

Imprima uma cópia do arquivo de dados. Quantas observações (linhas) existem no arquivo de dados?

(b) Dê um exemplo de uma pergunta que poderia ser feita usando esses dados com (i) a estatística descritiva, (ii) a estatística inferencial.

**1.12** Usando um programa com planilha (como o Microsoft Office Excel) ou um software estatístico, seu professor irá ajudar a turma a criar um arquivo de dados com os valores para os membros da turma de características como as do exercício anterior. Um exercício em cada capítulo irá usar este arquivo de dados.

(a) Copie o arquivo de dados no seu computador e imprima uma cópia.

(b) Dê um exemplo de uma pergunta que você poderia fazer analisando esses dados com (i) a estatística descritiva, (ii) a estatística inferencial.

**1.13** Para o software estatístico que o seu professor escolheu para o seu curso, descubra como acessar o software, entre com os dados e imprima todos os arquivos de dados que você criar. Crie um arquivo de dados usando os dados da Figura 1.1 na Seção 1.3 e o imprima.

**1.14** Ilustrando com um exemplo, explique a diferença entre:

- (a) uma estatística e um parâmetro.  
 (b) uma descrição e uma inferência como as duas propostas para usar os métodos estatísticos.

**1.15** Você tem dados de uma população obtidos a partir de um censo. Explique por que a estatística descritiva é útil e a estatística inferencial é desnecessária.

**1.16** Uma socióloga quer estimar a idade média no casamento para mulheres de New England no início do século XVIII. Ela descobre no seu estado arquivos com registros de casamentos de um grande vilarejo puritano para os anos de 1700-1730. Então, ela coleta uma amostra desses registros, anotando a idade da

noiva para cada registro. A idade média da amostra é de 24,1 anos. Usando um método estatístico do Capítulo 5, a socióloga estima que a idade média das noivas no casamento para a população esteja entre 23,5 e 24,7 anos.

- (a) Que parte deste exemplo é estatística descritiva?  
 (b) Que parte deste exemplo é estatística inferencial?  
 (c) A qual população a inferência se refere?

**1.17** Em um levantamento de dados recente do Eurobarometer sobre energia e aquecimento global, uma das perguntas era: "Você estaria disposto a pagar mais por uma energia produzida de recursos renováveis do que por uma energia produzida de outros recursos?". O percentual de respostas *sim* variou entre os países de 10% (na Bulgária) a 60% (em Luxemburgo). Dos 631 sujeitos entrevistados no Reino Unido, 45% disseram *sim*. Foi previsto para todos os 48 milhões de adultos do Reino Unido que o percentual dos que iam responder *sim* estaria entre 41% e 49%. Identifique nesta discussão (a) uma estatística, (b) um parâmetro, (c) uma análise estatística descritiva, (d) uma análise estatística inferencial.

**1.18** Vá ao site para a pesquisa do Gallup, <http://www.galluppoll.com>. A partir da informação registrada ou dos links da homepage, dê um exemplo de (a) uma análise estatística descritiva, (b) uma análise estatística inferencial.

**1.19** Verifique se você tem acesso ao JSTOR (*Journal Storage*) na sua faculdade visitando <http://www.jstor.org>. Se tiver, clique em [Browse] e, então, em [Sociology] ou outra disciplina do seu interesse. Selecione um periódico e um assunto e navegue por alguns artigos. Encontre um artigo que use métodos estatísticos. Em um parágrafo de 100 a 200 palavras, explique como a estatística descritiva foi usada.



## 2 AMostragem e Mensuração

*bilidade* entre os sujeitos. Por exemplo, a variação que ocorre de estudante para estudante na média das suas notas da graduação (GPA). O que é responsável por esta variação? A forma como estes estudantes variam em quanto eles estudam por semana? Em quanto eles assistem à televisão por dia? Pelo seu QI? No seu escore da graduação? Na sua média do ensino médio (GPA)?

### Variáveis

Toda a característica que podemos mensurar para cada sujeito é chamada de **variável**. O nome reflete aqueles valores da característica que *variam* entre os sujeitos.

#### Variável

Uma variável é uma característica que pode variar no seu valor entre sujeitos em uma amostra ou população.

Sujeitos diferentes podem ter valores diferentes de uma variável. Exemplos de variáveis são o rendimento do ano passado, o número de filhos, se está empregado e o sexo. Os valores que a variável pode ter formam a **escala de mensuração**. Para o sexo, por exemplo, a escala de mensuração consiste em dois rótulos, feminino e masculino. Para o número de filhos ela é 0, 1, 2, 3, ...

Os métodos estatísticos válidos para uma variável dependem da sua escala de mensuração. Tratamos uma variável com

Para estudar os fenômenos sociais com a análise estatística, os métodos *descritivos* resumem os dados e os métodos *inferenciais* usam dados amostrais para fazer previsões sobre as populações. Quando coletamos dados devemos decidir quais sujeitos amostrar. Seleccionar uma amostra que seja representativa da população é o tópico principal deste capítulo.

Coletada uma amostra, devemos considerar nossas ideias sobre os fenômenos sociais em dados para decidir o que mensurar e como mensurar. Desenvolver formas para mensurar conceitos abstratos como realizações, inteligência e preconceito são um dos aspectos mais desafiadores da pesquisa social. Uma medida deve ter *validade*, descrever o que é pretendido mensurar e refletir com exatidão sobre o conceito. Também deve ter *credibilidade* no sentido de que o sujeito dará a mesma resposta quando perguntado novamente. Instrumentos de coleta de dados inválidos ou não confiáveis tornam as manipulações estatísticas dos dados sem sentido.

A primeira seção deste capítulo introduz definições relacionadas à mensuração, como tipos de dados. As outras seções discutem formas, boas ou ruins, de seleccionar a amostra.

### 2.1 VARIÁVEIS E SUA MENSURAÇÃO

Os métodos estatísticos nos ajudam a determinar os fatores que explicam a *variá-*

#### NOTAS

<sup>1</sup> *Attitudes towards Energy*, publicado em janeiro de 2006 em [http://ec.europa.eu/public\\_opinion](http://ec.europa.eu/public_opinion).

valor numérico como o rendimento anual diferentemente de uma variável com uma escala de mensuração consistindo em categorias, como (sim, não) ou se está ou não empregado. A seguir apresentaremos formas de classificar as variáveis. O primeiro tipo verifica se a escala de mensuração consiste em categorias ou números. Outro tipo consiste em avaliar o número de níveis naquela escala.

### Variáveis quantitativas e categóricas

Uma variável é chamada de **quantitativa** quando a escala de mensuração tem valores numéricos. Os valores representam magnitudes diferentes da variável. Exemplos de variáveis quantitativas são o rendimento anual do sujeito, o número de filhos, a idade e o número de anos de escolaridade completa.

Uma variável é chamada de **categórica** quando a escala de mensuração é um conjunto de categorias. Por exemplo, o estado civil com as categorias (solteiro, casado, divorciado, viúvo) é categórica. Para os canadenses, a província de residência é categórica, com as categorias Alberta, British Columbia e assim por diante. Outras variáveis categóricas são se está empregado no momento (sim, não), principal destino para compra de roupas (*shopping* local, centro local, internet, outro), tipo de música favorita (clássica, *country*, folclórica, jazz, *rock*), afiliação religiosa (protestante, católico, judeu, muçulmano, outra, nenhuma) e partido político de preferência.

Para as variáveis categóricas, categorias distintas diferem em qualidade, não em magnitude numérica. As variáveis categóricas são geralmente chamadas de **qualitativas**. Fazemos uma distinção entre variáveis categóricas e quantitativas porque métodos estatísticos diferentes se aplicam a cada tipo. Alguns métodos se aplicam às variáveis categóricas e outros se aplicam às variáveis quantitativas. Por

exemplo, a *média* é um resumo estatístico para uma variável quantitativa porque usa valores numéricos. É possível encontrar a média para uma variável quantitativa como o rendimento, mas não para uma variável categórica como afiliação religiosa ou tipo de música preferido.

### Escala de mensuração nominal, ordinal e intervalar

Para uma variável quantitativa, considera-se que os valores numéricos possíveis formam uma **escala intervalar**. Escalas intervalares têm uma distância numérica específica ou *intervalo* entre cada par de níveis. O rendimento anual é geralmente mensurado em uma escala intervalar. O intervalo entre \$40000 e \$30000, por exemplo, é igual a \$10000. Podemos comparar resultados em termos de quanto maior ou menor um intervalo é do outro.

As variáveis categóricas têm dois tipos de escalas. Para as variáveis categóricas mencionadas na subseção anterior, as categorias não estão ordenadas. A escala não tem uma extremidade "superior" ou "inferior". As categorias, então, formam uma **escala nominal**. Por exemplo, uma variável mensurando o principal modo de transporte para o trabalho pode usar uma escala nominal com categorias (automóvel, ônibus, metrô, bicicleta, a pé).

Embora as diferentes categorias sejam geralmente chamadas de *níveis* da escala, para uma variável nominal nenhum nível é maior ou menor do que qualquer outro nível. Os nomes ou rótulos como "automóvel" e "ônibus" para meio de transporte identificam categorias, mas não representam magnitudes diferentes. Ao contrário, cada valor possível de uma variável quantitativa é maior ou menor do que qualquer outro valor possível.

Um terceiro tipo de escala está, de certa forma, entre a nominal e a intervalar. Ela consiste em escalas categóricas tendo

uma *ordem* natural de valores. Os níveis formam uma **escala ordinal**. Os exemplos são a classe social (alta, média, baixa), a filosofia política (muito liberal, levemente liberal, moderado, levemente conservador, muito conservador), os gastos do governo com o meio ambiente (muito pouco, o suficiente, muito) e a frequência das atividades religiosas (nunca, menos do que uma vez ao mês, aproximadamente 1-3 vezes ao mês, toda semana, mais do que uma vez por semana). Essas escalas não são nominais porque as categorias estão ordenadas, e não são intervalares porque não existe uma distância definida entre os níveis. Por exemplo, uma pessoa categorizada como muito conservadora é *mais* conservadora do que uma pessoa categorizada como levemente conservadora, mas não existe valor numérico para *quanto mais* conservadora aquela pessoa é.

Em resumo, para variáveis ordinais as categorias têm uma ordem natural, enquanto para variáveis nominais as categorias não estão ordenadas. As escalas se referem à mensuração real e não aos próprios fenômenos. O *lugar de residência* pode indicar um nome de um lugar geográfico como um país (nominal), a distância daquele de um ponto no globo (intervalo), o tamanho do lugar (intervalar ou ordinal) ou outros tipos de variáveis.

### Aspectos quantitativos de dados ordinais

Como discutimos, os níveis de escalas nominais são qualitativos, variando em qualidade, não em quantidade. Os níveis de escalas intervalares são quantitativos, variando em magnitude. A posição das escalas ordinais na classificação quantitativa-qualitativa é confusa. Pelo fato de que a sua escala é um conjunto de categorias, elas são geralmente analisadas usando os mesmos métodos que as escalas nominais. Porém, em muitos aspectos, as escalas ordinais é que mais se

parecem com as escalas intervalares. Elas possuem uma característica quantitativa importante: cada nível tem uma magnitude maior ou menor do que o outro nível.

Alguns métodos estatísticos se aplicam especificamente às variáveis ordinais. Embora frequentemente seja útil analisar escalas ordinais atribuindo escores numéricos às categorias. Tratando as variáveis ordinais como intervalares em vez de nominais, podemos usar métodos mais poderosos disponíveis para as variáveis quantitativas.

Por exemplo, as notas do curso (como A, B, C, D, E) são ordinais. Mas nós as tratamos como intervalares quando atribuímos números às notas (como 4, 3, 2, 1, 0) para calcular a média das notas. Tratar as variáveis ordinais como intervalares requer boa ponderação na atribuição dos escores. Fazendo isso, você pode conduzir uma "análise de sensibilidade" verificando se as conclusões iriam diferir de modo significativo para outras escolhas de escores.

### Variáveis discretas e contínuas

Uma forma de classificar uma variável também ajuda a determinar quais métodos estatísticos são apropriados para ela. Esta classificação se refere ao número de valores na escala de mensuração.

#### Variáveis discretas e contínuas

Uma variável é **discreta** se seus valores possíveis formam um conjunto separado de números como 0, 1, 2, 3,.... Ela é **contínua** se ela pode ter um contínuo de valores reais possíveis.

Exemplos de variáveis discretas são o número de filhos e o número de visitas ao médico ano passado. Toda a variável expressa como "o número de..." é discreta porque é possível listar seus valores como {0, 1, 2, 3, 4,....}.

Exemplos de variáveis contínuas são altura, peso e o tempo que se leva para ler

um parágrafo de um livro. É impossível escrever todos os valores potenciais distintos, visto que eles formam um intervalo infinito de muitos valores. O tempo necessário pra ler um livro, por exemplo, poderia assumir o valor de 8,6294473... horas.

As variáveis discretas têm uma unidade básica de mensuração que não pode ser subdividida. Por exemplo, 2 e 3 são valores possíveis para o número de filhos, mas 2,5716 não são. Para uma variável contínua, ao contrário, entre quaisquer dois valores possíveis existe sempre outro valor possível. Por exemplo, a idade é contínua no sentido de que um indivíduo não envelhece em saltos discretos. Em um ponto bem definido durante o ano em que você atingir 21 para 22 anos, você tem 21,3851 anos e, da mesma forma, para cada outro número real entre 21 e 22. Uma coleção contínua e infinita de valores da idade ocorre entre 21 e 22 anos.

Toda a variável com um número finito de valores é discreta. Todas as variáveis categóricas, nominais ou ordinais são discretas e têm um conjunto finito de categorias. As variáveis quantitativas podem ser discretas ou contínuas; a idade é contínua e o número de filhos é discreta.

Para variáveis quantitativas, a distinção entre as variáveis discretas e contínuas pode ser confusa dependendo de como as variáveis são realmente mensuradas. Na prática, arredondamos as variáveis contínuas quando as mensuramos, portanto a mensuração é, na verdade, discreta. Dizemos que um indivíduo tem 21 anos sempre que a idade daquela pessoa está em algum ponto entre 21 e 22. Por outro lado, algumas variáveis, embora discretas, têm um grande número de valores possíveis. Na mensuração do rendimento anual familiar em dólares os valores potenciais são 0, 1, 2, 3, ..., até um valor muito grande de muitos milhões.

Qual é a implicação disso? Os métodos estatísticos para variáveis discretas são principalmente usados para as variáveis quantitativas que aceitam relativamente

poucos valores, como o número de vezes que uma pessoa foi casada. Os métodos estatísticos para as variáveis contínuas são usados para as variáveis quantitativas que podem aceitar muitos valores, não obstante se elas são, teoricamente, contínuas ou discretas. Por exemplo, os estatísticos tratam as variáveis como a idade, rendimento e QI como contínuas.

Em resumo,

- As variáveis são *quantitativas* (com valores numéricos) ou *categóricas*. As variáveis quantitativas são mensuradas em uma escala *intervalar*. As variáveis categóricas com categorias não ordenadas têm uma escala *nominal* e as variáveis com categorias ordenadas têm uma escala *ordinal*.
- As variáveis *categóricas* (nominais ou ordinais) são *discretas*. As variáveis quantitativas podem ser discretas ou contínuas. Na prática, as variáveis quantitativas que podem aceitar muitos valores são tratadas como *contínuas*.


A Figura 2.1 resume os tipos de variáveis em termos de classificações (quantitativa, categórica), (nominal, ordinal, intervalar) e (contínua, discreta).

## 2.2 ALEATORIZAÇÃO

Os métodos estatísticos inferenciais usam a estatística amostral para fazer previsões sobre os parâmetros da população. A qualidade das inferências depende de quão bem a amostra representa a população. Esta seção introduz um método amostral importante que incorpora a **aleatorização**, o mecanismo para conseguir uma boa representação amostral.

### Amostragem aleatória simples

Os sujeitos de uma população podem ser indivíduos, famílias, escolas, cidades, hospitais, registro de relato de crime e assim



Nota: Os dados ordinais são tratados, algumas vezes, como categóricos e, algumas vezes, como quantitativos.

Figura 2.1 Resumo das classificações quantitativa-categórica, nominal-ordinal-intervalar, contínua-discreta.

por diante. A *amostragem aleatória simples* é um método de amostragem para o qual cada amostra possível tem uma chance igual de ser selecionada.

Considere  $n$  a representação do número de sujeitos na amostra, chamado de **tamanho da amostra**.

#### Amostra aleatória simples

Uma amostra aleatória simples de  $n$  sujeitos de uma população é uma na qual cada amostra possível daquele tamanho tem a mesma probabilidade (chance) de ser selecionada.

Por exemplo, suponha que um pesquisador administre um questionário a um adulto aleatoriamente selecionado em cada um de vários domicílios. Um domicílio em especial tem 4 adultos – mãe, pai, tio e tia – identificados como M, P, T e A. Para uma amostra aleatória simples de  $n = 1$  adulto, cada um dos quatro adultos é provável de ser entrevistado. Você poderia selecionar um colocando os quatro nomes em cédulas idênticas e selecionar um, sem olhar, de um chapéu. Para uma amostra aleatória simples de  $n = 2$  adultos, cada amostra possível de tamanho dois é igualmente provável. As seis amostras potenciais são (M,

P), (M, A), (M, T), (P, A), (P, T) e (A, T). Para selecionar a amostra, você seleciona, sem olhar, duas cédulas do chapéu.

Uma amostra aleatória simples é geralmente apenas chamada de **amostra aleatória**. O adjetivo *simples* é usado para distinguir esse tipo de amostragem de outros métodos mais complexos apresentados na Seção 2.4 que também têm elementos de aleatorização.

Por que é uma boa ideia usar a amostragem aleatória? Porque todos têm a mesma chance de serem incluídos na amostra, portanto ela é justa. Isso reduz a chance de a amostra ser tendenciosa de alguma forma, levando a inferências imprecisas sobre a população. A maioria dos métodos estatísticos inferenciais assume uma aleatorização do tipo fornecido pela amostragem aleatória.

### Como selecionar uma amostra aleatória simples

Para selecionar uma amostra aleatória simples, precisamos de uma lista de todos os sujeitos da população. Esta lista é chamada de **quadro amostral**. Suponha que você planeje amostrar os estudantes da sua faculdade. A população é todos os alunos

da faculdade. Um quadro amostral possível é o diretório dos estudantes.

O método mais comum para selecionar uma amostra aleatória é (1) numerar os sujeitos no plano amostral, (2) gerar um conjunto desses números aleatoriamente e (3) amostrar os sujeitos cujos números foram gerados. Usar *números aleatórios* para selecionar a amostra assegura que cada sujeito tenha uma chance igual de seleção.

#### Números aleatórios

Os números aleatórios são valores gerados pelo computador de acordo com um esquema por meio do qual cada dígito é igualmente provável de ser qualquer um de dois inteiros 0, 1, 2, 3, ..., 9 e não depende dos outros dígitos gerados.

A Tabela 2.1 apresenta uma coleção de números aleatórios. Os números flutuam de acordo com um padrão não estabelecido. Qualquer número em particular tem a mesma chance de ser um 0, 1, 2, ..., ou 9. Os números são escolhidos independentemente, assim qualquer dígito escolhido não tem influência em nenhuma outra seleção. Se o primeiro dígito em uma linha da tabela for um 9, por exemplo, o próximo dígito é, da mesma forma, ainda provável de ser um 9 como um 0 ou 1 ou qualquer outro número. Os números aleatórios estão disponíveis em tabelas publicadas e podem ser gerados com um *software* e com muitas calculadoras estatísticas.

☑ Tabela 2.1 Parte de uma tabela de números aleatórios

Linha/Col.	(1)	(2)	(3)	(4)	(5)	(6)	(7)	(8)
1	10480	15011	01536	02011	81647	91646	69179	14194
2	22368	46573	25595	85393	30995	89198	27982	53402
3	24130	48360	22527	97265	76393	64809	15179	24830
4	42167	93093	06243	61680	07856	16376	39440	53537
5	37570	39975	81837	16656	06121	91782	60468	81305
6	77921	06907	11008	42751	27756	53498	18602	70659

Fonte: Condensado de William H. Beyer, ed., *Handbook of Tables for Probability and Statistics*, 2a. ed., The Chemical Rubber Co., 1968. Usado com a permissão da Chemical Rubber Co.

Suponha que você quer selecionar uma amostra aleatória simples de  $n = 100$  estudantes do corpo discente de uma universidade com 30000 alunos. O plano amostral é uma listagem desse corpo discente. Selecione os estudantes usando seqüências de cinco dígitos para identificá-los, como segue:

1. Atribua os números 00001 a 30000 aos estudantes da lista, usando 00001 para o primeiro estudante da lista, 00002 para o segundo estudante e assim por diante.
2. Começando em qualquer ponto da tabela de números aleatórios ou gerando números aleatórios usando um *software* ou uma calculadora, escolha números com cinco dígitos sucessivos até você obter 100 números distintos entre 00001 e 30000.
3. Inclua na amostra os estudantes com os números na lista que sejam iguais aos selecionados aleatoriamente.

Por exemplo, para a primeira coluna de números com cinco dígitos na Tabela 2.1, os primeiros três números aleatórios são 10480, 22368 e 24130. Os primeiros três estudantes selecionados são os que apresentam os números 10480, 22368 e 24130 na lista.

Na seleção dos 100 números com cinco dígitos, omita os números maiores do que 30000, como os próximos três números de cinco dígitos da Tabela 2.1, visto que nenhum estudante da lista de matrícula tem

um valor atribuído tão grande. Após usar a primeira coluna dos números de cinco dígitos, vá para a próxima coluna dos números e continue. Se o tamanho da população estivesse entre 1000 e 9999, você iria usar quatro dígitos a cada vez. A coluna (ou linha) da qual você começa a selecionar os números não importa, visto que os números não têm um padrão estabelecido. A maioria dos *softwares* estatísticos pode fazer tudo isso para você.

#### Coletando dados com levantamentos amostrais

Muitos estudos selecionam uma amostra de pessoas de uma população e as entrevistam para coletar dados. Esse método de coleta de dados é chamado de **levantamento de dados**. A entrevista poderia ser uma entrevista pessoal, por telefone ou um questionário autoaplicado.

A Pesquisa Social Geral (PSG) é um exemplo de um levantamento de dados, pois coleta informação usando entrevistas pessoais de uma amostra aleatória de sujeitos da população adulta dos Estados Unidos para fornecer um registro instantâneo daquela população. (O levantamento de dados não usa a amostragem aleatória *simples*, mas preferivelmente um método discutido mais tarde no capítulo que incorpora estágios múltiplos e aglomerações, mas é projetado para dar a cada família a mesma chance de inclusão.) Pesquisas nacionais como a pesquisa do Gallup são também levantamentos de dados. Elas geralmente usam entrevistas por telefone. Visto que frequentemente é difícil de obter um plano amostral, muitas entrevistas por telefone obtêm a amostra com a *discagem digital aleatória*. Uma variedade de problemas pode fazer com que as respostas de um levantamento de dados tendam favorecerem a algumas partes da população sobre outras. Então, os resultados da amostra não são representativos da população.

Discutiremos alguns problemas potenciais na Seção 2.3.

#### Coletando dados com um experimento

Em alguns estudos, os dados são resultados de um *experimento* planejado. O propósito da maioria dos experimentos é comparar respostas dos sujeitos, sob diferentes condições. Essas condições são níveis de uma variável que pode influenciar o resultado. O cientista tem o controle do experimento por ser capaz de atribuir os sujeitos às condições.

Por exemplo, as condições podem ser medicamentos diferentes para tratar de algumas doenças. As condições são chamadas de **tratamentos**. Para conduzir o experimento, o pesquisador necessita de um plano para atribuir sujeitos aos tratamentos. Esses planos são chamados de **delineamentos experimentais**. Bons delineamentos experimentais usam a aleatorização para determinar qual tratamento um sujeito recebe.

No final da década de 1980, o Physician's Health Study Research Group da Faculdade de Medicina de Harvard delineou um experimento para analisar se a ingestão regular de aspirina reduz a mortalidade por doenças do coração. De aproximadamente 22000 médicos do sexo masculino, metade foi escolhida para tomar uma aspirina a cada dois dias. A metade restante tomou um placebo, que não tinha um agente ativo. Após cinco anos, as taxas de ataque cardíaco foram comparadas. Usando a aleatorização para determinar quem recebeu cada tratamento, os pesquisadores sabiam que os grupos teriam um equilíbrio aproximado dos fatores que poderiam afetar as taxas de ataque cardíaco, como idade e a qualidade da saúde. Se os médicos pudessem decidir eles próprios qual tratamento tomar, os grupos estariam desequilibrados em um fator importante. Suponha, por exemplo, que os médicos mais

juvens fossem mais prováveis de selecionar a aspirina. Então, uma taxa mais baixa de ataque cardíaco entre o grupo da aspirina poderia ocorrer simplesmente porque os sujeitos mais jovens têm uma probabilidade menor de sofrerem ataques cardíacos.

### Coletando dados com um estudo observacional

Na pesquisa social, raramente é possível conduzir experimentos. Não é possível atribuir aleatoriamente os sujeitos aos grupos que queremos comparar, como os níveis do sexo ou raça ou nível educacional ou rendimento anual. Muitos estudos meramente *observam* os resultados para sujeitos disponíveis nas variáveis sem qualquer manipulação experimental dos sujeitos. Tais estudos são chamados de **estudos observacionais**. O pesquisador mensura as respostas dos sujeitos nas variáveis de interesse, mas não tem controle experimental sobre os sujeitos.

Com estudos observacionais, comparar grupos é difícil porque os grupos podem estar desequilibrados nas variáveis que afetam o resultado. Isto é verdadeiro mesmo com a amostragem aleatória. Por exemplo, suponha que planejamos comparar os estudantes negros, hispânicos e os brancos com um teste padronizado. Se os estudantes brancos têm um escore médio maior, uma variedade de variáveis pode ser responsável por esta diferença, como a educação dos pais ou a renda dos pais ou ainda a qualidade da escola que frequentam. Isto dificulta a comparação de grupos com estudos observacionais, especialmente quando algumas variáveis chave podem não ter sido mensuradas no estudo.

Estabelecer relações de causa e efeito é o ponto principal para a ciência. Mas não é possível estabelecer causa e efeito com um estudo não experimental, quer seja um estudo experimental com uma amostra disponível ou um levantamento de dados

usando uma amostragem aleatória. Com um estudo observacional, existe uma forte possibilidade de que a amostra não expresse muito bem a população. Com um estudo observacional ou um levantamento de dados, existe sempre a possibilidade de que uma variável não mensurada poderia ser responsável por padrões observados nos dados. Com um experimento que atribui aleatoriamente sujeitos a tratamentos, esses tratamentos deveriam ser aproximadamente equilibrados em quaisquer variáveis não mensuradas. Por exemplo, no estudo do ataque cardíaco mencionado acima, os médicos que tomaram a aspirina não tenderiam a ser mais jovens ou mais saudáveis do que os médicos que tomaram o placebo. Pelo fato de que um experimento aleatório equilibra os grupos que estão sendo comparados com outros fatores, é possível estudar a causa e o efeito mais precisamente com um experimento do que com um estudo observacional.

Quer um estudo seja experimental ou não, é importante incorporar a aleatorização em todo o estudo em que se planeja fazer inferências. Esta aleatorização pode ter a forma de seleção aleatória ou uma amostra por um levantamento de dados ou alocar aleatoriamente os sujeitos a diferentes tratamentos para um estudo experimental.

### 2.3 VARIABILIDADE AMOSTRAL E TENDENCIOSIDADE POTENCIAL

Mesmo se um estudo usa a aleatorização sensatamente, os resultados do estudo ainda dependem dos sujeitos que são amostrados. Dois pesquisadores que separadamente selecionam amostras aleatórias de uma mesma população podem ter pouca superposição, se existir alguma, entre os dois grupos de indivíduos amostrados. Portanto, os valores da estatística amostral irão diferir nas duas amostras e os resulta-

dos das análises baseados nessas amostras quase que certamente irão diferir.

### Erro amostral

Suponha que as organizações de pesquisa de opinião pública Gallup, Harris, Zogby e Pew cada uma aleatoriamente amostram 1000 adultos canadenses para estimar o percentual de canadenses que acham bom o desempenho do primeiro-ministro. Baseadas nas amostras que elas selecionam, talvez a Gallup relate uma taxa de aprovação de 63%, Harris relate 68%, Zogby 65% e Pew 64%. Essas diferenças poderiam refletir uma formulação levemente diferente da pergunta. Mas mesmo se as perguntas são expressas exatamente iguais, os percentuais inam, provavelmente, diferir um pouco porque as amostras são diferentes.

Para conclusões baseadas em inferência estatística serem válidas, devemos conhecer o *erro amostral* — o quanto a estatística diferente do parâmetro que ela prevê por causa da forma com que os resultados naturalmente exibem variação de amostra para amostra.

#### Erro amostral

O erro amostral de uma estatística é igual à diferença entre o seu valor e o parâmetro populacional que ela está estimando.

Suponha que o percentual real da população adulta do Canadá, que deu ao primeiro-ministro uma avaliação favorável, seja de 66%. Então, a Organização Gallup, que previu 63%, teve um erro amostral de 63% - 66% = -3%. A Organização Harris, que previu 68%, teve um erro amostral de 68% - 66% = 2%. Na prática, o erro amostral é desconhecido porque os valores dos parâmetros da população são desconhecidos.

A amostragem aleatória protege contra a tendenciosidade, no sentido de que o erro amostral tende a flutuar em torno de zero, algumas vezes sendo positivo (como

na pesquisa da Harris) e algumas vezes sendo negativo (como na pesquisa da Gallup). A amostragem aleatória também nos permite prever o provável tamanho do erro amostral. Para tamanhos da amostra de aproximadamente 1000, veremos que o erro amostral para estimar percentuais é geralmente não maior do que mais ou menos 3%. Esse limite é a *margem de erro*. A variabilidade também ocorre nos valores da estatística amostral com a amostragem não aleatória, mas a amplitude do erro amostral não é previsível como ocorre com as amostras aleatórias.

### Tendenciosidade amostral: amostragem não probabilística

Outros fatores além do erro amostral podem ser as causas de os resultados variarem de amostra para amostra. Estes fatores podem, possivelmente, também induzir à tendenciosidade. Nós iremos discutir três tipos de tendenciosidade. O primeiro é chamado de **tendenciosidade amostral**.

Para a amostragem aleatória simples, cada amostra possível de  $n$  sujeitos tem probabilidade conhecida e igual de ser selecionada. Este é um plano de **amostragem probabilística**, significando que é conhecida a probabilidade de que qualquer amostra em particular será selecionada. Os métodos de estatística inferencial supõem que a amostragem é probabilística. Os métodos de **amostragem não probabilística** são aqueles para os quais não é possível determinar as probabilidades das possíveis amostras. As inferências usando tais amostras têm uma confiabilidade desconhecida e resultam em **tendenciosidade amostral**.

O método de amostragem não probabilística mais comum é a **amostragem voluntária**. Como o nome sugere, os sujeitos se voluntariam para fazerem parte da amostra. Mas, a amostra pode não ser representativa da população e gerar conclusões equivocadas. Por exemplo, um questionário enviado

pelo correio publicado na *TV Guide* propôs a pergunta: "O presidente deve ter o poder do veto para eliminar o lixo?". Daquelas que responderam, 97% disseram sim. Para a mesma pergunta proposta a uma amostra aleatória, 71% disseram sim.<sup>1</sup>

Exemplos de amostragem voluntária são visitados todo dia em muitos sites da internet e programas de notícias na televisão. Os espectadores registram suas opiniões sobre um assunto votando pela internet. Os espectadores que respondem não são provavelmente ser um grupo representativo, mas será daqueles que podem facilmente acessar a internet e estão seguros o suficiente para responder. Os indivíduos que têm uma opinião em particular podem ser mais propensos de responder do que indivíduos que têm uma opinião diferente. Por exemplo, uma noite o programa *Nightline* da ABC perguntou aos espectadores se a Organização das Nações Unidas (ONU) deveria continuar localizadas nos Estados Unidos. De mais de 186000 respondentes, 67% queriam as Nações Unidas fora dos Estados Unidos. Ao mesmo tempo, uma pesquisa de opinião usando uma amostra aleatória de aproximadamente 500 respondentes estimou que o percentual da população era de aproximadamente 28%. Embora a amostra aleatória tivesse um tamanho bem menor, ela é muito mais confiável.

Uma amostra grande não ajuda com a amostragem voluntária – a tendenciosidade permanece. Em 1936, a revista semanal *Literary Digest* enviou mais de 10 milhões de questionários pelo correio para prever o resultado da eleição presidencial. Os questionários foram enviados a um segmento da sociedade relativamente abastado (aqueles que têm carros ou telefones) e menos do que 2% retornaram. O periódico usou essa estratégia para prever uma vitória esmagadora de Alfred Landon sobre Franklin Roosevelt. O resultado contrário foi previsto por George Gallup com uma amostra menor na primeira pesquisa de opinião científica feita

para este propósito. Na verdade, Roosevelt venceu de forma esmagadora.

Infelizmente, a amostragem voluntária é algumas vezes necessária. Isto é frequentemente verdadeiro em estudos médicos. Suponha que um estudo planeja investigar o desempenho de um novo medicamento comparado com um medicamento padrão, para sujeitos que sofrem de pressão alta. Os pesquisadores não serão capazes de encontrar um quadro amostral de todos os que sofrem de pressão alta e coletar uma amostra aleatória simples deles. Eles podem, entretanto, serem capazes de amostrar tais sujeitos em certos centros médicos ou usar voluntários. Mesmo assim, a aleatorização deve ser usada sempre que possível. Para os pacientes do estudo, eles podem selecionar aleatoriamente quem recebe o novo medicamento e quem recebe o medicamento padrão.

Mesmo com a amostragem aleatória, a tendenciosidade amostral pode ocorrer. Um caso é quando o plano amostral está sujeito a uma **subcobertura**: alguns grupos populacionais não estão representados. Um levantamento de dados por telefone não irá alcançar os presidiários ou pessoas sem teto ou pessoas tão pobres que não podem arcar com um telefone, ao passo que famílias que têm muitos telefones tenderão a ser representadas em excesso. As respostas daqueles que não têm telefones podem tender a ser bem diferentes daqueles que realmente foram amostrados, levando a resultados tendenciosos.

### Resposta tendenciosa

Em um levantamento de dados, a forma como a pergunta é formulada ou feita pode ter um grande impacto nos resultados. Por exemplo, a pesquisa de opinião do *New York Times/CBS* em 2006 perguntou se o entrevistado era a favor de uma nova taxa para a gasolina, e somente 12% disseram sim. Quando a taxa foi apresentada como

uma redução da dependência dos Estados Unidos do petróleo estrangeiro, 55% disseram sim e quando perguntados sobre uma taxa para a gasolina que iria reduzir o aquecimento global, 59% disseram sim.<sup>2</sup>

Questões mal colocadas ou confusas resultam em **respostas tendenciosas**. Mesmo a ordem em que as perguntas são feitas pode influenciar tremendamente os resultados. Durante a Guerra Fria, um estudo perguntou: "Você acha que os Estados Unidos deveriam permitir que os jornalistas russos viessem aqui e enviassem o que eles quisessem de volta para a Rússia?" e "Você acha que a Rússia deveria permitir que os jornalistas americanos entrassem na Rússia e enviassem o que eles quisessem de volta?". O percentual de respostas *sim* para a primeira pergunta foi de 36% quando ela foi feita em primeiro lugar e 73% quando foi feita em segundo lugar.<sup>3</sup>

Em uma entrevista, as características do entrevistador podem resultar em uma resposta tendenciosa. Os respondentes podem mentir se acharem que sua opinião não é socialmente aceitável. Eles podem ser mais prováveis de dar a resposta que acham que o entrevistador prefira. Um exemplo é fornecido por um estudo no efeito da raça do entrevistador. Seguindo uma entrevista por telefone, foi perguntado aos respondentes se eles achavam que o entrevistador era negro ou branco (todos eram, na verdade, negros). Perceber que o entrevistador é branco resultou em opiniões mais conservadoras. Por exemplo, 14% concordaram que "A sociedade americana é justa com todos" quando achavam que o entrevistador era negro, mas 31% concordaram quando eles acharam que o entrevistador era branco.<sup>4</sup>

### Tendenciosidade da não resposta:

#### dados que faltam

Alguns sujeitos que deveriam estar na amostra podem recusar a participação ou

não pode ser possível acessá-los. Isto resulta no problema da **tendenciosidade da não resposta**. Se somente metade da amostra planejada foi realmente observada, devemos nos preocupar se a metade não observada difere daquela observada de uma forma que cause resultados tendenciosos. Mesmo se selecionarmos a amostra aleatoriamente, os resultados são questionáveis se existir uma não resposta substancial, digamos, acima de 20%.

Para o livro *Women in Love*, a autora Shere Hite fez um levantamento de dados com mulheres nos Estados Unidos. Uma das suas conclusões foi que 70% das mulheres que estão casadas há pelo menos cinco anos têm casos extraconjugais. Ela baseou esta conclusão nas respostas aos questionários devolvidos por 4500 mulheres. Isto parece uma amostra muito grande. Entretanto, o questionário foi enviado pelo correio para aproximadamente 100000 mulheres. Não podemos saber se 4,5% das mulheres que responderam eram representativas das 100000 que receberam o questionário, muito menos da população total das mulheres americanas. Isto torna perigoso fazer inferência de uma população maior.

**Dados que faltam** (*missing data*) é um problema em quase todos os grandes estudos. Alguns sujeitos não fornecem respostas para algumas das variáveis mensuradas. Mesmo nos censos, que são planejados para acessar todos em um país, algumas pessoas não são alcançadas ou não cooperam. A maioria dos *softwares* ignora casos para os quais observações estão faltando para pelo menos uma variável usada em uma análise. Isso resulta em desperdício de informação e uma possível tendenciosidade. Os estatísticos desenvolveram recentemente métodos que substituem as observações que faltam por valores previstos nos padrões nos dados. Veja Allison (2002) para uma introdução a formas de tratamento dos dados que faltam.

### Resumo de tipos de tendenciosidade

Em resumo, o levantamento de dados por amostragem tem fontes potenciais de tendenciosidade:

- **Tendenciosidade amostral** ocorre com o uso de amostras não probabilísticas ou com falta de cobertura.
- **Tendenciosidade da resposta** ocorre quando o sujeito dá uma resposta incorreta (talvez minta) ou a formulação da pergunta ou a forma com que o entrevistador faz as perguntas é confusa ou equivocada.
- **Tendenciosidade da não resposta** ocorre quando os sujeitos amostrados não podem ser encontrados ou se recusam a participar ou não respondem a algumas perguntas.

Em qualquer estudo, avalie cuidadosamente o alcance das conclusões. Formule de modo crítico as conclusões observando a constituição da amostra. Como a amostra foi selecionada? Qual era o seu tamanho? Como foram formuladas as perguntas? Quem patrocinou e conduziu a pesquisa? Quanto menos informação disponível, menos você deve confiar.

Finalmente, seja cauteloso com qualquer estudo que faça inferências para uma população maior do que é justificado pela amostra escolhida. Suponha que um psicólogo execute um experimento usando uma amostra aleatória de estudantes de um curso introdutório de psicologia. Com inferência estatística, os resultados da amostra generalizam a população de todos os estudantes da turma. Para os resultados terem um interesse mais amplo, o psicólogo pode afirmar que a conclusão se estende a *todos* os estudantes da faculdade, a todos os adultos jovens ou até mesmo a todos os estudantes. Essas generalizações podem estar erradas, porque a amostra pode diferir daquelas populações de formas fundamentais, como na idade média ou no *status* socioeconômico.

### 2.4 OUTROS MÉTODOS DE AMOSTRAGEM PROBABILÍSTICA\*

A Seção 2.2 introduziu a **amostragem aleatória simples** e explicou a sua importância para a inferência estatística. Na prática, outros métodos de amostragem probabilística que têm elementos de aleatorização são, algumas vezes, preferíveis à amostragem aleatória simples ou são mais fáceis de serem obtidos.

#### Amostragem aleatória sistemática

A **amostragem aleatória sistemática** seleciona um sujeito próximo ao início da lista do plano amostral, pula vários nomes e seleciona outro sujeito, pula mais alguns nomes e seleciona o próximo sujeito e assim por diante. O número de nomes omitidos em cada estágio depende do tamanho da amostra desejado. Aqui está como é feito:

#### Amostra aleatória sistemática

Indique o tamanho da amostra por  $n$  e o tamanho da população por  $N$ . Seja  $k = N/n$ , o tamanho da população dividido pelo tamanho da amostra. Uma **amostra aleatória sistemática** (1) seleciona um sujeito ao acaso dos primeiros  $k$  nomes no plano amostral e (2) seleciona cada  $k$ ésimo sujeito listado depois daquele. O número  $k$  é chamado de **período**.

Suponha que você queira uma amostra aleatória sistemática de 100 estudantes de uma população de 30000 estudantes registrados em um banco de dados do *campus*. Então,  $n = 100$  e  $N = 30000$ , assim  $k = 30000/100 = 300$ . O tamanho da população é 300 vezes o tamanho da amostra, portanto você precisa selecionar um em cada 300 estudantes. Você seleciona um estudante ao acaso, usando números aleatórios, dos

\* Exercícios e subtítulos marcados com asterisco em itálico são de maior dificuldade ou introduzem um material novo e opcional.

primeiros 300 estudantes do arquivo. Então, você seleciona cada 300º estudante após aquele selecionado aleatoriamente. Isso produz um tamanho da amostra de 100. Os três primeiros dígitos na Tabela 2.1 são 104, que cai entre 001 e 300, assim você seleciona primeiro o estudante de número 104. Os números dos outros estudantes selecionados são  $104 + 300 = 404$ ,  $404 + 300 = 704$ ,  $704 + 300 = 1004$ ,  $1004 + 300 = 1304$  e assim por diante. O 100º estudante selecionado está listado nos últimos 300 nomes do arquivo.

Na amostragem de um plano amostral, é mais simples selecionar uma amostra aleatória sistemática do que uma amostra aleatória simples porque ela usa somente um número ao acaso. Esse método simplesmente fornece uma boa representação da população porque, para listas em ordem alfabética como arquivos de nomes, os valores da maioria das variáveis flutuam aleatoriamente pela lista. Com esse método, fórmulas estatísticas baseadas na amostra aleatória simples são geralmente válidas.

Uma amostra aleatória sistemática não é uma amostra aleatória simples porque todas as amostras de tamanho  $n$  não são igualmente prováveis. Por exemplo, diferente de uma amostra aleatória simples, dois sujeitos listados próximos um do outro na lista não podem, ambos, aparecer na amostra.

#### Amostragem aleatória estratificada

Outro método de amostragem probabilístico, útil na pesquisa em ciências sociais para estudos de comparação de grupos, é a **amostragem estratificada**.

#### Amostra aleatória estratificada

Uma amostra aleatória estratificada divide a população em grupos separados, chamados de estratos e, então, seleciona uma amostra aleatória simples de cada estrato.

Suponha um estudo em Cambridge, Massachusetts planeja comparar as opiniões de Democratas e Republicanos registrados sobre se o governo deveria garantir assistência médica para todos os cidadãos. Estratificando de acordo com a filiação política, o estudo seleciona uma amostra aleatória de Democratas e outra amostra aleatória de Republicanos.

A amostragem aleatória estratificada é chamada de **proporcional** se as proporções do estrato amostrado são as mesmas da população. Por exemplo, se 90% da população de interesse é Democrata e 10% é Republicana, então a amostragem é proporcional se o tamanho da amostra dos Democratas é nove vezes o tamanho da amostra dos Republicanos.

A amostragem aleatória estratificada é chamada de **desproporcional** se as proporções dos estratos amostrados diferem das proporções da população. Isto é útil quando o tamanho da população para um estrato é relativamente pequeno. Um grupo que inclui uma pequena parte da população pode não ter representação o suficiente em uma amostra aleatória simples para permitir inferências precisas. Não é possível comparar precisamente os Democratas e Republicanos, por exemplo, se somente 10 pessoas em um tamanho da amostra de 100 são Republicanos. Ao contrário, um tamanho da amostra estratificado desproporcionalmente de 100 pode mostrar aleatoriamente 50 Democratas e 50 Republicanos.

Para implementar a estratificação, devemos conhecer o estrato ao qual cada sujeito do plano amostral pertence. Isso geralmente restringe as variáveis que podem ser usadas para formar o estrato. As variáveis devem ter estratos que são facilmente identificáveis. Por exemplo, seria fácil selecionar uma amostra estratificada da população de uma escola usando o nível das notas como a variável estratificada, mas seria difícil preparar um plano amostral adequado de domicílios da cidade por renda familiar.

## Amostragem por conglomerados

As amostragens aleatórias estratificadas, sistemática e simples são geralmente difíceis de implementar porque requerem um plano amostral completo. Tais listas são fáceis de serem obtidas para amostrar cidades, escolas ou hospitais, por exemplo, mas mais difíceis para amostrar indivíduos ou famílias. *A amostragem por conglomerados* é útil quando uma lista completa da população não estiver disponível.

**Amostra aleatória por conglomerados**  
Divida a população em um grande número de conglomerados como quarteirões da cidade. Seleccione uma amostra aleatória simples dos conglomerados. Use os sujeitos desses conglomerados como a amostra.

Por exemplo, um estudo pode planejar mostrar aproximadamente 1% das famílias de uma cidade, usando os quarteirões da cidade como conglomerados. Usando um mapa para identificar os quarteirões da cidade, ele poderia selecionar uma amostra aleatória simples de 1% dos quarteirões e, então, mostrar cada família em cada quarteirão. Um estudo sobre o cuidado ao paciente em hospitais psiquiátricos em Ontário poderia amostrar aleatoriamente hospitais para doentes mentais (os conglomerados) e, então, coletar dados de pacientes dentro desses hospitais.

Qual a diferença entre uma amostra estratificada e uma amostra por conglomerados? Uma amostra estratificada usa cada estrato. Os estratos são geralmente grupos que queremos comparar. Ao contrário, uma amostra por conglomerados usa uma amostra dos conglomerados, em vez de todos eles. Na amostragem por conglomerados, os conglomerados são meramente formas de identificar facil-

mente grupos de sujeitos. O objetivo não é comparar os conglomerados, mas usá-los para obter uma amostra. A maioria dos conglomerados não é representada na amostra final.


A Figura 2.2 ilustra a distinção entre os sujeitos amostrados (amostra aleatória simples), os conglomerados amostrados (amostra aleatória por conglomerados) e sujeitos amostrados de dentro do estrato (amostra aleatória estratificada). A figura descreve formas para fazer um levantamento de dados de 40 estudantes em uma faculdade, fazer comparações entre calouros, estudantes do 2º ano, estudantes do penúltimo ano e formandos.

### Amostragem multiestágio

Quando conduz um levantamento para prever as eleições, a Organização Gallup geralmente identifica os distritos eleitorais como conglomerados e coleta uma amostra aleatória simples deles. Por outro lado, também coleta uma amostra aleatória simples dos domicílios dentro de cada distrito selecionado.

Isso é mais executável do que amostrar cada domicílio nos distritos escolhidos, e é um exemplo de *amostragem multiestágio*, que usa combinações de métodos amostrais. Aqui está um exemplo de uma amostra multiestágio:

- Tratar países (ou divisões do censo) como conglomerados e selecionar uma amostra aleatória de certo número deles.
- Dentro de cada país selecionado, coletar uma amostra aleatória por conglomerados de regiões de quarteirões.
- Dentro de cada região selecionada, coletar uma amostra aleatória sistemática de cada décima casa.
- Dentro de cada casa selecionada, selecionar um adulto ao acaso para a amostra.



**Figura 2.2.** Formas de amostrar aleatoriamente 40 estudantes. A figura é um plano para uma amostra aleatória simples, uma amostra aleatória por conglomerados com oito conglomerados de estudantes que vivem juntos e uma amostra aleatória estratificada de 10 estudantes de cada turma (calouros, 2º ano, penúltimo ano e formandos).

As amostras multiestágio são comuns

na pesquisa em ciências sociais. São mais simples de implementar do que a amostra aleatória simples, mas fornecem uma amostragem mais ampla da população do que um método simples como a amostragem por conglomerados.

Para a inferência estatística, amostras estratificadas, amostras por conglomerados e amostras multiestágio usam fórmulas diferentes daquelas deste livro. A amostragem por conglomerados requer uma amostragem maior para conseguir tanta precisão inferencial quanto a amostragem aleatória simples. As observações dentro dos conglomerados tendem a ser similares, por causa da tendência dos sujeitos que moram próximos uns dos outros de ter valores similares em assuntos de opinião e em variáveis demográficas e econômicas como idade, renda, raça e ocupação. Assim, precisamos de mais dados para obter um levantamento transversal representativo. Ao contrário, os resultados para a amostragem estratificada podem ser mais precisos do que os que estão neste livro para a amostragem aleatória simples. Os livros especializados em metodologia amostral fornecem mais detalhes (Scheaffer et al., 2005; Thompson, 2002).

## 2.5 RESUMO DO CAPÍTULO

Os métodos estatísticos analisam dados em **variáveis**, que são características que variam entre os sujeitos. Os métodos estatísticos usados dependem do tipo da variável:

- As variáveis mensuradas numericamente, como a renda familiar e o número de filhos de uma família, são **quantitativas**. São mensuradas numa **escala intervalar**.
- As variáveis que aceitam valores em um conjunto de categorias são chamadas de **categoricas**. Aquelas mensuradas como categorias não ordenadas, como afiliação religiosa e região da residência, têm uma **escala nominal**. Aquelas mensuradas como categorias ordenadas, como classe social e ideologia política, têm uma **escala ordinal** de mensuração.
- As variáveis são também classificadas como **discretas**, tendo valores possíveis que são um conjunto de números separados (como 0, 1, 2, ...) ou **contínuas**, tendo um conjunto infinito e contínuo de possíveis valores. As variáveis categóricas, quer nominais ou ordinais, são discretas. As variáveis quantitativas podem ser de ambos os tipos, mas na



prática são tratadas como contínuas se elas podem assumir um grande número de valores.

A maioria das pesquisas em ciências sociais se vale de **estudos observacionais**, que utilizam sujeitos disponíveis para observar as variáveis de interesse. Devemos ter cautela na tentativa de conduzir uma análise inferencial com os dados desses estudos. Os métodos de estatística inferencial requerem **amostras probabilísticas**, que incorporam a aleatorização de alguma forma. A amostragem aleatória permite o controle sobre a quantidade do **erro amostral**, que descreve como os resultados podem variar de amostra para amostra. As amostras aleatórias são mais prováveis de serem representativas da população do que as amostras não probabilísticas, como as amostras de voluntários.

- Para o plano de **amostra aleatória simples**, cada amostra possível de ta-

manho  $n$  tem a mesma chance de ser selecionada.

- Aqui estão outros exemplos de amostragem probabilística: A amostragem aleatória **sistemática** toma cada  $k$ -ésimo sujeito da lista do plano amostral. A amostragem aleatória **estratificada** divide a população em grupos (estratos) e coleta uma amostra aleatória de cada estrato. A amostragem aleatória **por conglomerados** coleta uma amostra aleatória de conglomerados de sujeitos (como quarteirões de uma cidade) e usa os sujeitos desses conglomerados como amostra. A amostragem **multistágio** usa uma combinação desses métodos.

O Capítulo 3 introduz as estatísticas para descrever amostras e os parâmetros correspondentes para descrever as populações. Por conseguinte, seu foco é na *estatística descritiva*.

- (g) Proprietário de um computador pessoal (sim, não).
- (h) Número de pessoas com Aids que você conhece (0, 1, 2, 3, 4 ou mais).
- (i) Forma do casamento de uma sociedade (monogamia, poligamia, poliandria).

2.3 Que escala de mensuração (nominal, ordinal ou intervalar) é mais apropriada para:

- (a) Atitude em relação à legalização da maconha (a favor, neutro, contrário).
- (b) Sexo (masculino, feminino).
- (c) Número de filhos da família (0, 1, 2, ...).
- (d) Afiliação partidária (Democrata, Republicano, Independente).
- (e) Afiliação religiosa (católico, judeu, protestante, muçulmano, outra).
- (f) Filosofia política (muito liberal, um pouco liberal, moderado, um pouco conservador, muito conservador).

## Praticando o básico

2.1 Explique a diferença entre:

- (a) As variáveis discretas e contínuas.
- (b) As variáveis categóricas e quantitativas.
- (c) As variáveis nominais e ordinais.

Por que essas distinções são importantes para a análise estatística?

2.2 Identifique cada variável como categórica ou quantitativa:

- (a) Número de animais de estimação em uma família.
- (b) Região da residência.
- (c) Escolha do carro (nacional ou importado).
- (d) Distância (em milhas) da casa para o trabalho.
- (e) Escolha da dieta (vegetariana, não vegetariana).
- (f) Tempo gasto no mês anterior navegando na internet.

ly *Telegraph* em junho de 2006 fez várias perguntas a uma amostra aleatória de 1962 adultos britânicos sobre a sua imagem sobre os Estados Unidos. Uma pergunta foi: "Como você avaliaria George W. Bush como um líder mundial?" As escolhas possíveis eram (um líder importante, um líder razoavelmente satisfatório, um líder bem medíocre, um líder horrível).

(a) Trata-se de uma variável nominal ou ordinal de quatro categorias? Por quê?

(b) Essa variável é discreta ou contínua? Por quê?

(c) Dos 93% da amostra que responderam, os percentuais nas quatro categorias foram 1% (um líder importante), 16%, 37%, 46% (um líder horrível). Esses valores são estatísticas ou parâmetros? Por quê?

2.8 Um levantamento de dados pediu aos sujeitos para avaliar cinco assuntos de acordo com sua importância na determinação da intenção de voto para senador dos Estados Unidos, usando a escala (muito importante, de certa forma importante, sem importância). Os assuntos são política externa, desemprego, inflação, corrida armamentista e direitos civis. A avaliação pode ser tratada como cinco variáveis: avaliação da política externa, avaliação do desemprego e assim por diante. Essas variáveis representam que tipo de mensuração?

2.9 Quais das seguintes variáveis poderiam, teoricamente, ser mensuradas em uma escala contínua? (a) Método de concepção usado, (b) período de tempo de residência em um estado, (c) tempo no cumprimento de uma tarefa, (d) inteligência, (e) autoritarismo, (f) alienação, (g) país de residência.

2.10 Quais das seguintes variáveis são contínuas quando as mensurações são tão perfeitas quanto possível? (a) Idade da mãe, (b) número de filhos em uma família, (c) renda do cônjuge, (d) população das cidades, (e) latitude e longitude das cidades, (f) distância da casa até o local

(g) Anos de estudos completos (0, 1, 2, 3, ...).

(h) Grau de escolaridade mais alto (nenhum, ensino médio, graduado, mestrado, doutorado).

(i) Formação universitária (educação, antropologia, física, sociologia, ...).

(j) Escore de um teste (0 - 100 intervalo para os escores).

(k) Situação no emprego (empregado em período integral, empregado meio turno, desempregado).

2.4 Qual escala de mensuração é mais apropriada para:

(a) Ocupação (encanador, professor, secretária, ...).

(b) Situação ocupacional (operário, funcionário administrativo).

(c) Status social (classe baixa, média, alta).

(d) Taxa de assassinato no estado (número de assassinatos por 1000 da população).

(e) Tamanho da população de um país (número de pessoas).

(f) Taxa de crescimento de uma população (em percentual).

(g) Tamanho da comunidade (rural, cidade pequena, cidade grande).

(h) Renda anual (milhares de dólares por ano).

(i) Atitude em relação à ação afirmativa (favorável, neutro, não favorável).

(j) Número de parceiros sexuais.

2.5 Qual escala de mensuração é mais apropriada para a "educação obtida" mensurada como:

(a) Número de anos (0, 1, 2, 3, ...).

(b) Nível de graduação (ensino elementar, ensino fundamental, ensino médio, faculdade, pós-graduação).

(c) Tipo de escola (escola pública, escola privada).

2.6 Dê um exemplo de uma variável que é (mensurada numa) (a) categórica, (b) quantitativa, (c) escala ordinal, (d) escala nominal, (e) discreta, (f) contínua, (g) quantitativa e discreta.

2.7 Uma pesquisa de opinião conduzida pela YouGov para o jornal britânico *The Dai-*

de trabalho. (g) número de línguas estrangeiras faladas.

**2.11** Uma turma tem 50 estudantes. Use a coluna dos primeiros dois dígitos da tabela de números aleatórios (Tabela 2.1) para selecionar uma amostra aleatória simples de três estudantes. Se os estudantes estão numerados de 01 a 50, quais são os números dos três estudantes selecionados?

**2.12** Um guia telefônico local tem 400 páginas com 130 nomes por página, um total de 52000 nomes. Explique como você poderia escolher uma amostra aleatória simples de 5 nomes. Use a segunda coluna da Tabela 2.1, um *software* ou uma calculadora. Selecione 5 números aleatórios para identificar os sujeitos da amostra.

**2.13** Diga se um experimento ou um estudo observacional seria o mais apropriado para investigar o seguinte:

- (a) Se (sim ou não) as cidades com taxas altas de desemprego tendem a ter taxas mais altas de crime.  
 (b) Se o Honda Accord ou o Toyota Camry é mais econômico, isto é, consome menos gasolina.  
 (c) Se (sim ou não) escores mais altos do GPA no curso universitário pertencem a estudantes que têm escores mais altos nos exames de ingresso ao curso.

(d) Se (sim ou não) um cupom especial preso no lado de fora de um catálogo torna o destinatário mais propável de solicitar produtos de uma empresa que vende pelo correio.

**2.14** Um estudo é planejado para estudar se o fumo passivo (ser exposto à fumaça do cigarro regularmente) acarreta altas taxas de câncer de pulmão.

- (a) Um estudo possível é coletar uma amostra de crianças, aleatoriamente selecionar metade delas para colocá-las em um ambiente onde elas são fumantes passivos e colocar a outra metade em um ambiente onde não são expostas à fumaça do cigarro. Então, 60 anos depois, a observação é se cada um

desenvolveu câncer no pulmão. Este estudo seria um estudo experimental ou um estudo observacional? Por quê?

- (b) Por muitas razões, incluindo ética e tempo, não é possível conduzir o estudo em (a). Descreva uma forma que seja possível e indique se o estudo seria experimental ou observacional.

**2.15** A Tabela 2.2 mostra o resultado da eleição presidencial de 2000 e as previsões de várias organizações nos dias anteriores à eleição. Os tamanhos das amostras utilizadas foram de aproximadamente 2000 pessoas. Os percentuais para cada pesquisa de opinião não somam 100 em virtude dos indecisos ou dos eleitores a favor de outro candidato.

- (a) Que fatores causam as variações observadas entre as organizações de pesquisa?  
 (b) Identifique o erro amostral para o levantamento realizado pela Gallup.

☑ Tabela 2.2

Levantamento	Votos previstos		
	Gore	Bush	Nader
Gallup	46	48	4
Harris	47	47	5
ABC	45	48	3
CBS	45	44	4
NBC	44	47	3
Pew Research	47	49	4
Votos Reais	48,4	47,9	2,7

Fonte: [www.hrcpp.org/](http://www.hrcpp.org/)

**2.16** A BBC, na Grã-Bretanha, solicitou aos telespectadores que ligassem para a TV e indicassem seu poema favorito. Dos mais de 7500 telefonemas, mais do que a metade votou no poema *If*, de Rudyard Kipling. A BBC relatou que este poema foi evidentemente o favorito.

- (a) Explique o que significa chamar essa amostra de uma "amostra voluntária".  
 (b) Se a BBC realmente queria determinar o poema favorito dos britânicos, como poderia fazer com mais confiança?

**2.17** Uma pesquisa de opinião da Roper foi

delineada para determinar o percentual de americanos que apresentam dúvidas sobre a existência do holocausto nazista. Em resposta à pergunta: "É ou não possível que o extermínio de judeus, pelos nazistas, nunca tenha ocorrido?", 22% disseram que era possível que o holocausto, de fato, não tivesse acontecido. A Organização Roper, mais tarde, admitiu que a pergunta foi expressa de uma maneira confusa. Quando a pesquisa de opinião perguntou: "Parece possível a você que o extermínio de judeus pelos nazistas nunca tenha acontecido ou você tem certeza de que aconteceu?", somente 1% disse que era possível que ele nunca tivesse acontecido. Use esse exemplo para explicar o conceito de resposta tendenciosa.

**2.18** Considerando o Exercício 2.12 sobre a seleção de 5 nomes, de 52000, em 400 páginas de um catálogo telefônico:

- (a) Selecione cinco números para identificar os sujeitos para uma amostra aleatória sistemática de tamanho cinco.  
 (b) A amostragem por conglomerados é aplicável? Como ela poderia ser realizada e quais seriam as vantagens e desvantagens?

**2.19** Você planeja realizar um levantamento de opinião em uma população de 5000 estudantes de uma faculdade para comparar as proporções de homens e mulheres que acreditam que a idade legal para o consumo de álcool deveria ser baixada para 18 anos. Explique como você irá proceder se quiser uma amostra aleatória sistemática de 100 estudantes.

**2.20** Você planeja realizar um levantamento entre os 3500 estudantes universitários matriculados na Universidade de Rochester para comparar as proporções de estudantes femininos e masculinos que gostariam de ver os Estados Unidos terem uma presidente mulher.

- (a) Suponha que você use números aleatórios para selecionar os estudantes, mas você para na seleção das mulheres tão logo você obtenha 40 e na se-

leção de homens tão logo você tenha igualmente 40. A amostra resultante é uma amostra aleatória simples? Por que sim ou por que não?

- (b) Que tipo de amostra é a obtida em (a)? Que vantagens ela pode ter sobre a amostra aleatória simples?

**2.21** Conglomerados versus estratos:

- (a) Com uma amostra aleatória por conglomerados, você coleta uma amostra dos (i) conglomerados? (ii) dos sujeitos dentro de cada conglomerado?  
 (b) Com uma amostra aleatória estratificada, você coleta uma amostra dos (i) estratos? (ii) dos sujeitos dentro de cada estrato?  
 (c) Resume as principais diferenças entre a amostragem por conglomerados e a amostragem estratificada em termos de amostrar os grupos ou os sujeitos dentro dos grupos que fornecem os conglomerados ou estratos.

### Conceitos e aplicações

**2.22** Consulte o arquivo de dados *Student Survey* introduzido no Exercício 1.11 (página 25). Para cada variável no conjunto de dados indique se ela é:

- (a) Categórica ou quantitativa.  
 (b) Nominal, ordinal ou intervalar.

**2.23** Repita o exercício anterior para o arquivo de dados citado no Exercício 1.12 (página 26).

**2.24** Você está realizando um estudo para determinar os fatores que estão relacionados ao bom desempenho acadêmico na sua faculdade.

- (a) Descreva como você poderia selecionar uma amostra de 100 estudantes para o estudo.  
 (b) Liste algumas variáveis que você iria mensurar. Para cada uma forneça a escala que você iria usar para mensurá-la e indique se uma análise estatística poderia tratá-la como (i) categórica ou quantitativa, (ii) nominal, ordinal ou intervalar, (iii) contínua ou discreta.

(c) Dê um exemplo de uma pergunta da pesquisa que poderia ser feita usando os dados das variáveis que você listou em (b).

**2.25** Com a amostragem por quotas um pesquisador para numa esquina de uma rua e conduz entrevistas até obter uma quota representando os tamanhos relativos de vários grupos na população. Por exemplo, a quota poderia ser 50 trabalhadores de fábricas, 100 donas de casa, 60 idosos, 30 negros e assim por diante. Este é um método de amostragem probabilística ou não probabilística? Explique e discuta as vantagens potenciais ou desvantagens deste método. (Pesquisadores da opinião pública profissionais como a Gallup usaram este método até 1948, quando derrotar Truman numa vitória esmagadora na eleição presidencial.)

**2.26** Quando a organização de pesquisa da opinião pública Yankelovich perguntou: "Leis deveriam ser aprovadas para eliminar todas as possibilidades de interesses particulares darem grandes somas de dinheiro aos candidatos?", 80% dos entrevistados da amostra responderam *sim*. Quando eles apresentaram a pergunta: "Leis deveriam ser aprovadas para proibir grupos de interesse de contribuir às campanhas ou os grupos têm o direito de contribuir para o candidato que eles apoiam?", somente 40% disseram *sim*. Explique o que este exemplo ilustra e use sua resposta para evidenciar a diferença entre o erro amostral e a resposta tendenciosa nos resultados de levantamento de dados.

**2.27** Em cada uma das seguintes situações, avalie se o método da seleção da amostra é apropriado para obter informação sobre a população de interesse. Como você aprimoraria o plano amostral?

(a) Um jornal quer determinar se seus leitores acreditam que os gastos do governo deveriam ser reduzidos cortando os benefícios dos deficientes físicos. Eles fornecem um endereço na internet para os leitores votarem *sim* ou *não*. Baseado em 1434

votos pela internet, eles relataram que 93% dos moradores da cidade acreditam que os benefícios deveriam ser reduzidos.

(b) Uma congressista relata que as cartas enviadas para o seu gabinete estão vencendo de 3 a 1 em oposição à aprovação da lei de um controle mais rígido de armas. Ela conclui que aproximadamente 75% dos seus constituintes se opõem às leis do controle mais rígido de armas.

(c) Uma professora de antropologia queria comparar as atitudes em relação ao sexo antes do casamento, dos alunos de ciências físicas e de ciências sociais. Para tanto, ela administrou um questionário para sua turma grande de Antropologia, Sexualidade Humana Comparativa. Ela não encontrou uma diferença apreciável entre os alunos das ciências físicas e ciências sociais quanto às suas atitudes, assim ela concluiu que os dois grupos de estudantes eram aproximadamente os mesmos na sua aceitação relativa ao sexo antes do casamento.

(d) Um questionário foi enviado pelo correio para uma amostra aleatória simples de 500 domicílios de uma cidade. Dez retornaram como endereços errados, 63 retornaram completos e o restante não retornou. O pesquisador analisou os 63 casos e relatou que eles representavam uma "amostra aleatória simples dos domicílios da cidade".

(e) Uma diretora de uma grande escola de ensino médio está interessada nas atitudes dos estudantes em relação a um teste de desempenho proposto para determinar se um estudante deveria se formar. Ela lista todas as aulas do primeiro período, designando um número para cada uma. Então, usando uma tabela de números aleatórios, ela escolhe uma turma ao acaso e entrevista cada estudante daquela turma sobre o teste proposto.

**2.28** Uma análise de conteúdo de um jornal diário estuda o percentual do espaço do jornal reservado para notícias sobre entretenimento. O plano amostral consiste em edições diárias do jornal do ano anterior. Que problema potencial pode ocorrer se for utilizada uma amostra sistemática com período igual a 7 ou múltiplo de 7?

**2.29** Em uma amostra aleatória sistemática, cada sujeito tem a mesma chance de ser selecionado, mas a amostra não é uma amostra aleatória simples. Explique.

**2.30** Com uma amostra de tamanho 100, nós queremos comparar as opiniões dos nativos americanos a outros norte-americanos sobre a legalização do jogo. Por que seria útil coletar uma amostra aleatória estratificada não proporcional?

**2.31** Em uma amostra aleatória por conglomerados, com conglomerados do mesmo tamanho, cada sujeito tem a mesma chance de ser selecionado. Entretanto, a amostra não é aleatória simples. Explique.

**2.32** Encontre um exemplo de resultados de uma pesquisa de opinião pela internet. Você acredita nos resultados da pesquisa de opinião? Se não, explique.

**2.33** Para mostrar os residentes das casas de repouso registradas em Yorkshire, Reino Unido, eu construo uma lista de todas as casas de repouso do condado, as quais numero de 1 a 100. Iniciando aleatoriamente, escolho cada décima casa da lista, terminando com 11 casas. Então, obtenho listas dos residentes destas 11 casas e seleção uma amostra aleatória simples de cada lista. Que tipos de amostragens eu usel?

Para as questões de múltipla escolha 2.34 – 2.37, seleccione a melhor resposta.

**2.34** Uma amostra aleatória simples de tamanho  $n$  é uma que:

- (a) cada  $n$ ésimo membro é selecionado da população.  
 (b) cada amostra possível de tamanho  $n$  tem a mesma chance de ser selecionada.

(c) há exatamente a mesma proporção de mulheres na amostra do que a existente na população.

(d) você continua amostrando até que tenha um número fixo de pessoas que apresentam as mesmas características (por exemplo, homens, mulheres).

(e) um membro de um grupo minoritário particular de uma população é menos provável de ser escolhido do que um membro de um grupo majoritário particular.

(f) Todas as opções listadas acima.

**2.35** Se usarmos números aleatórios para coletar uma amostra aleatória simples de 50 estudantes de uma população de 20000 estudantes de uma universidade,

(a) é impossível conseguir o número aleatório 11111, porque ele não é uma sequência aleatória.

(b) se obtivermos 20001 para o primeiro número aleatório, então, para o segundo número aleatório, aquele número é menos provável de ocorrer do que qualquer outro número aleatório de cinco dígitos.

(c) o sorteio de 12345 não é mais nem menos provável do que o sorteio de 11111.

(d) visto que a amostra é aleatória, então é impossível que ela não seja representativa se ela for composta apenas por mulheres.

**2.36** Crosson (1994, p. 168) descreveu análises de estudos médicos publicados envolvendo tratamentos para ataques cardíacos. Nos estudos que envolveram aleatorização e forte controle contra a tendenciosidade, a nova terapia utilizada melhorou o tratamento em 9% das vezes. Em estudos sem aleatorização ou controles de tendenciosidade, a nova terapia melhorou o tratamento em 58% das vezes. Seleccione a(s) resposta(s) correta(s).


(a) Esse resultado sugere que é melhor não usar a aleatorização em estudos médicos porque é muito difícil mostrar que ideias novas são benéficas.

- (b) Muitos artigos de jornais que sugerem que um alimento, medicamento ou agente ambiental em particular é nocivo ou benéfico devem ser vistos com ceticismo, a não ser que saibamos mais sobre o delineamento e a análise estatística utilizados no estudo.
- (c) Esse resultado sugere que você deve ser cético quanto aos resultados de estudos médicos publicados que não sejam estudos aleatórios e controlados.
- (d) Controlar a tendenciosidade tanto suspeita quanto insuspeita é necessário na pesquisa médica, mas não na pesquisa social, porque as ciências sociais lidam com verdades subjetivas em vez de objetivas.
- 2.37 Um PSG recente perguntou às pessoas se elas apoiavam a legalização do aborto em cada uma de sete diferentes circunstâncias. O percentual que apoiava a legalização do aborto variou entre 45% (se a mulher o desejava por qualquer motivo) a 97% (se a saúde da mulher está seriamente em perigo devido à gravidez). Isso indica que:
- (a) as respostas podem depender muito da maneira como a pergunta é formulada.
- (b) os levantamentos amostrais lidam com uma pequena parte da população e nunca podemos confiar neles.
- (c) a amostra não precisa ser selecionada aleatoriamente.
- (d) a amostra deve ter problemas de tendenciosidade como resultado de as pessoas não dizerem a verdade.
- 2.38 Um pesquisador está na entrada de um *shopping* popular realizando entrevistas. Verdadeiro ou falso: como não podemos prever quem será entrevistado, a amostra obtida é um exemplo de amostra aleatória. Explique.
- 2.39 Em um concurso recente de Miss Americana, os telespectadores podiam votar se cancelavam o desfile de traje de banho ligando para um número fornecido pelo canal de televisão. Aproximadamente 1 milhão de telespectadores ligaram e registraram a sua opinião, dos quais 79% disseram que queriam ver as candidatas vestidas como beladades em traje de banho. Verdadeiro ou falso: visto que todos tiveram a chance de ligar, trata-se de uma amostra aleatória simples de todos os telespectadores desse programa. Explique.
- \*2.40 Uma escala intervalar para a qual as proporções são válidas é chamada de uma *escala de proporções*. Tais escalas têm um ponto 0 bem definido, assim, por exemplo, podemos considerar o valor 20 como o dobro da quantidade do valor 10. Explique por que a renda anual é mensurada em uma escala de proporções, mas a temperatura (em Fahrenheit ou Centígrado) não é. O QI, como uma medida de inteligência, é uma variável expressa em uma escala de proporções?

## NOTAS

- 1 D. M. Wilbur, *Public Perspective*, disponível em <http://roperweb.ropercenter.uconn.edu>, Maio-Junho de 1993.
- 2 Coluna de T. Friedman, *New York Times*, 2 de março de 2006.
- 3 Veda Crosson (1994).
- 4 *Washington Post*, 26 de junho de 1995.
- 5 *Newsweek*, 25 de julho de 1994.
- 6 *Fonte: A Mathematician Reads the Newspaper*, por J. A. Paulos, Basic Books, 1995, p. 15.

# ESTATÍSTICA DESCRITIVA



Vimos que os métodos estatísticos são *descritivos* ou *inferenciais*. O propósito da estatística descritiva é resumir os dados, facilitar a assimilação da informação. Este capítulo apresenta os métodos básicos da estatística descritiva.

Apresentamos, em primeiro lugar, tabelas e gráficos que descrevem os dados mostrando o número de vezes em que vários resultados ocorrem. As variáveis quantitativas também apresentam duas características-chave para descrevê-las numericamente:

- O **centro** dos dados – uma observação típica.
- A **variabilidade** dos dados – a dispersão em torno do centro.

Aprenderemos a descrever dados quantitativos com estatísticas que resumem o centro e a variabilidade e, finalmente, com estatísticas que especificam certas posições nos conjuntos de dados que resumem tanto o centro quanto a variabilidade.

## 3.1 DESCREVENDO DADOS COM TABELAS E GRÁFICOS

As tabelas e gráficos são úteis para todos os tipos de dados. Começaremos com as variáveis categóricas.

### Frequências relativas: dados categóricos

Para dados categóricos listamos as categorias e mostramos a frequência (o número

de observações) em cada categoria. Para facilitar a comparação de diferentes categorias, relatamos, também, as proporções ou percentuais, também chamados de **frequências relativas**.

#### Frequência relativa

A frequência relativa para uma categoria é a proporção ou o percentual das observações que pertencem àquela categoria.

A *proporção* é igual ao número de observações em uma dada categoria dividida pelo número total de observações. É um número entre 0 e 1 que expressa o percentual de observações naquela categoria.

#### EXEMPLO 3.1 Estrutura domiciliar norte-americana

A Tabela 3.1 lista tipos diferentes de domicílios nos Estados Unidos em 2005. De 111,1 milhões de domicílios, por exemplo, 24,1 milhões eram de um casal com filhos. A proporção  $24,1/111,1 = 0,22$  era de um casal com filhos.

O percentual é a proporção expressa em relação a 100, isto é, a vírgula é movida duas posições para a direita. Por exemplo, 0,22 é a proporção de famílias casadas com filhos, então o percentual é  $0,22 = 22\%$ . A Tabela 3.1 mostra as proporções e os percentuais para todas as categorias.

A soma das proporções é igual a 1,00. A soma dos percentuais é igual a 100. (Na