











Figura 02- Série de dados de óbitos em acidentes de trânsito no período 2001-2010.



Fonte: <[http://www.vias-seguras.com/layout/set/print/os\\_acidentes/estatisticas/estatisticas\\_nacionais](http://www.vias-seguras.com/layout/set/print/os_acidentes/estatisticas/estatisticas_nacionais)>.

Para que gráficos como os apresentados nas Figuras 03 e 04 possam ser produzidos, faz-se necessária a mobilização de um esforço importante, com mobilização de recursos humanos, materiais e financeiros de monta para a coleta, tratamento e análise de dados, conforme metodologia adequada com o estudo das distribuições de frequências e representações gráficas, medidas de posição e dispersão para que possam ser adequadamente utilizados para atender, por exemplo, às necessidades do Estado na formulação de políticas públicas, fornecendo dados estatísticos demográficos e econômicos.

## Enap

Passaremos, então, à apresentação dos fundamentos da estatística descritiva, essenciais para a compreensão do processo estatístico utilizado para a análise de dados e o adequado tratamento dos mesmos.

Como primeiro tópico a ser trabalhado, teremos o estudo das distribuições de frequências para os dados analisados para a adequada compreensão de determinada variável à luz da Estatística.

## 1.2. DISTRIBUIÇÕES DE FREQUÊNCIAS

Para o estudo do tema relacionado à distribuição de frequências para uma determinada variável, serão apresentados os conceitos referentes à forma de organização dos dados com a adequada determinação do número de classes, sua amplitude, obtenção de suas frequências absoluta e relativa, bem como as formas de representação gráfica e de análise para as variáveis de estudo.

### Tipos de Variáveis e a Determinação do Número de Classes (K)

É importante que a distribuição conte com um número adequado de classes. Se o número de classes for excessivamente pequeno, acarretará perda de detalhe e pouca informação se poderá extrair da tabela. Por outro lado, se for utilizado um número excessivo de classes, haverá alguma classe com frequência nula ou muito pequena, não atingindo o objetivo de classificação que é tornar o conjunto de dados supervisionáveis.









Enap

Enap

Enap

Enap

Enap

Enap

Enap

Enap

Enap

Enap

Enap

Enap

Enap

Enap

Enap

Enap

Enap

Enap

Enap

Enap

Enap

Enap

Enap

Enap

Enap

Enap

Enap

Enap

Enap

Enap

Enap

Enap

Enap

Enap

Enap

Enap

Enap

Enap

Enap

Enap

Enap

Convém destacar que o ponto médio do intervalo para a primeira classe corresponderá ao valor 0mm e, tendo em vista que não existe valor negativo para precipitação pluviométrica (desconsiderando-se a evapotranspiração), teremos o Quadro 02 abaixo com as classes da nossa distribuição, basta que somemos a amplitude do intervalo de classe a cada limite inferior.

**Quadro 02: Definição dos limites inferior e superior de cada uma das classes determinadas para o universo de dados analisado.**

Classe	LI	LS
1a	-24,5	24,6
2a	24,6	73,7
3a	73,7	122,8
4a	122,8	171,9
5a	171,9	221
6a	221	270,1
7a	270,1	319,2

Poderemos, então, elaborar um quadro de frequências<sup>7</sup> absolutas e relativas, conforme indicado no quadro apresentado a seguir:

**Quadro 03: Frequências absoluta ( $f_a$ ) e relativa ( $f_r$ ) para cada uma das classes.**

Classe	LI	LS	$f_a$	$f_r$
1a	-24,5	24,6	18	0,375
2a	24,6	73,7	8	0,167
3a	73,7	122,8	6	0,125
4a	122,8	171,9	11	0,229
5a	171,9	221	4	0,083
6a	221	270,1	0	0,000
7a	270,1	319,2	1	0,021
Total			48	1,000

Em relação à interpretação das informações contidas no Quadro 03, pode-se observar que os valores para precipitação ocorrida nos 48 meses avaliados estão concentrados na primeira, segunda e quarta classes, decrescendo em direção às classes do fim da tabela.

A apresentação dos dados na forma de distribuição de frequências facilita bastante o cálculo manual de várias medidas estatísticas de interesse, bem como a sua apresentação gráfica, consistindo em ferramenta à disposição do analista.

Caso o interesse do analista, além da determinação das frequências absolutas e relativas, se dirija à determinação da quantidade de observações que existe acima ou abaixo de um

7. A frequência absoluta ( $f$ ) corresponde ao número de observações que temos em uma determinada classe ou em um determinado atributo de uma variável qualitativa, e a frequência relativa ( $f_r$ ) corresponde à proporção do número de observações em uma determinada classe em relação ao total de observações que temos. Esta frequência pode ser expressa em termos percentuais. Para isto, basta multiplicar a frequência relativa obtida por 100.








Enap  
Enap  
Enap  
Enap  
Enap  
Enap  
Enap  
Enap  
Enap  
Enap  
Enap  
Enap  
Enap  
Enap  
Enap  
Enap  
Enap  
Enap  
Enap  
Enap  
Enap

b) Polígono de frequência absoluta

**Figura 4b - Exemplos de Polígono de frequência absoluta**




Gráficos para a representação de polígono de frequências acumuladas são chamados de ogivas e correspondem a um gráfico onde estas frequências são localizadas sobre perpendiculares, levantadas nos limites inferiores ou superiores das classes.

Para uma tabela de variável qualitativa, há um tipo de gráfico adequado para apresentar os resultados correspondes ao gráfico de setores, também popularmente conhecido como gráfico tipo pizza (Figura 05), com construção simples feita mediante a proporção entre o ângulo central do setor (“fatia da pizza”) e o valor para a variável representada.

**Figura 05- Composição média do tráfego para os postos de contagem na BR101-NE<sup>11</sup>.**

**Enap**



Enap  
Enap  
Enap  
Enap  
Enap  
Enap  
Enap  
Enap  
Enap  
Enap  
Enap  
Enap  
Enap  
Enap  
Enap  
Enap  
Enap  
Enap  
Enap  
Enap  
Enap

Após o estudo das formas de determinação das distribuições de frequências e gráficos que as representam, você deverá ser capaz de organizar um conjunto de dados por meio de uma distribuição de frequências (absoluta, relativa, e acumuladas), representá-las graficamente e proceder à análise das informações contidas nos mesmos.

<sup>11</sup>. Pesquisa realizada pelo Exército Brasileiro (2005), mediante parceria com o Departamento Nacional de Infraestrutura de Transportes - DNIT, em 8 (oito) postos de contagem considerados no levantamento estatístico para o projeto de duplicação da BR101-NE.



Enap  
Enap  
Enap  
Enap  
Enap  
Enap  
Enap  
Enap  
Enap  
Enap  
Enap  
Enap  
Enap  
Enap  
Enap  
Enap  
Enap  
Enap  
Enap  
Enap  
Enap

## A Utilização da Média

Sendo a Distribuição Normal uma das distribuições mais importantes e que surge com mais frequência nas aplicações (o que justifica a grande utilização da média), a média consistirá na melhor medida de localização do centro para uma série de dados. Entretanto, sendo a média uma medida bastante sensível à variabilidade dos dados, é preciso ter cuidado com a sua utilização, tendo em vista que pode propiciar uma imagem distorcida da amostra.

A média possui uma particularidade bastante interessante, que consiste no seguinte: se calcularmos os desvios de todas as observações relativamente à média e somarmos esses desvios, o resultado obtido é igual a zero.

Outra característica da média que torna a sua utilização vantajosa em certas aplicações é quando o que se pretende representar é a quantidade total expressa pelos dados, e então se utiliza a média. Na realidade, ao multiplicar a média pelo número total de elementos, obtemos a quantidade pretendida.

## Moda

Define-se moda como sendo o valor que surge com mais frequência se os dados são discretos ou, ainda, o intervalo de classe com maior frequência se os dados são contínuos.

Assim, da representação gráfica dos dados, obtém-se imediatamente o valor que representa a moda ou a classe modal. Esta medida é especialmente útil para reduzir a informação de um conjunto de dados qualitativos, apresentados sob a forma de nomes ou categorias para os quais não se pode calcular a média e por vezes a mediana.

Enap

Para dados agrupados com classes, teríamos o seguinte processo para a determinação do valor modal para uma determinada série de dados:

Enap  
Enap  
Enap  
Enap  
Enap  
Enap  
Enap  
Enap  
Enap  
Enap  
Enap  
Enap  
Enap  
Enap  
Enap  
Enap  
Enap  
Enap  
Enap  
Enap  
Enap  
Enap  
Enap

### 1º. Identificação da classe de maior frequência:

Para o exemplo apresentado no Quadro 06, teríamos a 3ª classe (158 | - 162).

### 2º passo: Cálculo da Moda:

$$Mo = (l_i + l_s) / 2 = (158 + 162) / 2 = 160$$

Sendo:

$$\begin{aligned} l_i &: \text{limite inferior da classe modal} = 158 \\ l_s &: \text{limite superior da classe modal} = 162 \end{aligned}$$



## Mediana

A mediana é uma medida de localização do centro da distribuição dos dados, definida do seguinte modo: Ordenados os elementos da amostra, a mediana é o valor (pertencente ou não à amostra) que a divide ao meio, isto é, 50% dos elementos da amostra são menores ou iguais à mediana e os outros 50% são maiores ou iguais à mediana.

Para sua determinação, utiliza-se a seguinte regra, depois de ordenada a amostra de  $n$  elementos: Se  $n$  é ímpar, a mediana é o elemento médio e, se  $n$  é par, a mediana é a semi-soma dos dois elementos médios.

Teríamos, então, para dados não agrupados, o seguinte processo:

a) Quando o número de valores observados é ímpar:

Exemplo: Considere o conjunto de dados:

$$X = (5, 2, 7, 10, 3, 4, 1)$$

1º) Coloque os valores em ordem crescente ou decrescente:

$$X = (1, 2, 3, 4, 5, 7, 10)$$

2º) Determine a ordem ou posição (P) da Mediana por  $P = (n+1)/2$ ; portanto:

$$P = (7+1) / 2 = 4^{\text{a}} \text{ posição}$$

O número que se encontra na 4ª posição consiste na mediana, portanto,  $Md = 4$

b) Quando o número de valores observados é par:

Exemplo: Considere o conjunto de dados:

$$X = (4, 3, 9, 8, 7, 2, 10, 6)$$

1º) Coloque os valores em ordem crescente ou decrescente:

$$X = (2, 3, 4, 6, 7, 8, 9, 10)$$

2º) Determine a ordem ou posição (P) para  $n/2$  e para  $n/2 + 1$

$$P = 8/2 = 4^{\text{a}} \text{ posição}$$

e

$$P = 8/2 + 1 = 5^{\text{a}} \text{ posição}$$

Enap  
Enap  
Enap  
Enap  
Enap  
Enap  
Enap  
Enap  
Enap  
Enap  
Enap  
Enap  
Enap  
Enap  
Enap  
Enap  
Enap  
Enap  
Enap

Enap

Enap  
Enap  
Enap  
Enap  
Enap  
Enap  
Enap  
Enap  
Enap  
Enap  
Enap  
Enap  
Enap  
Enap  
Enap  
Enap  
Enap  
Enap  
Enap  
Enap  
Enap

Os números são 6 (4ª posição) e 7 (5ª posição): 2, 3, 4, 6, 7, 8, 9, 10

Tira-se a média aritmética entre os dois números:

$$Md = (6+7) / 2 = 6,5$$

**Considerações a respeito de Média e Mediana**

Como medida de localização, a mediana é mais robusta do que a média, pois não é tão sensível ao valor dos dados que compõem a amostra. Dentre as observações a respeito da comparação entre média e mediana, poderíamos destacar as seguintes:

Quando a distribuição é simétrica, a média e a mediana coincidem.

A mediana não é tão sensível, como a média, às observações que são muito maiores ou muito menores do que as restantes (*outliers*). Por outro lado, a média reflete o valor de todas as observações.


Assim, a média, ao contrário da mediana, é uma medida muito influenciada por valores “muito grandes” ou “muito pequenos”, mesmo que estes valores surjam em pequeno número na amostra. Estes valores são os responsáveis pela má utilização da média em muitas situações em que teria mais significado utilizar a mediana.

Portanto, teríamos as seguintes considerações sobre a influência da forma da distribuição dos dados:

**Enap**

**Figura 05- Exemplos de distribuições simétricas.**


- Quando for aproximadamente simétrica, a média aproxima-se da mediana.



Quando se apresentar de forma enviesada para a direita (alguns valores grandes como *outliers*), a média tende a ser maior que a mediana.

**Figura 06- Exemplos de distribuições assimétricas.**

Caso a distribuição seja enviesada para a esquerda (alguns valores pequenos como *outliers*), a média tende a ser inferior à mediana.



#### 1.4. MEDIDAS DE DISPERSÃO

No item anterior foram apresentados conceitos de algumas medidas de localização do centro de uma distribuição de dados. Veremos agora como medir a variabilidade presente num conjunto de dados. As medidas de dispersão são utilizadas para medir o grau de variabilidade (dispersão) dos valores observados em torno da média aritmética. Servem para medir a representatividade da média e proporcionam conhecer o nível de homogeneidade ou heterogeneidade dentro de cada grupo analisado.

Assim, um aspecto importante no estudo descritivo de um conjunto de dados é o da determinação da variabilidade ou dispersão desses dados, relativamente à medida de localização do centro da amostra. Supondo ser a média a medida de localização mais importante, será relativamente a ela que se define a principal medida de dispersão – a variância, apresentada a seguir.

##### **Variância**

Define-se a variância como sendo a medida que se obtém somando os quadrados dos desvios das observações da amostra, relativamente à sua média, e dividindo pelo número de observações da amostra menos um.

$$\sum \frac{(x_1 - \text{média})^2}{n - 1}$$

##### **Desvio-padrão**

É a raiz quadrada da variância. Na fórmula original para o cálculo da variância, observa-se que é uma soma de quadrados, a unidade em que se exprime não é a mesma que a dos dados. Por exemplo, se a unidade original for metro (m), o resultado será metro ao quadrado (m<sup>2</sup>).

Enap  
Enap  
Enap  
Enap  
Enap  
Enap  
Enap  
Enap  
Enap  
Enap  
Enap  
Enap  
Enap  
Enap  
Enap  
Enap  
Enap  
Enap  
Enap  
Enap  
Enap  
Enap

Para retornar à unidade de medida original, extrai-se a raiz quadrada da variância, passando a chamar-se de desvio-padrão. Assim, para obter uma medida da variabilidade ou dispersão com as mesmas unidades que os dados, tomamos a raiz quadrada da variância e obtemos o desvio padrão.

$$\sqrt{\frac{\sum (x_i - \text{média})^2}{n - 1}}$$

O desvio padrão, portanto, é uma medida que só pode assumir valores não negativos e, quanto maior for, maior será a dispersão dos dados. O desvio padrão será maior, quanto mais variabilidade houver entre os dados.

### ***Coefficiente de Variação***

O coeficiente de variação (CV) consiste em uma medida relativa de dispersão, útil para a comparação em termos relativos ao grau de concentração em torno da média de séries distintas. Para uma amostra, teríamos a seguinte expressão:

$$CV = \text{Desvio Padrão} / \text{Média} \times 100 (\%)$$

Enap

Enap  
Enap  
Enap  
Enap  
Enap  
Enap  
Enap  
Enap  
Enap  
Enap  
Enap  
Enap  
Enap  
Enap  
Enap  
Enap  
Enap  
Enap  
Enap  
Enap  
Enap  
Enap



## **IMPORTANTE**

O coeficiente de variação é expresso em porcentagem, avaliado para amostras segundo a seguinte referência:

**Baixa dispersão:  $CV \leq 15\%$**

**Média dispersão:  $15\% < CV < 30\%$**

**Grande dispersão:  $CV \geq 30\%$**


### **Distribuição Normal**

A distribuição normal é a mais importante distribuição estatística, considerando a questão prática e teórica, apresentando-se em formato de sino, unimodal, simétrica em relação a sua média.

Considerando a probabilidade de ocorrência, a área sob sua curva soma 100%. Isso quer dizer que a probabilidade de uma observação assumir um valor entre dois pontos quaisquer é igual à área compreendida entre esses dois pontos.

Na figura apresentada a seguir, com as barras situadas logo abaixo do eixo das abscissas, representando os desvios-padrão, quanto mais afastado do centro da curva normal, mais área compreendida abaixo da curva haverá, ou seja, a um desvio-padrão, temos 68,26% das observações contidas, a dois desvios-padrões, possuímos 95,44% dos dados compreendidos e, finalmente, a três desvios, temos 99,73% de probabilidade de ocorrência.

**Figura 07- Relação entre o desvio-padrão e a probabilidade de ocorrência de um evento.**



$p(x)$  para  $n$  desvios-padrão 68,26% => 1 desvio

95,44% => 2 desvios

99,73% => 3 desvios

O desvio-padrão, quando analisado isoladamente, não dá margem a muitas conclusões. Por exemplo, para uma distribuição cuja média é 79,7, como é o caso do exemplo com a série de dados de precipitação pluviométrica mensal, visto no início do curso, que apresentou desvio padrão de 76,9, considerado como bastante elevado, um desvio-padrão de 5mm/mês seria pequeno, mas para uma distribuição cuja média fosse 10, este desvio-padrão já não seria tão pequeno.



## IMPORTANTE

Condições para se usar o desvio-padrão ou variância para comparar a variabilidade entre grupos:

- mesmo número de observações;
- mesma unidade;
- mesma média.

Além disso, se quisermos comparar duas ou mais amostras de valores expressos em unidades diferentes, não será possível fazer a comparação por meio do desvio-padrão, pois ele é expresso na mesma unidade dos dados.

Enap  
Enap  
Enap  
Enap  
Enap  
Enap  
Enap  
Enap  
Enap  
Enap  
Enap  
Enap  
Enap  
Enap  
Enap  
Enap  
Enap  
Enap

**Enap**

Enap  
Enap  
Enap  
Enap  
Enap  
Enap  
Enap  
Enap  
Enap  
Enap  
Enap  
Enap  
Enap  
Enap  
Enap  
Enap  
Enap  
Enap  
Enap