

Unidade 1 - ESTATÍSTICA DESCRITIVA



Objetivos da Unidade

Esta unidade tem por objetivo fazer com que você tenha condições de descrever e apresentar os resultados de um conjunto de observações de forma clara, objetiva e passando o máximo de informações possíveis.

Para tal objetivo, serão abordadas questões relacionadas a dados estatísticos, distribuições de frequências, representações gráficas, medidas de posição e dispersão.

Após concluir esta unidade, espera-se que você seja capaz de:

- Reconhecer a importância dos métodos estatísticos para o estudo de variáveis.
- Compreender os conceitos fundamentais da estatística descritiva.
- Analisar distribuições de frequências para dados estatísticos e suas formas de representação.
- Distinguir e saber aplicar as diversas medidas de posição. Calcular a média, mediana e moda para uma amostra.
- Distinguir e saber aplicar as diversas medidas de dispersão.
- Calcular a variância, o desvio-padrão e coeficiente de variação para uma amostra.

1.1. DADOS ESTATÍSTICOS

A Estatística pode ser definida como sendo “parte da matemática aplicada que fornece métodos para a coleta, organização, descrição, análise e interpretação de dados e para a utilização dos mesmos na tomada de decisões”.

A estatística, portanto, é uma ciência que se dedica à coleta, análise e interpretação de dados, preocupando-se com os métodos de coleta, organização, síntese, apresentação e interpretação dos dados, assim como em tirar conclusões sobre as características das fontes donde estes foram retirados para melhor compreender as situações analisadas.

Como podemos apreciar no portal do Instituto Brasileiro de Geografia e Estatística – IBGE (http://www.ibge.gov.br/brasil_em_sintese/), são diversos os dados considerados como de interesse para utilização nos processos de planejamento e gestão de projetos e políticas públicas, apresentando-se de forma destacada no site os dados referentes às temáticas

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>.

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.

Qualquer conjunto de dados, tais como a precipitação pluviométrica em um determinado mês, o PIB de municípios em um Estado, a ocorrência de acidentes em uma rodovia etc., contém informação sobre algum grupo de indivíduos. As possíveis diferenças entre indivíduos determinam a variação que está sempre presente na análise de dados.

Uma característica que pode assumir diferentes valores de indivíduo para indivíduo é denominada variável, pois de outra forma, seria denominada constante. As variáveis podem ser classificadas em qualitativas e quantitativas. Os dados qualitativos são divididos em nominais e ordinais, enquanto os dados quantitativos são divididos em discretas e contínuas.

Portanto, ao conjunto de distintos valores numéricos que adota um caráter quantitativo, denomina-se “variável estatística”, que pode apresentar-se conforme dois tipos:

Variáveis qualitativas ou categóricas: que não se podem medir numericamente (ex: nacionalidade, sexo, escolaridade etc).

Variáveis quantitativas: Possuem valor numérico (ex: idade, preço de um produto, renda etc).

As variáveis também podem se classificar em:

- Variáveis unidimensionais: somente transmitem informação sobre uma característica (ex: idade de alunos de uma turma).
- Variáveis bidimensionais: guardam informação sobre duas características da população (ex: idade e renda de trabalhadores de uma cidade).
- Variáveis pluridimensionais: detém informação sobre três ou mais características (ex: idade, altura e peso de alunos de uma turma).

Por sua parte, as variáveis quantitativas podem classificar-se em discretas e contínuas:

- Discretas: só podem tomar valores inteiros (ex: 1, 2, 8, -4, etc.), como é o caso do número de espécies de orquídeas em um determinado bioma.
- Contínuas: Podem tomar qualquer valor real dentro de um intervalo. Por exemplo, a velocidade de um veículo em uma rodovia, que pode ser 70,4 km/h, 94,57 km/h...

Quando se estuda o comportamento de uma variável, é necessário que se proceda à distinção dos seguintes conceitos:

- Indivíduo: qualquer elemento que porte informação sobre o fenômeno que se estuda. Assim, se estudamos à altura dos alunos em uma turma, cada aluno é um indivíduo; se o objeto de estudo é o preço de uma habitação, cada unidade de habitação é um indivíduo.
- População: conjunto de todos os indivíduos (pessoas, objetos, animais etc) que portem informação sobre o fenômeno que se estuda. Por exemplo, se estudamos o preço de habitações em uma cidade, a população será o total de habitações em dita cidade.
- Amostra: subconjunto que, selecionando uma população, por exemplo no caso do estudo do preço de habitações em uma cidade, o normal seria não obter informações sobre todas as moradias da cidade, pois seria um trabalho muito complexo, mas deveria selecionar um subgrupo (amostra) que se entenda suficientemente representativo.

Convém destacar que quando coletamos dados para uma pesquisa, estas observações são chamadas de dados brutos. Um exemplo de dados brutos corresponde à precipitação

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
Enap
Enap
Enap

pluviométrica mensal, medida em mm, consistindo em dados obtidos conforme metodologia utilizada na hidrologia, na forma que foram coletados em uma determinada estação climatológica, sendo, por este motivo, denominados de dados brutos¹.

Geralmente, este tipo de dado não possui as informações que são necessárias pelo observador para a utilização direta em um projeto, ou conclusões que o auxiliem na tomada de decisão, que somente poderá ser viabilizada após a adequada organização dos dados, visando potencializar a sua capacidade de fornecer informações úteis ao analista e minimizar o erro na tomada de decisão na avaliação de um dado problema a ser enfrentado.

A simples organização dos dados em um rol² aumenta muito a capacidade de informação destes. Será possibilitada a verificação da amplitude total³ de variação para os dados observados e também será possível a organização de rol crescente dos dados, com a identificação dos dados mais frequentes na amostra.

Para a organização de um conjunto de dados, recomenda-se a elaboração de tabela de distribuição de frequências, onde são apresentadas as frequências de cada uma das classes⁴, contando o número de observações contidas em cada uma delas, obtendo-se a frequência de classe. Denomina-se distribuição de frequências a disposição tabular dos dados agrupados em classes, associados às suas frequências correspondentes.

Para o caso, por exemplo, da precipitação pluviométrica mensal em uma determinada região, poder-se-ia incluir, em uma única classe, os meses em que a precipitação pluviométrica, para um certo período estivesse compreendida no intervalo de 100 e 200mm.

Considerando os dados de chuva referentes ao registro de observações em estação climatológica, tomado como exemplo, será possível identificar conceitos presentes em uma distribuição de frequências. Para a elaboração da distribuição de frequências, é necessário que, primeiramente, se determine o número de classes (k) em que os dados serão agrupados.

Por questões de ordem prática e estética, sugere-se utilizar de 5 a 20 classes, e uma recomendação de ordem prática que poderá ser seguida é a definição do número de classes (k) em função do número de observações (n), segundo a expressão $k = \sqrt{n}$.

Quadro 01: Precipitação pluviométrica média mensal para um período de 4 anos.

Mês/Ano	P (mm)	Mês/Ano	P (mm)	Mês/Ano	P (mm)	Mês/Ano	P (mm)
jan/08	70,9	jan/09	103,3	jan/10	25,5	jan/11	139,8
fev/08	0,9	fev/09	154,2	fev/10	21,7	fev/11	75,9
mar/08	154,4	mar/09	131,8	mar/10	15,3	mar/11	89,5
abr/08	219,6	abr/09	145,6	abr/10	94,3	abr/11	169,1
mai/08	111,3	mai/09	160,6	mai/10	69,7	mai/11	168,9
jun/08	294,5	jun/09	190,6	jun/10	62,7	jun/11	194,1
jul/08	146,1	jul/09	139,5	jul/10	22,8	jul/11	122,8
ago/08	204,8	ago/09	146,7	ago/10	9,9	ago/11	33,8
set/08	25,0	set/09	26,5	set/10	0,0	set/11	2,3
out/08	23,6	set/09	0,2	set/10	0,3	set/11	5,3

1. Dados na forma em que foram coletados, sem nenhum tratamento
2. É a mais simples organização numérica. É a ordenação dos dados em ordem crescente ou decrescente
3. Corresponde à diferença entre o maior e o menor valor observado em um conjunto de dados. Notaremos por A
4. Intervalos nos quais os valores da variável analisada são agrupados.

nov/08	3,5	nov/09	2,0	nov/10	34,7	nov/11	2,7
dez/08	1,8	dez/09	2,6	dez/10	2,6	dez/11	2,6
Obs. P correspondendo a precipitações totais mensais, em mm.							

Para $n = 48$ observações, teremos, então, o número de classes definido por $k = \sqrt{48} = 6,9$, o que implicaria na definição de 7 classes.

Convém destacar que a definição do número de classes, poderá, inclusive, ser realizada conforme critérios fixados pelo próprio analista, respeitando-se o princípio de evitar classes excessivamente ou fracamente populosas.

Em seguida à determinação do número de classes (k) para o agrupamento dos dados, se procederá à determinação da amplitude⁵ do intervalo de classe (c), sendo necessária⁶, antes, a determinação da amplitude total dos dados (A), que corresponde à diferença entre o maior valor observado e o menor valor observado. Para o cálculo da amplitude total dos dados (A) para o exemplo considerado, que corresponde à diferença entre o maior valor observado e o menor valor observado, teríamos:

$$A = 294,5 - 0 = 294,5 \text{ mm}$$

Para a amplitude do intervalo de classe (c), considerando o valor da amplitude total (A) calculado, teremos:

$$C = 294,5 / (7 - 1) = 49,1 \text{ mm}$$

O próximo passo, após conhecida a amplitude de classes, será a determinação dos intervalos de classe, mediante a definição dos limites inferior (LI) e superior (LS) das classes, escolhidos de modo que o menor valor observado esteja localizado no ponto médio (PM) da primeira classe, ou seja:

$$PM = (LI + LS) / 2$$

Para o valor do limite inferior para um intervalo, teríamos:

$$\text{Limite Inferior} = \text{Menor Valor} - c / 2$$

Como exemplo de cálculo, o limite Inferior da 1ª Classe será dado por:

$$LI = 0 - 49,1/2 = - 24,5 \text{ mm}$$

5. Intervalos abertos – os limites da classe (inferior e superior) não pertencem a ela. Intervalos fechados – os limites de classe (superior e inferior) pertencem à classe em questão. Intervalos mistos – um dos limites pertence à classe, e o outro, não.

6. Existem outros procedimentos para determinação da amplitude do intervalo de classe que podem ser encontrados na literatura.

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

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 frequências⁷ 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

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 correspondentes 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-NE¹¹.

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.

11. 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.

1.3. MEDIDAS DE POSIÇÃO

As medidas de posição ou de tendência central constituem uma forma mais sintética de apresentar os resultados contidos nos dados observados, pois representam um valor central em torno do qual os dados se concentram. As medidas de tendência central mais empregadas são: média (aritmética, ponderada e geométrica), mediana e moda. Quando se estuda variabilidade, as medidas mais importantes são: amplitude, desvio padrão e variância.

No Quadro 07 mostrado abaixo, são apresentadas as expressões aritméticas para o cálculo das principais medidas de posição:

Quadro 07: Expressões para as principais medidas de tendência central.

<i>Medidas</i>	<i>Expressão</i>
Média aritmética	$\frac{x_1 + \dots + x_n}{n}$
Média aritmética para dados agrupados	$\frac{f_1 \cdot X_1 + \dots + f_i \cdot X_i}{f_1 + \dots + f_i}$
Média aritmética ponderada	$\frac{P_1 \cdot (X_1) + P_2 \cdot (X_2)}{P_{total}}$
Mediana	1) Se n é ímpar, o valor é central da série. 2) se n é par, o valor é a média dos dois valores centrais.
Moda	Valor que ocorre com mais frequência.
Média geométrica	$G = \sqrt[n]{x_1 \cdot x}$

Enap
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

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:

l_i : limite inferior da classe modal = 158
 l_s : limite superior da classe modal = 162

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
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:

$$\text{Md} = (6+7) / 2 = 6,5$$

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.

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

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.

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

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

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 (m²).

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:

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



IMPORTANTE

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

Baixa dispersão: CV ≤ 15%

Média dispersão: 15% < CV < 30%

Grande dispersão: CV ≥ 30%



OBJETIVOS DA UNIDADE

Após concluir esta unidade, espera-se que você seja capaz de:

- Reconhecer a importância do estudo das probabilidades e das técnicas de amostragem na avaliação de projetos.
- Conhecer e saber aplicar os conceitos fundamentais de probabilidade e amostragem.
- Calcular a probabilidade de ocorrência de um evento.
- Associar o estudo da probabilidade à atividade de análise de risco em projetos.
- Distinguir técnicas de amostragem e identificar vantagens de determinada técnica em relação às demais.

Enap

2.1. INTRODUÇÃO AO ESTUDO DAS PROBABILIDADES

Estudaremos agora a probabilidade, que é uma ferramenta usada e necessária para se fazer correlações entre a amostra e a população, de modo que a partir de informações da amostra se possam fazer afirmações sobre características da população, entendendo-se a probabilidade como ferramenta básica da inferência estatística.

Interessante observar que utilizamos, no nosso cotidiano, o conceito de probabilidade em situações como:

- É pouco provável que amanhã chova. O risco do projeto é elevado.
- Provavelmente fulano não conseguirá se eleger.
- Diminuiu a chance do paciente se recuperar.

São fenômenos ou eventos com resultados não completamente conhecidos a priori. Mesmo que a chance da ocorrência seja alta, os resultados não são conhecidos antes de ocorrer mas, de certa forma, mantém certa regularidade, o que permite determinar a chance de ocorrência: a Probabilidade.

A probabilidade é um número entre zero e um, inclusive, o que significa que, no mínimo, não há nenhuma hipótese do evento acontecer e, no máximo, o evento sempre ocorrerá:

$$0 \leq P(E) \leq 1$$

Normalmente representamos probabilidades através de frações, mas também podemos representá-las por números decimais ou por porcentagens.

Por exemplo, em um projeto de embarcações, a estimativa da altura da onda de projeto é feita, geralmente, considerando-se 0,75 a probabilidade do navio encontrar ondas maiores que sua onda de projeto. A probabilidade acumulada é a de ocorrência de todas as alturas menores que a determinada.

Neste exemplo, mediante interpolação linear, pode-se obter a altura de onda correspondente à probabilidade de 75%. Portanto, para a probabilidade acumulada da ocorrência correspondente à altura de onda de projeto, ter-se-ia o valor da altura de onda a ser utilizado no dimensionamento da estrutura naval em questão, como mostra a tabela a seguir:

Tabela 1 – Dimensionamento da estrutura naval


Altura de Onda			
Hs(m)	Total	Probabilidade Relativa	Probabilidade Acumulada
1,0	26287	0,263	0,263
2,0	34001	0,340	0,603
3,0	20092	0,201	0,804
4,0	10482	0,105	0,909
5,0	5073	0,051	0,959
6,0	2323	0,023	0,983
7,0	1018	0,010	0,993
8,0	432	0,004	0,997
9,0	178	0,002	0,999
10,0	70	0,001	1,000
11,0	28	0,000	1,000
12,0	11	0,000	1,000
13,0	4	0,000	1,000
14,0	1	0,000	1,000
Total	100000		
Probabilidade de Ocorrência			
% Ocorrência		Altura de Onda(m)	
75,0%	0,750	2,73	(valor interpolado)
60,3%	0,603	2,00	
80,4%	0,804	3,00	

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
Enap
Enap
Enap
Enap

Figura 08- Procedimento para a determinação da altura de onda de projeto14.



Fonte: Exercício contido no site <www.oceanica.ufrj.br > [consulta em 10/04/2012].

2.2. CONCEITOS FUNDAMENTAIS: EXPERIMENTOS, ESPAÇO AMOSTRAL E TIPOS DE EVENTOS¹²

Enap

O estudo da probabilidade resulta na necessidade de, em certas situações, prevermos a possibilidade de ocorrência de determinados fatos. Ao começarmos o estudo da probabilidade, normalmente a primeira ideia que nos vem à mente é a da sua utilização em jogos, mas podemos utilizá-lo em muitas outras áreas. Um bom exemplo é na área da avaliação do risco de projetos, bem como na utilização de métodos de análise de sensibilidade em processos de tomada de decisão na seleção de projetos. Para iniciarmos o estudo da probabilidade, vamos a seguir definir alguns conceitos importantes sobre a matéria, fazendo uso de exemplos clássicos para a compreensão dos fundamentos do cálculo de probabilidades.

Experimento Aleatório

Se lançarmos uma moeda ao chão para observarmos a face que ficou para cima, o resultado é imprevisível, pois tanto pode dar cara quanto coroa. Se, ao invés de uma moeda, o objeto a ser lançado for um dado, o resultado será mais imprevisível ainda, pois aumentamos o número de possibilidades de resultado. Experimentos como estes, ocorrendo nas mesmas condições ou em condições semelhantes, que podem apresentar resultados diferentes a cada ocorrência, damos o nome de experimentos aleatórios.

Espaço Amostral

Ao lançarmos uma moeda, não sabemos qual será a face que ficará para cima, no entanto, podemos afirmar com toda certeza que, ou será cara, ou será coroa, pois uma moeda só possui estas duas faces.

12. Conteúdo sobre noções de probabilidade adaptado do material instrucional contido no sítio <http://www.matematicadidatica.com.br/ProbabilidadeConceitos.aspx> [consulta em 13/04/2012].

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
Enap
Enap
Enap
Enap
Enap
Enap
Enap

Evento Certo: Ao lançarmos um dado, é certo que a face que ficará para cima, terá um número divisor de 720. Este é um evento certo, pois $720 = 6! = 6 \cdot 5 \cdot 4 \cdot 3 \cdot 2 \cdot 1$, obviamente qualquer um dos números da face de um dado é um divisor de 720, pois 720 é o produto de todos eles. O conjunto $A = \{2, 3, 5, 6, 4, 1\}$ representa um evento certo, pois ele possui todos os elementos do espaço amostral $S = \{1, 2, 3, 4, 5, 6\}$.

Evento Impossível: No lançamento do conjunto de dois dados, qual é a possibilidade de a soma dos números contidos nas duas faces para cima, ser igual a 15? Este é um evento impossível, pois o valor máximo que podemos obter é igual a doze. Podemos representá-lo por $A = \{\}\{?$, ou ainda por $A = \{??\}$.

Evento União: Seja $A = \{1, 3\}$, o evento de ocorrência da face superior no lançamento de um dado, ímpar e menor ou igual a 3 e $B = \{3, 5\}$, será o evento de ocorrência da face superior, ímpar e maior ou igual a 3, então teremos $C = \{1, 3, 5\}$, que representa o evento de ocorrência da face superior ímpar, que é a união dos conjuntos A e B, ou seja, $C = A \cup B$. Note que o evento C contém todos os elementos de A e B.

Evento Intersecção: Seja $A = \{2, 4\}$, o evento de ocorrência da face superior no lançamento de um dado, par e menor ou igual a 4 e $B = \{4, 6\}$, será o evento de ocorrência da face superior, par e maior ou igual a 4, então teremos $C = \{4\}$, que representa o evento de ocorrência da face superior par, que é a intersecção dos conjuntos A e B, ou seja,

Veja que o evento C contém apenas os elementos comuns a A e B.

Eventos Mutuamente Exclusivos: Seja $A = \{1, 2, 3, 6\}$ o evento de ocorrência da face superior no lançamento de um dado, um número divisor de 6 e $B = \{5\}$, o evento de ocorrência da face superior, um divisor de 5, os eventos A e B são mutuamente exclusivos, pois $A \cap B = \emptyset$, isto é, os eventos não possuem elementos em comum.

Evento Complementar: Seja $A = \{1, 3, 5\}$ o evento de ocorrência da face superior no lançamento de um dado, um número ímpar, o seu evento complementar é $A = \{2, 4, 6\}$ o evento de ocorrência da face superior no lançamento de um dado, um número par. Os elementos de A são todos os elementos do espaço amostral S que não estão contidos em A, então temos que $A = S - A$ e ainda que $S = A + A$.

2.3. PROBABILIDADE DE OCORRÊNCIA DE UM EVENTO

Passaremos a apresentar considerações sobre os fundamentos para o estudo da probabilidade de ocorrência de um determinado evento.



IMPORTANTE

O ponto central em todas as situações onde usamos probabilidade é a possibilidade de quantificar quão provável é determinado EVENTO. As probabilidades são utilizadas para exprimir a chance de ocorrência de determinado evento .

Experimentos aleatórios, espaço, amostral e evento

Encontramos na natureza dois tipos de fenômenos: determinísticos e aleatórios. Os fenômenos determinísticos são aqueles em que os resultados são sempre os mesmos, qualquer que seja o número de ocorrência dos mesmos.

Se considerarmos o fenômeno, por exemplo, da flutuação de objeto imerso na água, sabemos que caso o objeto possui peso específico menor que a água, ele flutuará. Esse exemplo caracteriza um fenômeno determinístico. Nos fenômenos aleatórios, os resultados não serão previsíveis, mesmo que haja várias repetições do mesmo fenômeno.

Podemos considerar, como experimentos aleatórios, os seguintes exemplos de fenômenos produzidos pelo homem:

- lançamento de uma moeda;
- lançamento de um dado;
- determinação da vida útil de um componente eletrônico;
- previsão do tempo.

A cada experimento aleatório está associado o resultado do mesmo, que não é previsível, chamado de evento aleatório.

Um conjunto “*S*” que consiste de todos os resultados possíveis de um experimento aleatório é denominado espaço amostral.

Definição de Probabilidade

A probabilidade de um evento *A*, denotada por $P(A)$, é um número de 0 a 1 que indica a chance de ocorrência do evento *A*. Quanto mais próxima de 1 é $P(A)$, maior é a chance de ocorrência do evento *A*, e quanto mais próxima de zero, menor é a chance de ocorrência do evento *A*. A um evento impossível, atribui-se probabilidade zero, enquanto que um evento certo tem probabilidade 1,0.

As probabilidades podem ser expressas de diversas maneiras, inclusive decimais, frações e porcentagens. Por exemplo, a chance de ocorrência de um determinado evento pode ser expressa como 20%; 2 em 10; 0,20 ou 1/5.

Assim, sendo *E* é um evento, $n(E)$ é o seu número de elementos, *S* é o espaço amostral não vazio e $n(S)$ é a quantidade de elementos do mesmo, e assim temos que a probabilidade de *E* ocorrer é igual a:

$$P(E) = n(E) / n(S), \text{ para } n(S) \neq 0$$

Recorreremos ao exemplo clássico do lançamento de um dado para a utilização da equação para o cálculo de probabilidades: Qual é a probabilidade de obtermos um número divisor de 6 no lançamento de um dado?

Como vimos acima, o espaço amostral do lançamento de um dado é:

$$S = \{1, 2, 3, 4, 5, 6\}$$

Enap

Podemos calcular a probabilidade de ocorrer A, tendo ocorrido B através da fórmula:

$$P\left(\frac{A}{B}\right) = \frac{n(A \cap B)}{n(B)}$$

Segundo o enunciado

$$n(A \cap B) = 200 \quad \text{e} \quad n(B) = 500$$

Portanto:

$$P(A/B) = 200 / 500 = 2/5$$



IMPORTANTE


Note que, no caso da probabilidade condicional, ao invés de calcularmos a probabilidade em função do número de elementos do espaço amostral, a calculamos em função do número de elementos do evento que já ocorreu. Portanto, a probabilidade de o pedreiro também possuir mais de dez anos de experiência profissional é de 40%.

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

Enap

Probabilidade no Caso da União de Eventos

Considere A e B como dois eventos de um espaço amostral S, finito e não vazio. Temos:




$$\begin{aligned} n(A \cup B) &= n(A) + n(B) - n(A \cap B) \iff \\ \Rightarrow \frac{n(A \cup B)}{n(S)} &= \frac{n(A)}{n(S)} + \frac{n(B)}{n(S)} - \frac{n(A \cap B)}{n(S)} \end{aligned}$$

Logo:

$$P(A \cup B) = P(A) + P(B)$$

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

Probabilidade no Caso de Eventos Mutuamente Exclusivos



Considerando que $A \cap B = \emptyset$, nesse caso A e B serão denominados mutuamente exclusivos. Observe que $P(A \cap B) = 0$, pois:

Caso da Probabilidade Condicionada

Considere dois eventos A e B de um espaço amostral S, finito e não vazio. A probabilidade de B condicionada a A é dada pela probabilidade de ocorrência de B, sabendo que já ocorreu A. É representada por $P(B/A)$.

Situação da Intersecção de Eventos

Considerando A e B como dois eventos de um espaço amostral S, finito e não vazio, temos:

$$P(B/A) = \frac{n(A \cap B)}{n(A)} = \frac{n(A \cap B) \div n(S)}{n(A) \div n(S)} = \frac{P(A \cap B)}{P(A)}$$

$$P(A/B) = \frac{n(A \cap B)}{n(B)} = \frac{n(A \cap B) \div n(S)}{n(B) \div n(S)} = \frac{P(A \cap B)}{P(B)}$$

Portanto:

$$P(A \cap B) = P(A) \cdot P(B/A)$$

$$P(A \cap B) = P(B) \cdot P(A/B)$$

Considerando A e B como eventos independentes, logo $P(B/A) = P(B)$, $P(A/B) = P(A)$, sendo assim:

$$P(A \cap B) = P(A) \cdot P(B)$$

Para saber se os eventos A e B são independentes, podemos utilizar a definição ou calcular a probabilidade de $A \cap B$.

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

Condições definidas para escalas de impacto de um risco em objetivos importantes do projeto (os exemplos são mostrados somente para impactos negativos)					
Objetivo do projeto	São mostradas escalas relativas ou numéricas				
	Muito baixo / 0,05	Baixo / 0,10	Moderado / 0,20	Alto / 0,40	Muito alto / 0,80
Custo	Aumento de custo não significativo	Aumento de custo < 10%	Aumento de custo de 10% a 20%	Aumento de custo de 20% a 40%	Aumento de custo > 40%
Tempo	Aumento de tempo não significativo	Aumento de tempo < 5%	Aumento de tempo de 5% a 10%	Aumento de tempo de 10% a 20%	Aumento de tempo > 20%
Escopo	Diminuição do escopo quase imperceptível	Áreas menos importantes do escopo afetadas	Áreas importantes do escopo afetadas	Redução do escopo inaceitável para o patrocinador	Item final do projeto sem nenhuma utilidade
Qualidade	Degradação da qualidade quase imperceptível	Somente as aplicações mais críticas são afetadas	Redução da qualidade exige a aprovação do patrocinador	Redução da qualidade inaceitável para o patrocinador	Item final do projeto sem nenhuma utilidade

Figura 03- Exemplo de condições para definição de escalas de risco em projeto18.

Fonte: Sítio < }<http://danielettinger.files.wordpress.com/2011/06/> [consulta em 01/05/2012]

As definições dos níveis de probabilidade e impacto podem ser adaptadas a cada projeto de acordo com o ambiente organizacional. Tabelas semelhantes podem ser definidas para os riscos positivos do projeto.

Diante dos riscos a que qualquer projeto encontra-se exposto, torna-se necessário encontrar uma ferramenta que possibilite priorizá-los de forma, no mínimo, aceitável.

É nesse cenário que surge a matriz de probabilidade e impacto. Elas especificam as combinações de probabilidade e impacto que resultam em uma classificação dos riscos como de prioridade BAIXA, MODERADA ou ALTA, conforme poderemos observar na tabela apresentada a seguir:

Tabela xx- Exemplo de definição de matriz de probabilidade e impacto em projetos.

Prob.	Ameaças					Oportunidades				
0.90	0.05	0.09	0.18	0.36	0.72	0.72	0.36	0.18	0.09	0.05
0.70	0.04	0.07	0.14	0.28	0.56	0.56	0.28	0.14	0.07	0.04
0.50	0.03	0.05	0.10	0.20	0.40	0.40	0.20	0.10	0.05	0.03
0.30	0.02	0.03	0.06	0.12	0.24	0.24	0.12	0.06	0.03	0.02
0.10	0.01	0.01	0.02	0.04	0.08	0.08	0.04	0.02	0.01	0.01
	0.05	0.10	0.20	0.40	0.80	0.80	0.40	0.20	0.10	0.05

Assim, as células em cinza escuro, com maiores valores, representam alto risco, enquanto que as preenchidas com cinza médio são riscos baixos. As células em tonalidade cinza claro representam riscos moderados. Por exemplo, um risco negativo com probabilidade de ocorrência estimada em 0,70 e impacto de 0,10 representa uma ameaça de valor 0,07, o que é considerada como MODERADA.

de valor sobre a representatividade da população. Um exemplo deste tipo de amostragem corresponde à situação em que se deseja saber a aceitação em relação a uma nova marca de automóvel de passeio a ser inserida no mercado de uma cidade. Somente entrarão para compor a amostra pessoas que façam uso do automóvel e que tenham condições financeiras de comprar esta nova marca (público-alvo).

O entrevistador dirige-se a um grupo em específico para saber sua opinião. Por exemplo, quando de um estudo sobre automóveis, o pesquisador procura apenas oficinas.

Quotas ou proporcional

Neste tipo de amostragem é procedida a divisão da população em grupos, selecionando-se uma cota proporcional ao tamanho de cada grupo. Entretanto, dentro de cada grupo não é feito sorteio, sendo procurados os elementos até que a cota de cada grupo seja alcançada.

Em pesquisas eleitorais, a divisão de uma população em grupos (considerando, por exemplo, o sexo, o nível de escolaridade, a faixa etária e a renda) pode servir de base para a definição dos grupos, partindo da suposição de que estas variáveis definem grupos com comportamentos diferenciados no processo eleitoral. Para se ter uma ideia do tamanho destes grupos, pode-se recorrer a pesquisas feitas anteriormente pelo IBGE (Instituto Brasileiro de Geografia e Estatística).

Na realidade, trata-se de uma variação da amostragem intencional. Necessita-se ter um prévio conhecimento da população e sua proporcionalidade. Por exemplo, deseja-se entrevistar apenas indivíduos da classe A, que representam 12% da população. Esta será a quota para o trabalho. Comumente também substratifica-se uma quota obedecendo a uma segunda proporcionalidade.

Desproporcional

Muito utilizada quando a escolha da amostra for desproporcional à população. Atribuem-se pesos para os dados, e assim obtêm-se resultados ponderados representativos para o estudo.

Probabilística

Para que se possam realizar inferências sobre a população, é necessário que se trabalhe com amostragem probabilística. É o método que garante segurança quando se investiga alguma hipótese. Normalmente os indivíduos investigados possuem a mesma probabilidade de ser selecionado na amostra.

Aleatória Simples

Você deve utilizar a amostragem aleatória simples somente quando a população for homogênea em relação à variável que se deseja estudar. Geralmente, atribuímos uma numeração a cada indivíduo da população, e através de um sorteio aleatório, os elementos que vão compor a amostra são selecionados.

Todos os elementos da população têm a mesma probabilidade de pertencer à amostra. Imagine que você queira amostrar um número de pessoas que estão fazendo um determinado concurso com n inscritos. Como a população é finita, devemos enumerar cada um dos n candidatos e sortear n deles. É o mais utilizado processo de amostragem. Prático e eficaz, confere precisão ao processo de amostragem. Normalmente utiliza-se uma tabela de números

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

aleatórios e nomeiam-se os indivíduos, sorteando-se um por um até completar a amostra calculada. Uma variação deste tipo de amostragem é a sistemática. Em um grande número de exemplos, o pesquisador depara-se com a população ordenada. Neste sentido, tem-se os indivíduos dispostos em sequência, o que dificulta a aplicação exata desta técnica. Amostragem Sistemática

Porém, é de fundamental importância que a variável de interesse não apresente ciclos de variação coincidente com os ciclos de retirada, pois este fato tornará a amostragem não aleatória.

A técnica de amostragem caracterizada pela coleta na população de elementos que vão compor a amostra, de forma cíclica (em períodos), se chama amostragem sistemática, interessante de ser utilizada quando convém obter a amostra, por exemplo, quando os elementos da população apresentam-se ordenados.

Uma situação típica é quando se necessita retirar uma amostra de população onde a variável tempo condiciona características presentes nos elementos estudados, como é o caso da análise da evolução dos índices de preços para a consideração do efeito da inflação, durante certo período, sobre uma série de pagamentos.

Quanto ao procedimento, o primeiro passo será o cálculo da constante (**K**), que atuará como fator de ciclo para a definição do momento e período a considerar para a realização da amostragem o que possibilitará, em um segundo momento, a definição do intervalo de tempo para a coleta da amostra.

Após a definição do valor de **K**, é definido o ponto inicial da amostragem, ou seja, um dos elementos do primeiro intervalo é constituído pelos elementos populacionais numerados de 1 até n . Escolhe-se o seguinte, que será o elemento de ordem $(i + K)$; , sempre somando-se K à ordem do elemento anterior, até completar a escolha dos n elementos que vão compor a amostra.

Amostragem Aleatória Estratificada

Quando se deseja guardar uma proporcionalidade na população heterogênea e a variável de interesse apresenta uma heterogeneidade na população, permitindo a identificação de grupos homogêneos, poderá a população ser dividida em grupos (estratos) e proceder-se à amostragem dentro de cada estrato, garantindo, assim, a representatividade de cada estrato na amostra. A estratificação em cada subpopulação poderá ser realizada mediante critérios como classe social, renda, idade, sexo, entre outros.

Conforme comenta Tavares (2007), podemos verificar que pesquisas eleitorais apresentam uma grande heterogeneidade em relação à intenção de votos, quando consideramos, por exemplo, a faixa salarial ou o nível de escolaridade.

Então, se fizéssemos uma amostragem aleatória simples, poderíamos incluir na amostra uma maior quantidade de elementos de um grupo, e, proporcionalmente, este grupo será pequeno em relação à população. Desta forma, não teríamos uma amostra representativa da população a ser estudada. Então, podemos dividir a população em grupos (estratos) que são homogêneos para a característica que estamos avaliando, ou seja, neste caso, a intenção de votos.

Destaca-se que, como estamos dividindo a população em estratos (grupos) que são homogêneos dentro de si, podemos, então, caracterizar a amostragem estratificada. Para

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

ainda que este tipo de amostragem é muito útil quando a população é grande, por exemplo, no caso de uma pesquisa em nível nacional. Para efetuarmos a amostragem por conglomerados, primeiramente os definimos e depois dividimos a população nos conglomerados, procedendo-se ao sorteio destes por meio de um processo aleatório onde são avaliados todos os indivíduos presentes em um estágio.



IMPORTANTE

Conglomerados são definidos geralmente segundo fatores geográficos. A Pesquisa Nacional por Amostra de Domicílios (PNAD) do IBGE, por exemplo, é feita por conglomerados, em três estágios.

2.6. DIMENSIONAMENTO DA AMOSTRA

Efetivamente, um dos temas mais importantes em uma análise estatística trata da determinação de qual o melhor tamanho de amostras que devemos ter, sabendo-se que amostras grandes são dispendiosas e demandam mais tempo de manipulação e estudo, bem como amostras pequenas são menos precisas e pouco confiáveis. Quando se deseja dimensionar o tamanho da amostra, o procedimento desenvolve-se em três etapas distintas:

- Avaliar a variável mais importante do grupo e a mais significativa.
- Analisar se é ordinal, intervalar ou nominal.
- Verificar se a população é finita ou infinita.

Enap

Abaixo podemos observar diversas expressões propostas para a determinação do tamanho da amostra:

Variável intervalar e população infinita

$$n = \left(\frac{Z \cdot \sigma}{d} \right)^2$$

Variável intervalar e população finita

$$n = \frac{Z^2 \cdot \sigma^2 \cdot N}{d^2(N-1) + Z^2 \cdot \sigma^2}$$

Variável nominal ou ordinal e população infinita

$$n = \left(\frac{Z^2 \cdot pq}{d^2} \right)$$

Variável nominal ou ordinal e população finita

$$n = \frac{Z^2 \cdot p \cdot q \cdot N}{d^2(N-1) + Z^2 \cdot p \cdot q}$$

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

Observa-se que a variável **d** corresponde ao erro admissível, sendo **Z** função do nível de confiança a ser considerado. Para os casos de populações consideradas como finitas, a variável **N** corresponde ao tamanho da população. A proporção (**p**) será a estimativa da verdadeira proporção de um dos níveis escolhidos para a variável adotada. Por exemplo, 55% dos integrantes da população é do sexo feminino, então **p** será 0,55. A proporção (**q**) será sempre $1 - p$. Neste exemplo **q**, será 0,45. O erro é representado por **d**. Para casos em que não se tenha como identificar as proporções confere-se 0,5 para **p** e **q**.

Como exemplo, realizaremos o cálculo do tamanho de amostra para o caso de população considerada como infinita, recorrendo-se à equação correspondente a variável intervalar. Observa-se que o tamanho da amostra depende do grau de confiança desejado, da margem de erro pretendida e do desvio padrão (σ).

Vamos ao exemplo:

Queremos estimar a renda média no primeiro ano de um egresso de escola técnica profissional. Para um nível de confiança de 95% [$\alpha = 0,05 \rightarrow Z = 1,96$; conforme relação $Z = f(\alpha)$], quantas amostras deveremos ter para que a média esteja a menos que R\$250,00 da renda média verdadeira da população. Suponha σ conhecido e igual a R\$800,00?

$$n = [Z \cdot \sigma / d]^2 = [1,96 \cdot 800 / 250]^2 = 39,34 \Rightarrow 40 \text{ amostras}$$

Caso fosse admissível uma margem de erro de R\$500, teríamos:

$$n = [Z \cdot \sigma / d]^2 = [1,96 \cdot 800 / 500]^2 = 9,83 \Rightarrow 10 \text{ amostras}$$

Ou seja, caso o erro admissível fosse o dobro, o tamanho da amostra poderia ser reduzido à quarta parte.

Enap



IMPORTANTE

A utilização de uma amostra probabilística é melhor para garantir a representatividade da amostra, pois o acaso será o único responsável por eventuais discrepâncias entre população e amostra.

Estas discrepâncias são levadas em consideração nas inferências estatísticas.

REFERÊNCIAS

UNIDADE 1

BARBETTA, P. A. **Estatística Aplicada às Ciências Sociais**. 4 ed. Florianópolis: Ed. da UFSC, 2002.

BRAULE, Ricardo. **Estatística Aplicada com Excel: para cursos de Administração e Economia**. Rio de Janeiro: Campus, 2001.

BUSSAB, W. O.; MORETTIN, P. **Estatística Básica**. São Paulo: Atual, 2002.

COSTA NETO, P. L. de O. **Estatística**. São Paulo: Edgard Blücher, 2002.

DOWNING, D.; CLARK, J. **Estatística Aplicada**. São Paulo: Saraiva, 2000.

FONSECA, Jairo Simon da; MARTINS, Gilberto de Andrade. **Curso de Estatística**. Rio de Janeiro: LTC, 1982.

FREUD, J. E.; SIMON, G. A. **Estatística Aplicada**. Bookman, 2000, 403 p.

LEVINE, D. M.; BERENSON, M. L.; STEPHAN, D. **Estatística: teoria e aplicações (usando o Microsoft Excel em português)**. LTC, 2000, 812 p.

MORETTIN, L. G. **Estatística Básica: Probabilidade**. V. 1. São Paulo: Makron Books, 1999.

SOARES, J. F.; FARIAS, A. A.; CESAR, C. C. **Introdução à Estatística**. Rio de Janeiro: LTC, 1991.

SPIEGEL, M. **Probabilidade e Estatística**. Mc Graw Hill. 1993.

TAVARES, M. **Estatística Aplicada à Administração. Secretaria de Educação à Distância do Ministério da Educação Sistema Universidade Aberta do Brasil – UAB**. Diretoria do Departamento de Políticas em Educação a Distância – DPEAD. Brasília: MEC, 2007.

TRIOLA, M. F. **Introdução à Estatística**. Rio de Janeiro: LTC, 1999.

WONNACOTT, T. H., WONNACOTT, R. J. **Estatística Aplicada à Economia e à Administração**. Rio de Janeiro: LTC, 1981.

UNIDADE 2

BARBETTA, P. A. **Estatística Aplicada às Ciências Sociais**. 4 ed. Florianópolis: Ed. da UFSC, 2002.

BRAULE, Ricardo. **Estatística Aplicada com Excel: para cursos de Administração e Economia**. Rio de Janeiro: Campus, 2001.

BUSSAB, W. O.; MORETTIN, P. **Estatística Básica**. São Paulo: Atual, 2002.

COSTA NETO, P. L. de O. **Estatística**. São Paulo: Edgard Blücher, 2002.

DOWNING, D.; CLARK, J. **Estatística Aplicada**. São Paulo: Saraiva, 2000.

FONSECA, Jairo Simon da; MARTINS, Gilberto de Andrade. **Curso de Estatística**. Rio de Janeiro: LTC, 1982.

FREUD, J. E.; SIMON, G. A. **Estatística Aplicada**. Bookman, 2000, 403 p.

LEVINE, D. M.; BERENSON, M. L.; STEPHAN, D. **Estatística: teoria e aplicações (usando o Microsoft Excel em português)**. LTC, 2000, 812 p.

MORETTIN, L. G. **Estatística Básica: Probabilidade**. V. 1. São Paulo: Makron Books, 1999.

