

Medidas-Resumo

Medidas de Posição

- **A moda** é definida como a realização mais frequente do conjunto de valores observados.

Tabela 2.5 Frequências e porcentagens dos empregados da seção de orçamentos da Companhia MB, segundo o número de filhos.

Nº de filhos z_i	Frequência n_i	Porcentagem $100 f_i$
0	4	20
1	5	25
2	7	35
3	3	15
5	1	5
Total	20	100

Fonte: Tabela 2.1.

Moda = 2

- **A mediana** é a realização que ocupa a posição central da série de observações, quando estão ordenadas em ordem crescente.

Exemplo:

- i) 3, 4, 7, 8 e 8, a mediana = 7;
- ii) 3, 4, 7, 8, 8 e 9, a mediana = $(7+8)/2 = 7,5$.

- **A média aritmética**, é a soma das observações dividida pelo número delas. Assim, a média aritmética de 3, 4, 7, 8 e 8 é

$$(3 + 4 + 7 + 8 + 8)/5 = 6.$$

Exemplo 3.1 Usando os dados da Tabela 2.5, já encontramos que a moda da variável Z é 2. Para a mediana, constatamos que esta também é 2, média aritmética entre a décima e a décima primeira observações.

Tabela 2.5 Frequências e porcentagens dos empregados da seção de orçamentos da Companhia MB, segundo o número de filhos.

Nº de filhos z_i	Frequência n_i	Porcentagem 100 f_i
0	4	20
1	5	25
2	7	35
3	3	15
5	1	5
Total	20	100

Fonte: Tabela 2.1.

A média aritmética será

$$\frac{4 \times 0 + 5 \times 1 + 7 \times 2 + 3 \times 3 + 5 \times 1}{20} = \frac{33}{20} = 1,65.$$

Vamos formalizar os conceitos introduzidos acima. Se x_1, \dots, x_n são os n valores (distintos ou não) da variável X , a média aritmética, ou simplesmente média, de X pode ser escrita

$$\bar{x} = \frac{x_1 + \dots + x_n}{n} = \frac{1}{n} \sum_{i=1}^n x_i. \quad (3.1)$$

Agora, se tivermos n observações da variável X , das quais n_1 são iguais a x_1 , n_2 são iguais a x_2 etc., n_k iguais a x_k , então a média de X pode ser escrita

$$\bar{x} = \frac{n_1 x_1 + n_2 x_2 + \dots + n_k x_k}{n} = \frac{1}{n} \sum_{i=1}^k n_i x_i. \quad (3.2)$$

Se $f_i = n_i/n$ representar a frequência relativa da observação x_i , então (3.2) também pode ser escrita

$$\bar{x} = \sum_{i=1}^k f_i x_i. \quad (3.3)$$

Consideremos, agora, as observações ordenadas em ordem crescente. Vamos denotar a menor observação por $x_{(1)}$, a segunda por $x_{(2)}$, e assim por diante, obtendo-se

$$x_{(1)} \leq x_{(2)} \leq \dots \leq x_{(n-1)} \leq x_{(n)}. \quad (3.4)$$

Por exemplo, se $x_1 = 3, x_2 = -2, x_3 = 6, x_4 = 1, x_5 = 3$, então $-2 \leq 1 \leq 3 \leq 3 \leq 6$, de modo que $x_{(1)} = -2, x_{(2)} = 1, x_{(3)} = 3, x_{(4)} = 3$ e $x_{(5)} = 6$.

As observações ordenadas como em (3.4) são chamadas *estatísticas de ordem*.

Com essa notação, a mediana da variável X pode ser definida como

$$\text{md}(X) = \begin{cases} x_{\left(\frac{n+1}{2}\right)}, & \text{se } n \text{ ímpar;} \\ \frac{x_{\left(\frac{n}{2}\right)} + x_{\left(\frac{n}{2}+1\right)}}{2}, & \text{se } n \text{ par.} \end{cases} \quad (3.5)$$

Exemplo:

Tabela 2.6 Distribuição de frequências da variável S , salário dos empregados da seção de orçamentos da Companhia MB.

Classes de salários	Ponto médio s_i	Frequência n_i	Porcentagem $100 f_i$
4,00 ─ 8,00	6,00	10	27,78
8,00 ─ 12,00	10,00	12	33,33
12,00 ─ 16,00	14,00	8	22,22
16,00 ─ 20,00	18,00	5	13,89
20,00 ─ 24,00	22,00	1	2,78
Total	—	36	100,00

Fonte: Tabela 2.4.

A moda, mediana e média para os dados da Tabela 2.6 são, respectivamente,

$$\text{mo}(S) \approx 10,00,$$

$$\text{md}(S) \approx 10,00,$$

$$\bar{s} \approx \frac{10 \times 6,00 + 12 \times 10,00 + 8 \times 14,00 + 5 \times 18,00 + 1 \times 22,00}{36} = 11,22.$$

Medidas de Dispersão: um valor que resume a variabilidade de um conjunto de dados.

Por exemplo, suponhamos que cinco grupos de alunos submeteram-se a um teste, no qual obtiveram as seguintes notas:

Grupo A (variável X):	3, 4, 5, 6, 7.
Grupo B (variável Y):	1, 3, 5, 7, 9.
Grupo C (variável Z):	5, 5, 5, 5, 5.
Grupo D (variável W):	3, 5, 5, 7.
Grupo E (variável V):	3, 5, 5, 6, 6.

$$\bar{x} = \bar{y} = \bar{z} = \bar{w} = \bar{v} = 5,0$$

Duas medidas são as mais usadas: **desvio médio e variância.**

O princípio básico é analisar os desvios das observações em relação à média dessas observações.

Para o grupo A teríamos, respectivamente,

$$\sum_{i=1}^5 |x_i - \bar{x}| = 2 + 1 + 0 + 1 + 2 = 6,$$
$$\sum_{i=1}^5 (x_i - \bar{x})^2 = 4 + 1 + 0 + 1 + 4 = 10.$$

O uso desses totais pode causar dificuldades quando comparamos conjuntos de dados com **números diferentes de observações**, como os conjuntos A e D acima. Desse modo, é mais conveniente exprimir as medidas como médias, isto é, o desvio médio e a variância são definidos por

$$\text{dm}(X) = \frac{\sum_{i=1}^n |x_i - \bar{x}|}{n}, \quad (3.6)$$

$$\text{var}(X) = \frac{\sum_{i=1}^n (x_i - \bar{x})^2}{n}, \quad (3.7)$$

respectivamente. Para o grupo A temos

$$\text{dm}(X) = 6/5 = 1,2,$$
$$\text{var}(X) = 10/5 = 2,0,$$

enquanto para o grupo D temos

$$\text{dm}(W) = 4/4 = 1,0,$$
$$\text{var}(W) = 8/4 = 2,0.$$

Sendo a variância uma medida de dimensão igual ao quadrado da dimensão dos dados (por exemplo, se os dados são expressos em cm, a variância será expressa em cm^2), pode causar problemas de interpretação. Costuma-se usar, então, o **desvio padrão**, que é definido como a raiz quadrada positiva da variância.

Ambas as medidas de dispersão (d_m e d_p) indicam, em média, qual será o “erro”(desvio) cometido ao tentar substituir cada observação pela medida resumo do conjunto de dados (no caso, a média).

Exemplo 3.3 Calcular as medidas de dispersão acima para a variável $Z =$ número de filhos, resumida na Tabela 2.5.

Tabela 2.5 Frequências e porcentagens dos empregados da seção de orçamentos da Companhia MB, segundo o número de filhos.

Nº de filhos z_i	Frequência n_i	Porcentagem $100 f_i$
0	4	20
1	5	25
2	7	35
3	3	15
5	1	5
Total	20	100

Fonte: Tabela 2.1.

A média aritmética será

$$\frac{4 \times 0 + 5 \times 1 + 7 \times 2 + 3 \times 3 + 5 \times 5}{20} = \frac{33}{20} = 1,65.$$

Os desvios são $z_i - \bar{z}$: $-1,65$; $-0,65$; $0,35$; $1,35$; $3,35$. Segue-se que

$$dm(Z) = \frac{4 \times (1,65) + 5 \times (0,65) + 7 \times (0,35) + 3 \times (1,35) + 1 \times (3,35)}{20} = 0,98.$$

Também,

$$var(Z) = \frac{4(-1,65)^2 + 5(-0,65)^2 + 7(0,35)^2 + 3(1,35)^2 + 1(3,35)^2}{20} = 1,528.$$

Consequentemente, o desvio padrão de Z é

$$dp(Z) = \sqrt{1,528} = 1,24.$$

Suponha que observemos n_1 vezes os valores x_1 etc., n_k vezes o valor x_k da variável X . Então,

$$dm(X) = \frac{\sum_{i=1}^k n_i |x_i - \bar{x}|}{n} = \sum_{i=1}^k f_i |x_i - \bar{x}|, \quad (3.8)$$

$$var(X) = \frac{\sum_{i=1}^k n_i (x_i - \bar{x})^2}{n} = \sum_{i=1}^k f_i (x_i - \bar{x})^2, \quad (3.9)$$

$$dp(X) = \sqrt{var(X)}. \quad (3.10)$$

Exemplo 3.4 Consideremos a variável S = salário.

Tabela 2.6 Distribuição de frequências da variável S , salário dos empregados da seção de orçamentos da Companhia MB.

Classes de salários	Ponto médio s_i	Frequência n_i	Porcentagem $100 f_i$
4,00 — 8,00	6,00	10	27,78
8,00 — 12,00	10,00	12	33,33
12,00 — 16,00	14,00	8	22,22
16,00 — 20,00	18,00	5	13,89
20,00 — 24,00	22,00	1	2,78
Total	—	36	100,00

Fonte: Tabela 2.4.

$$\bar{s} \approx \frac{10 \times 6,00 + 12 \times 10,00 + 8 \times 14,00 + 5 \times 18,00 + 1 \times 22,00}{36} = 11,22.$$

$$var(S) \approx \left[10(6,00 - 11,22)^2 + 12(10,00 - 11,22)^2 + 8(14 - 11,22)^2 + 5(18,00 - 11,22)^2 + 1(22,00 - 11,22)^2 \right] / 36 = 19,40$$

e, portanto,

$$dp(S) \approx \sqrt{19,40} = 4,40.$$

É fácil ver que $dm(S) \approx 3,72$.

Uma maneira computacionalmente mais eficiente de calcular a variância é

$$\text{var}(X) = \frac{\sum_{i=1}^n x_i^2}{n} - \bar{x}^2, \quad (3.11)$$

e, no caso de observações repetidas,

$$\text{var}(X) = \sum_{i=1}^k f_i x_i^2 - \bar{x}^2. \quad (3.12)$$