



Lista 01 - Gabarito

8. Intervalos de Classes Desiguais - É muito comum o uso de classes com tamanhos desiguais no agrupamento dos dados em tabelas de frequências. Nestes casos, deve-se tomar alguns cuidados especiais quanto à análise e construção do histograma.

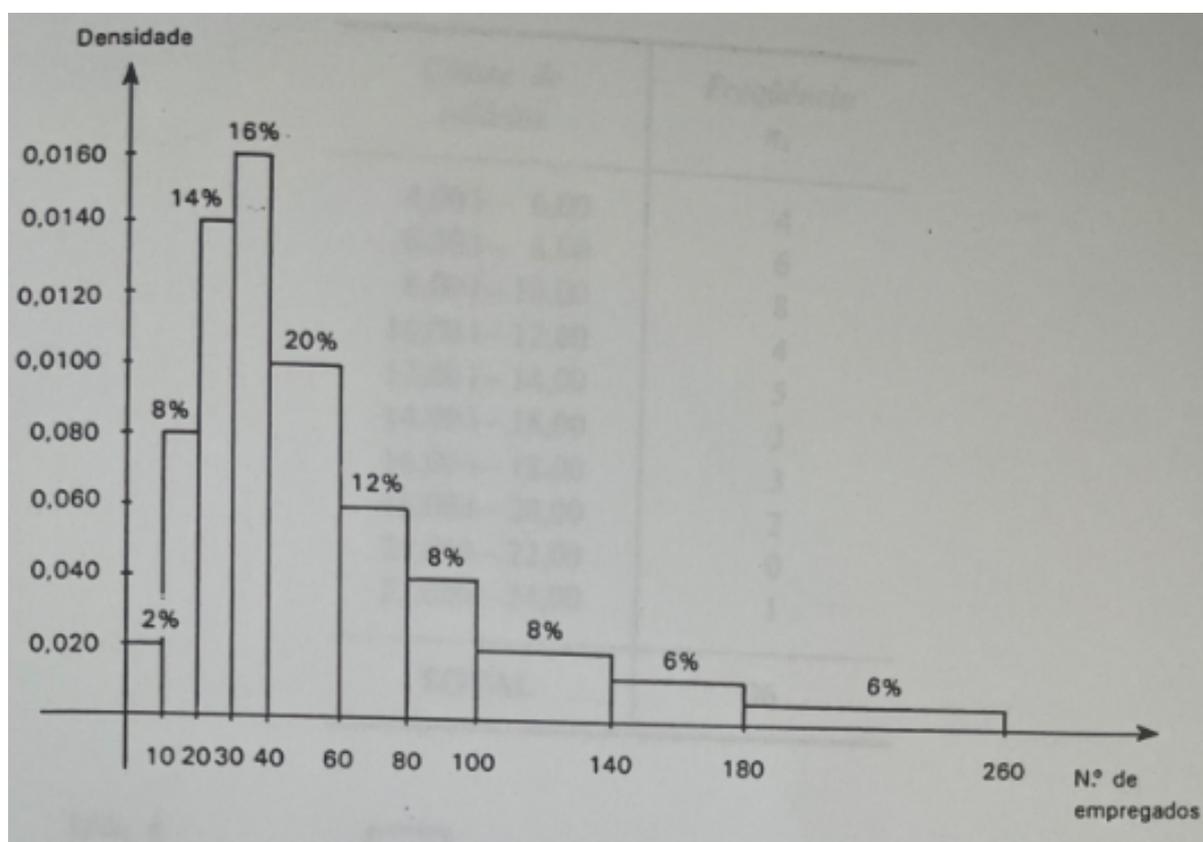
A tabela abaixo fornece a distribuição de 250 empresas classificadas segundo o número de empregados. Uma análise superficial pode levar à conclusão de que a concentração vem aumentando até atingir um máximo na classe de 40-60, voltando a diminuir depois, mas não tão acentuadamente. Porém, um estudo mais detalhado revela que a amplitude da classe 40-60 é o dobro da amplitude das classes anteriores. Assim, espera-se que mais elementos caiam nessa classe, mesmo que a concentração seja levemente inferior. Então, um primeiro cuidado é construir a coluna que indica as amplitudes Δ_i de cada classe. Estes valores estão representados na terceira coluna da tabela.

| <i>Número de empregados</i> | <i>Frequência</i> n_i | <i>Amplitude</i> Δ_i | <i>Densidade</i> n_i/Δ_i | <i>Proporção</i> f_i | <i>Densidade</i> f_i/Δ_i |
|-----------------------------|----------------------------|--------------------------------|------------------------------------|---------------------------|------------------------------------|
| 0 — 10 | 5 | 10 | 0,50 | 0,02 | 0,0020 |
| 10 — 20 | 20 | 10 | 2,00 | 0,08 | 0,0080 |
| 20 — 30 | 35 | 10 | 3,50 | 0,14 | 0,0140 |
| 30 — 40 | 40 | 10 | 4,00 | 0,16 | 0,0160 |
| 40 — 60 | 50 | 20 | 2,50 | 0,20 | 0,0100 |
| 60 — 80 | 30 | 20 | 1,50 | 0,12 | 0,0060 |
| 80 — 100 | 20 | 20 | 1,00 | 0,08 | 0,0040 |
| 100 — 140 | 20 | 40 | 0,50 | 0,08 | 0,0020 |
| 140 — 180 | 15 | 40 | 0,38 | 0,06 | 0,0015 |
| 180 — 260 | 15 | 80 | 0,19 | 0,06 | 0,0008 |
| TOTAL | 250 | — | — | 1,00 | — |

Um segundo passo é a construção da coluna das densidades de frequências em cada classe que é obtida dividindo as frequências n_i pelas amplitudes Δ_i . Ou seja, à medida que indica qual a concentração por unidade da variável. Assim, observando-se os números da quarta coluna, vê-se que a classe de maior concentração passa a ser a 30-40, enquanto que a última é de menor concentração. Para compreender a distribuição, estes dados são muito mais informativos do que as frequências absolutas simplesmente.

De modo análogo, pode-se construir a densidade da proporção (ou porcentagem) por unidade da variável (verifique a construção através da 5ª e 6ª colunas). A interpretação para f_i / Δ_i é muito semelhante àquela dada para as sobre n_i / Δ_i .

Para a construção do histograma basta lembrar que a área total deve ser igual a um ou 100%, o que sugere usar no eixo das ordenadas os valores de f_i / Δ_i . O histograma para estes dados está na figura abaixo.



Não há nada para se resolver aqui, é só leitura.

9. Dispomos de uma relação de 200 aluguéis de imóveis urbanos e uma relação de 100 aluguéis rurais.

| <i>Classes de aluguéis (codificados)</i> | <i>Zona urbana</i> | <i>Zona rural</i> |
|--|------------------------|-----------------------|
| 2 ┤ 3 | 10 | 30 |
| 3 ┤ 5 | 40 | 50 |
| 5 ┤ 7 | 80 | 15 |
| 7 ┤ 10 | 50 | 5 |
| 10 ┤ 15 | 20 | 0 |
| TOTAL | 200 | 100 |

(a) Construa os histogramas das duas distribuições.

Primeiro, vamos construir as tabelas com as densidades. Em seguida, podemos construir o histograma.

Zona Urbana

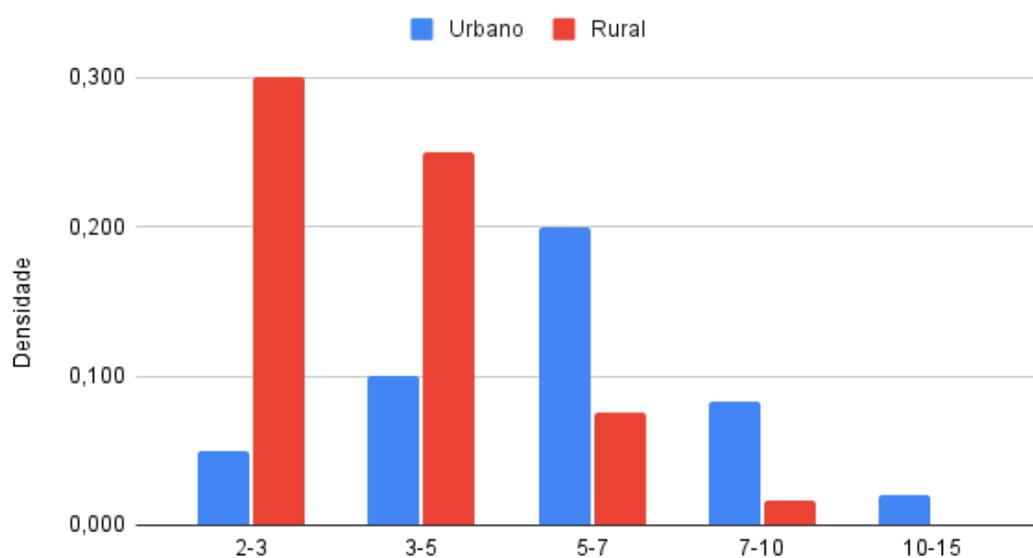
| Classe de Aluguéis | Frequência n_i | Amplitude Δi | Densidade $n_i / \Delta i$ | Proporção f_i | Densidade $f_i / \Delta i$ |
|--------------------|------------------|----------------------|----------------------------|-----------------|----------------------------|
| 2-3 | 10 | 1 | 10 | 0,05 | 0,050 |
| 3-5 | 40 | 2 | 20 | 0,20 | 0,100 |
| 5-7 | 80 | 2 | 40 | 0,40 | 0,200 |
| 7-10 | 50 | 3 | 16,67 | 0,25 | 0,083 |
| 10-15 | 20 | 5 | 4 | 0,10 | 0,020 |
| Total | 200 | | | 1,00 | |

Zona Rural

| Classe de Aluguéis | Frequência n_i | Amplitude Δi | Densidade $n_i / \Delta i$ | Proporção f_i | Densidade $f_i / \Delta i$ |
|--------------------|------------------|----------------------|----------------------------|-----------------|----------------------------|
| 2-3 | 30 | 1 | 30 | 0,30 | 0,300 |
| 3-5 | 50 | 2 | 25 | 0,50 | 0,250 |
| 5-7 | 15 | 2 | 7,5 | 0,15 | 0,075 |
| 7-10 | 5 | 3 | 1,67 | 0,05 | 0,017 |
| 10-15 | 0 | 5 | 0 | 0,00 | 0,000 |
| Total | 100 | | | 1,00 | |

O histograma da densidade $f_i / \Delta i$ por classes de aluguéis é

Histograma das Classes de Aluguéis



(b) Com base nos histogramas, discuta e compare as duas distribuições.

A densidade de frequência no gráfico da zona urbana demonstra que a classe de alugueis predominante é 5-7. No caso das famílias provenientes da zona rural, a classe predominante de alugueis é 2-3, demonstrando um valor mais baixo entre a população observada. É possível notar que a distribuição da densidade das classes de alugueis é mais simétrica, em torno da classe 5-7 (onde se encontra a mediana), na zona urbana, e mais assimétrica para esquerda na zona rural.

1. Quer se estudar o número de erros de impressão de um livro. Para isso, escolheu-se uma amostra de 50 páginas, encontrando-se o seguinte número de erros por página:

| Erros | Frequência |
|-------|------------|
| 0 | 25 |
| 1 | 20 |
| 2 | 3 |
| 3 | 1 |
| 4 | 1 |

(a) Qual o número médio de erros por página?

Seja x_i o número de erros na página i da nossa amostra. A média amostral de erros nessa amostra de 50 páginas é

$$\bar{X} = \frac{1}{50} \sum_{i=1}^{50} x_i = \frac{1}{50} [(25)(0) + (20)(1) + (3)(2) + (1)(3) + (1)(4)] = 0,66.$$

(b) E o número mediano?

Vamos ordenar x_i do menor para o maior, tal que $x_i < x_{i+1}$. Assim, $x_{50} > x_{49} > \dots > x_2 > x_1$. Assim, como o tamanho da amostra é 50, ou seja, é par, a mediana amostral é dada por

$$md_x = \frac{x_{50/2} + x_{(50/2)+1}}{2} = \frac{x_{25} + x_{26}}{2} = \frac{0 + 1}{2} = 0,5.$$

(c) Qual é o desvio padrão?

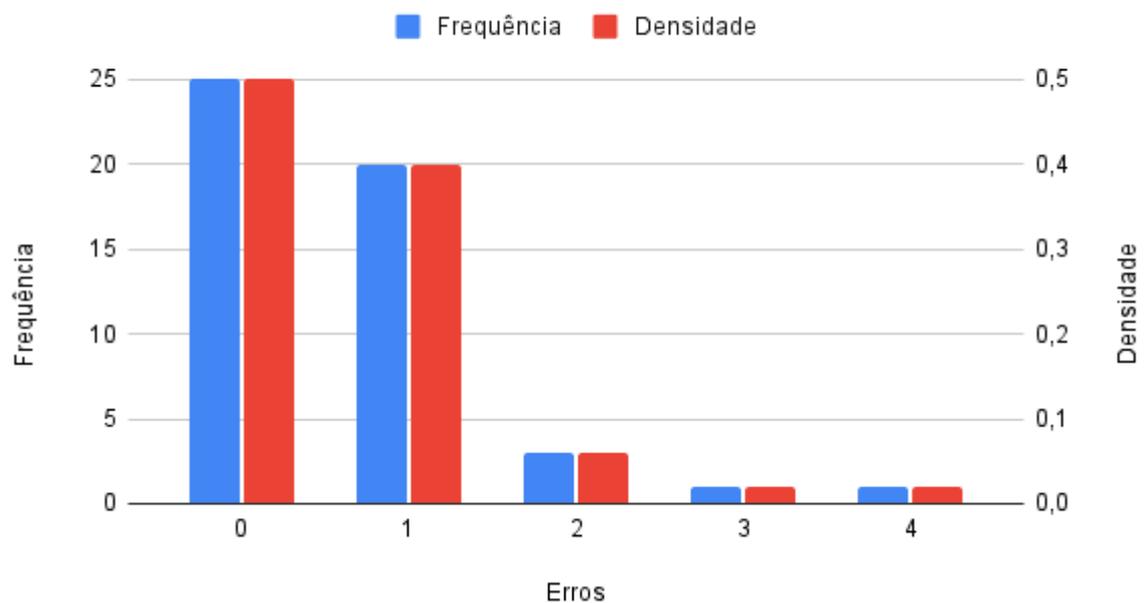
O desvio padrão amostral é dado por

$$S_x = \sqrt{\frac{1}{50-1} \sum_{i=1}^{50} (x_i - \bar{X})^2} =$$
$$= \frac{1}{7} \sqrt{25(0 - 0,66)^2 + 20(1 - 0,66)^2 + 3(2 - 0,66)^2 + (3 - 0,66)^2 + (4 - 0,66)^2} =$$
$$= \frac{1}{7} \sqrt{35,22} \approx 0,8478.$$

(d) Faça uma representação gráfica para a distribuição.

Note que a frequência e a densidade nos retornam informações equivalentes.

Erros por Página



(e) Se o livro tem 500, qual o número total de erros esperado no livro?

Partindo do pressuposto de que a nossa amostra é não viesada (por exemplo, se escolhermos só páginas com imagens, isto é, haveria menos palavras por página, subestimando o número de erros), espera-se que encontremos 330 erros nas 500 páginas (lembre-se que a média amostral de erros é 0,66 por página).

2. As taxas de juros recebidas por 10 ações durante um certo período foram (medidas em porcentagem) 2,59; 2,64; 2,60; 2,62; 2,57; 2,55; 2,61; 2,50; 2,63; 2,64. Calcule a média, a mediana e o desvio padrão.

Aqui não se faz a distinção de amostra e população. Assim, não diferenciaremos o cálculo do desvio padrão, podemos fazer de ambas as formas, amostral e populacional. Denotamos a taxa de juros como r .

Se considerarmos os dados como uma amostra, então,

- a média amostral é dada por

$$\bar{r} = \frac{1}{10}(2,59 + 2,64 + 2,60 + 2,62 + 2,57 + 2,55 + 2,61 + 2,50 + 2,63 + 2,64) = 2,595;$$

- ordenando a amostra (2,5; 2,55; 2,57; 2,59; **2,6**; **2,61**; 2,62; 2,63; 2,64; 2,64), vemos que a mediana amostral é

$$md_r = \frac{2,6 + 2,61}{2} = 2,605;$$

- a variância amostral é

$$S_r^2 = \frac{1}{10-1} \left[(2,5 - 2,595)^2 + (2,55 - 2,595)^2 + (2,57 - 2,595)^2 + (2,59 - 2,595)^2 + (2,6 - 2,595)^2 + (2,61 - 2,595)^2 + (2,62 - 2,595)^2 + (2,63 - 2,595)^2 + (2,64 - 2,595)^2 + (2,64 - 2,595)^2 \right] \approx 0,001983;$$

- e o desvio-padrão amostral é

$$S_r \approx \sqrt{0,001983} \approx 0,0445.$$

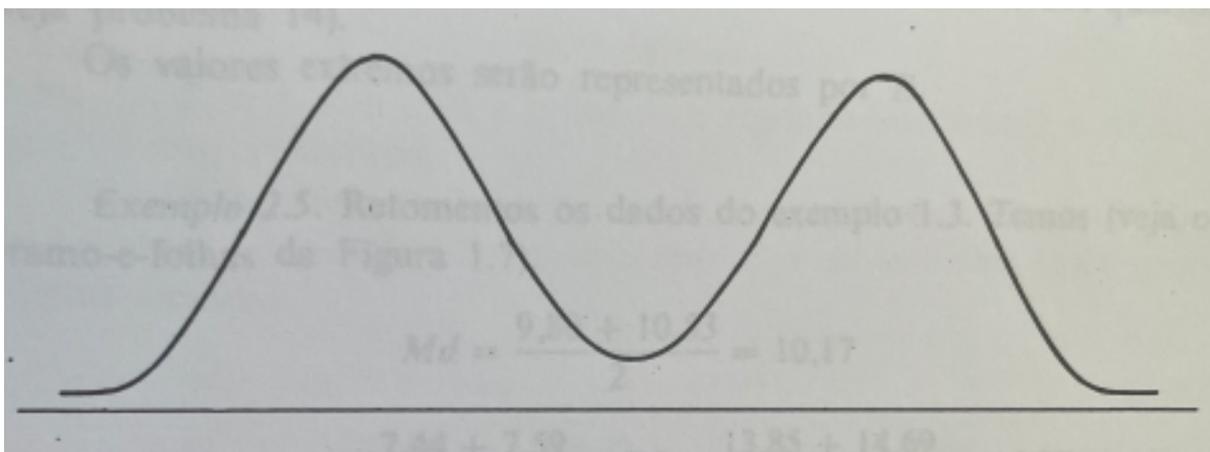
Se tratarmos os dados como nossa população de interesse (a média e a mediana ficam iguais), a variância populacional é

$$\begin{aligned} \sigma_r^2 = \frac{1}{10} & \left[(2,5 - 2,595)^2 + (2,55 - 2,595)^2 + (2,57 - 2,595)^2 \right. \\ & + (2,59 - 2,595)^2 + (2,6 - 2,595)^2 + (2,61 - 2,595)^2 + (2,62 - 2,595)^2 \\ & \left. + (2,63 - 2,595)^2 + (2,64 - 2,595)^2 + (2,64 - 2,595)^2 \right] \approx 0,001785. \end{aligned}$$

e o desvio padrão populacional é

$$\sigma_r \approx \sqrt{0,001785} \approx 0,0422.$$

5. Suponha que a variável abaixo tenha a distribuição como na figura abaixo (suponha que é simétrica - a página escaneada ta torta).



Você acha que a média é uma boa medida de posição? E a mediana? Justifique.

Observe que só com a média e a mediana não dá para saber muita coisa da nossa variável de interesse, dado que essas medidas de posição pouco informam sobre a distribuição, não sendo possível identificar se a distribuição é simétrica, nem o quão dispersa é.

Note que uma medida de posição que traria mais informação acerca da distribuição da variável de interesse seria a moda (no caso, se for simétrica), uma vez que, sabendo que há duas modas (a isto damos o nome de distribuição bimodal), saberíamos que haveria dois picos na distribuição (ainda não seria possível aferir nada sobre o quão simétrica é, nem sobre sua dispersão).

6. Numa pesquisa realizada com **100 famílias**, levantaram-se as seguintes informações:

| Número de filhos | 0 | 1 | 2 | 3 | 4 | 5 | mais que 5 |
|------------------------|----|----|----|----|---|---|------------|
| Frequência de famílias | 17 | 20 | 28 | 19 | 7 | 4 | 5 |

(a) Qual é a mediana do número de filhos?

Denotamos x_i o número de filhos da família i . Se ordenarmos a amostra, então, $x_{50} = 2$ e $x_{51} = 2$, ou seja, a mediana é 2. Note que da família 38 até a 55, todas têm dois filhos.

(b) E a moda?

A moda é 2, dado que a maior frequência é de famílias que têm 2 filhos.

(c) Que problemas você enfrentaria para calcular a média? Faça alguma suposição e encontre-a.

O problema é não saber quanto é “mais que 5” especificamente, dado que precisamos dessa informação para computar a média. Supondo que “mais que 5” seja 6, então,

$$\bar{X} = \frac{1}{100} [0(17) + 1(20) + 2(28) + 3(19) + 4(7) + 5(4) + 6(5)] = 2,11,$$

ou seja, cada família tem em média 2,11 filhos.

