$	$pm_1$	$fa_1$
$Li_2 - Ls_2$	$Pm_2$	$fa_2$
.	.	.
.	.	.
.	.	.
$Li_n - Ls_n$	$pm_n$	$fa_n$
Total	—	n

Onde PM é o ponto médio da Classe, dado por:

$$pm_i = \frac{Ls_i + Li_i}{2}$$



# Tratamento de Dados Agrupados



- A média aritmética para dados agrupados pode ser calculada adotando-se o ponto médio da classe como seu valor representativo

$$\bar{x} = \frac{\sum_{i=1}^m pm_i \cdot fa_i}{\sum_{j=1}^m fa_j} = \frac{\sum_{i=1}^m pm_i \cdot fa_i}{n}$$

# Tratamento de Dados Agrupados



- Outra forma de calcular a média de dados agrupados é a partir do **calculado abreviado ou desvio em classes**:

$$\bar{x} = K + \left( \frac{\sum_{i=1}^m fa_i \cdot v_i}{n} \right) \cdot c$$

– Onde:

- K é o ponto médio de uma classe
- $fa_i$  é a frequência absoluta da classe i
- $v_i$  é um valor de incremento ou decremento calculado a partir da classe escolhida para K
- c é o intervalo de classe

# Procedimento para o Cálculo Abreviado



- Escolhe-se uma classes, preferencialmente a de maior frequência absoluta. O ponto média desta classe será  $K$
- Atribui-se o valor zero ao  $v$  a classe escolhida
- Os demais valores de  $v$  são obtidos decrementando o seu valor para as classes anteriores à classe de  $K$ , e incrementando para as classes superiores

# Exemplo



**Tabela 4.5**

<b>Classe</b>	<b><i>fa</i></b>	<b><i>v</i></b>	<b><i>fa.v</i></b>
0,0-0,2	3	-3	-9
0,2-0,4	6	-2	-12
0,4-0,6	18	-1	-18
0,6-0,8	35	0	0
0,8-1,0	16	+1	+16
1,0-1,2	2	+2	+4
<b>Total</b>	<b>80</b>	<b>—</b>	<b>-19</b>

# Mediana para Dados Agrupados



- Calcula-se a mediana pela expressão:

- $$\hat{x} = \hat{Lir} + \left( \frac{\frac{n}{2} - \sum_{i=1}^{med-1} fa_i}{fa_{med}} \right) \cdot c$$

– Onde

- $\hat{Lir}$  = limite inferior real da classe mediana
- $fa_{med}$  = frequência absoluta da classe mediana
- Sendo a classe mediana aquela que contém o valor mediano
  - O valor mediano é o valor de ordem  $n/2$

# Exemplo - Mediana



- Para a última tabela apresentada, qual o valor da mediana?

# Moda para Dados Agrupados



- Calcula-se a moda para dados agrupados a partir da expressão:

$$\tilde{x} = \tilde{L}_{ir} + \left( \frac{\Delta 1}{\Delta 1 + \Delta 2} \right) \cdot c$$

– Onde:

- $L_{ir}$  = limite inferior da classe modal
- $\Delta 1$  = Excesso de frequência da classe modal sobre a classe imediatamente inferior
- $\Delta 2$  = Excesso de frequência da classe modal sobre a classe imediatamente Superior.

# Moda para Dados Agrupados



- Se existirem mais de uma frequência relevante na Tabela de dados, de tal forma que esta frequência não seja adjacente à frequência modal, então a distribuição dos dados terá mais de uma moda.
  - E todos os valores das modas devem ser calculados!



# Exemplo



- Para a última tabela, existem quantas modas?
  - E qual o valor destas?

# Referências da Aula



- Livro Texto: Bioestatística. Teoria e Computacional (Héctor G. Arango). Guanabara
  - Seção 1 – Medidas de Tendência Central
- Leituras Complementares:
  - Livro: Bioestatística. Princípios e Aplicações (Sidia M. Callegari-Jacques)
    - Capítulo 2.
  - Livro: Estatística Básica (Wilton de O. Bussab e Pedro A. Morettin). Saraiva
    - Capítulo: 3