



7

COMPARAÇÃO DE DOIS GRUPOS

Da Seção 3.5 (página 73), lembre que uma variável de saída sobre a qual as comparações são feitas é chamada de **variável resposta**. A variável que define o grupo é chamada de **variável explicativa**. Na Tabela 7.1 o tempo gasto cozinhando e limpando é a variável resposta. O sexo do responsável é a variável explicativa.

Amostras dependentes e independentes

Alguns estudos compararam médias ou proporções em dois ou mais pontos no tempo. Por exemplo, um **estudo longitudinal** observa sujeitos várias vezes. Um exemplo é o Framingham Heart Study, que a cada dois anos, desde 1948, observa muitas características de saúde em mais de 5000 adultos de Framingham, Massachusetts.

As amostras que contêm os mesmos sujeitos são ditas **dependentes**. Em um sentido amplo, duas amostras são **dependentes** quando uma equiparação natural ocorre entre cada sujeito nas duas amostras. Geralmente isso acontece quando cada amostra tem os mesmos sujeitos. Mas a equiparação pode também ocorrer quando as duas amostras têm sujeitos diferentes. Um exemplo é a comparação do trabalho de casa de maridos e esposas, os maridos formando uma amostra e suas esposas, a outra.

Mais comumente, as comparações usam **amostras independentes**. Isso significa que as observações em uma amostra são *independentes* daquelas da outra amostra. Os sujeitos nas duas amostras são diferentes e não existe equiparação entre amostras. Um exemplo é a Tabela 7.1. Os sujeitos foram selecionados aleatoriamente e então classificados quanto ao sexo e mensurados em relação ao tempo por eles gasto em diversas atividades. As amostras de homens e mulheres são independentes. Suponha que você planeja analisar se um programa com tutoria melhora o entendimento de matemática. O delineamento de um estudo administra um teste em uma amostra de estudantes antes e depois do programa. A amostra dos escores resultantes do teste após o programa é, então, *dependente* porque as duas amostras são formadas pelos mesmos sujeitos.

Outro delineamento de um estudo divide aleatoriamente a classe dos estudantes em dois grupos, um dos quais participa do programa com tutoria (o grupo *experimental*) e o outro grupo não (o grupo de *controle*). Após o curso, ambos os grupos fazem um teste em matemática e os escores médios são comparados. As duas amostras são, portanto, *independentes* porque contêm sujeitos diferentes e não existe equiparação entre as amostras.

Esses dois estudos são *experimentais*. Como foi mencionado no final da Seção 2.2 (página 30), muitos estudos das ciências sociais são, ao contrário, *observacionais*. Por exemplo, muitas comparações dos grupos resultam da divisão da amostra em subamostras de acordo com a classificação em uma variável, como sexo, raça ou partido político. A Tabela 7.1 é um exemplo disso. Tais casos são exemplos de estudos *transversais*, que usam um único levantamento de dados para comparar grupos. Se toda a amostra foi selecionada aleatoriamente, então as subamostras são amostras aleatórias *independentes* das sub-populações correspondentes.

Por que distinguimos entre amostras *independentes* e *dependentes*? Porque as fórmulas do erro padrão para as estatísticas que comparam médias ou comparam proporções são diferentes para os dois tipos de amostras. Com amostras dependentes, respostas equiparadas provavelmente estão associadas. No estudo sobre o programa de tutoria, os estudantes que tiveram um desempenho relativamente bom em um exame provavelmente tendem a ter um desempenho bom no segundo exame. Isso afeta o erro padrão das estatísticas na comparação dos grupos.

A comparação de dois grupos é um tipo muito comum de análise nas ciências sociais e comportamentais. Um estudo pode comparar a renda média para homens e mulheres que têm empregos e experiências similares. Outro estudo pode comparar a proporção de norte-americanos e canadenses que são a favor de leis de controle de armas de fogo. As médias são comparadas para as variáveis quantitativas e as proporções para as variáveis categóricas.

A Seção 7.1 introduz alguns conceitos básicos para a comparação de grupos. A Seção 7.2 ilustra esses conceitos para a comparação de proporções, e a Seção 7.3 para a comparação de médias. O restante do capítulo mostra alguns métodos alternativos úteis para casos especiais.

Análise bivariada com variáveis resposta e explicativa

Dois grupos sendo comparados constuem uma variável binária – uma variável que tem somente duas categorias é, algumas vezes, também chamada de **dicotómica**. Na comparação do tempo médio do trabalho doméstico, homens e mulheres são duas categorias da variável binária, sexo. Os métodos para comparar os dois grupos são os casos especiais dos métodos estatísticos **bivariados** – uma variável de saída de algum tipo é analisada para cada categoria de uma variável de entrada.

☒ Tabela 7.1 Minutos diários gastos cozinhando e limpando por homens e mulheres que trabalham em período integral na Grã-Bretanha

| Sexo | Tamanho da amostra | Minutos cozinhando e limpando | |
|----------|--------------------|-------------------------------|---------------|
| | | Média | Desvio padrão |
| Homens | 1219 | 23 | 32 |
| Mulheres | 733 | 37 | 16 |

Diferenças de estimativas e seu erro padrão

Para comparar duas populações, podemos estimar a diferença entre seus parâmetros. Para comparar as médias populacionais μ_1 e μ_2 , tratamos $\mu_2 - \mu_1$ como um parâmetro e o estimamos pela diferença das médias amostrais, $\bar{y}_2 - \bar{y}_1$. Para a Tabela 7.1, a diferença estimada entre o tempo médio populacional diário de cozinhar e limpar para homens e mulheres é igual a $\bar{y}_2 - \bar{y}_1 = 37 - 23 = 14$ minutos.

A distribuição amostral do estimador $\bar{y}_2 - \bar{y}_1$ tem valor esperado $\mu_2 - \mu_1$. Para amostras aleatórias grandes ou para amostras com distribuições normais, esta distribuição amostral tem uma forma normal, como é apresentado na Figura 7.1. Uma estimativa tem um erro padrão que descreve quanto precisamente ele estima um parâmetro. Da mesma forma ocorre para a diferença entre estimativas de duas amostras que apresentam um erro padrão. Para a Tabela 7.1, o erro padrão da distribuição amostral de $\bar{y}_2 - \bar{y}_1$ descreve quão precisamente $\bar{y}_2 - \bar{y}_1 = 14$ estima $\mu_2 - \mu_1$. Se muitos estudos tivessem sido conduzidos na Grã-Bretanha comparando o tempo diário cozinhar e limpando para homens e mulheres, a estimativa $\bar{y}_2 - \bar{y}_1$ não teria sido igual a 14 minutos para cada

um deles. A estimativa teria variado de estudo para estudo. O erro padrão descreve a variabilidade das estimativas de estudos potenciais diferentes do mesmo tamanho. A seguinte regra geral permite encontrar o erro padrão quando comparamos estimativas de amostras independentes:

Erro padrão da diferença entre duas estimativas

Para duas estimativas de amostras independentes que têm erros padrão estimados ep_1 e ep_2 , a distribuição amostral da sua diferença tem um erro padrão estimado $= \sqrt{(ep_1)^2 + (ep_2)^2}$.

Cada estimativa tem erro amostral as variabilidades se somam para determinar o erro padrão da diferença das estimativas. A fórmula do erro padrão para amostras dependentes difere desta fórmula e a Seção 7.4 a apresenta. Lembre que o erro padrão estimado de uma média amostral é igual a

$$ep = \frac{s}{\sqrt{n}}$$

onde s é o desvio padrão da amostra. Considere n_1 o tamanho da primeira amostra e n_2 da segunda. Considere s_1 e s_2 os desvios padrão das duas amostras respectivamente. A diferença $\bar{y}_2 - \bar{y}_1$ entre duas médias

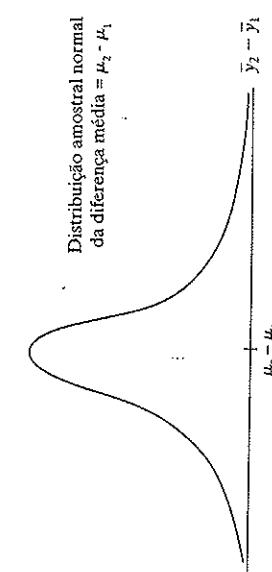


Figura 7.1 Para amostras aleatórias, a distribuição amostral da diferença entre as médias amostrais $\bar{y}_2 - \bar{y}_1$ é aproximadamente normal em torno de $\mu_2 - \mu_1$.

amostrais, de amostras independentes, tem o erro padrão estimado igual a:

$$ep = \sqrt{(ep_1)^2 + (ep_2)^2} = \sqrt{\frac{s_1^2}{n_1} + \frac{s_2^2}{n_2}}.$$

A razão dos parâmetros

Para exemplo, da Tabela 7.1, o erro padrão estimado da diferença em minutos entre as médias amostrais do tempo de cozinhar e limpar para mulheres e homens é igual a:

$$\begin{aligned} ep &= \sqrt{\frac{s_1^2}{n_1} + \frac{s_2^2}{n_2}} \\ &= \sqrt{\frac{(32)^2}{1219} + \frac{(16)^2}{733}} = 1.1. \end{aligned}$$

Para amostras grandes, a estimativa $\bar{y}_2 - \bar{y}_1$ não iria variar muito de estudo para estudo.

Note-se que o erro padrão da diferença é maior do que o erro padrão para cada estimativa individualmente. Por que isso? Em termos práticos, $(\bar{y}_2 - \bar{y}_1)$ geralmente está mais longe de $(\mu_2 - \mu_1)$ do que \bar{y}_1 está de μ_1 ou \bar{y}_2 está de μ_2 . Por exemplo, suponha que $\mu_1 = \mu_2 = 30$ (desconhecido para nós), mas as médias amostrais são $\bar{y}_1 = 23$ e $\bar{y}_2 = 37$. Então, os erros da estimativa seriam

$$\begin{aligned} \bar{y}_1 - \mu_1 &= 23 - 30 = -7 \text{ e} \\ \bar{y}_2 - \mu_2 &= 37 - 30 = 7, \end{aligned}$$

cada estimativa se distanciando 7 unidades da hipótese nula. Mas a estimativa $(\bar{y}_2 - \bar{y}_1) = 37 - 23 = 14$ está 14 de $(\mu_2 - \mu_1) = 0$. O erro de tamanho 14 para a diferença é maior do que o erro de tamanho 7 para cada média individualmente. Suponha que uma média amostral que está 7 unidades distante da média populacional esteja no final da cauda de uma distribuição amostral normal da diferença média $\mu_2 - \mu_1$.

da diferença entre as médias populacionais está no final da cauda da distribuição amostral de $\bar{y}_2 - \bar{y}_1$.

Outra forma de comparar duas proporções ou duas médias usa a sua razão. A razão é igual a 1,0 quando os parâmetros são iguais. As razões distantes de 1,0 representam efeitos maiores.

Na Tabela 7.1, a razão da média amostral do tempo de cozinhar e limpar para mulheres e homens é $37/23 = 1,61$. A média amostral para as mulheres é 1,61 vezes maior que a média amostral para homens.

Isso também pode ser expresso dizendo que a média para mulheres é 61% maior

do que a média dos homens.

A razão de duas proporções é geralmente chamada de risco relativo, porque geralmente é usada nas aplicações de saúde pública para comparar razões de um resultado não desejado entre dois grupos.

A razão é geralmente mais informativa do que a diferença quando as duas proporções estão próximas de zero.

Por exemplo, de acordo com dados recentes das Nações Unidas, a taxa anual de homicídios com armas de fogo é 62,4 por milhão de residentes nos Estados Unidos e 1,3 por milhão de residentes na Grã-Bretanha.

Na forma de proporção, os resultados são

0,000624 nos Estados Unidos e 0,000013 na Grã-Bretanha. A diferença entre as proporções é de $0,000624 - 0,000013 = 0,000611$, extremamente pequena. Em contrapartida, a razão é $0,000624/0,000013 = 624/13 = 48$. A proporção de pessoas mortas por armas de fogo nos Estados Unidos foi 48 vezes a proporção na Grã-Bretanha. Neste sentido, o efeito é grande.

Um software pode formar um intervalo de confiança para uma razão populacional de médias ou proporções. As fórmulas são complexas e não iremos cobri-las neste livro.

7.2 DADOS CATEGÓRICOS: COMPARANDO DUAS PROPORÇÕES

Vamos, agora, aprender como comparar as proporções de forma inferencial. Considere π_1 a representação da proporção para a primeira população e π_2 a proporção para a segunda população. Considere $\hat{\pi}_1$ e $\hat{\pi}_2$ a representação das proporções amostrais. Você talvez queira revisar as Seções 5.2 (página 134) e 6.3 (página 182) sobre inferências para proporções para o caso de uma amostra.

EXEMPLO 7.1 A oração ajuda pacientes de cirurgia coronária?

Um estudo usou pacientes em seis hospitais dos Estados Unidos que passaram por uma cirurgia de ponte de safena.² Os pacientes foram aleatoriamente designados a dois grupos. Para um grupo, voluntários cristãos foram instruídos para rezar por uma cirurgia bem-sucedida com uma recuperação rápida e sem complicações. A oração iniciou na noite anterior à cirurgia e continuou por duas semanas. A resposta foi a ocorrência de complicações médicas que ocorreram em um período de 30 dias após a cirurgia. A Tabela 7.2 resume os resultados.

Existe uma diferença nas taxas de complicações pós-operatórias entre os dois grupos? Considere π_1 a probabilidade de complicações para os pacientes que tiveram um grupo de oração e π_2 dos que não tiveram. Considerando a Tabela 7.2, as proporções amostrais são iguais a:

$$\hat{\pi}_1 = \frac{315}{604} = 0,522, \quad \hat{\pi}_2 = \frac{304}{597} = 0,509.$$

Tabela 7.2 Complicações que ocorreram com pacientes que sofreram uma cirurgia cardíaca que tinham ou não um grupo de oração

| Oração | Complicações | Sem complicações | Total |
|--------|--------------|------------------|-------|
| Sim | 315 | 289 | 604 |
| Não | 304 | 293 | 597 |

Compararmos as probabilidades usando a sua diferença, $\pi_2 - \pi_1$. A diferença das proporções amostrais, $\hat{\pi}_2 - \hat{\pi}_1$, estimada $\hat{\pi}_2 - \pi_1$. Se n_1 e n_2 são relativamente grandes, o estimador $\hat{\pi}_2 - \hat{\pi}_1$ tem uma distribuição amostral que é aproximadamente normal. Veja a Figura 7.2. A média da distribuição amostral é o parâmetro $\pi_2 - \pi_1$ a ser estimado.

Da regra no quadro da Seção 7.1 (página 214), o erro padrão da diferença das proporções amostrais é igual à raiz quadrada da soma dos erros padrão ao quadrado de proporções amostrais separadas. Lembre que o erro padrão estimado de uma única proporção amostral é:

$$ep = \sqrt{\frac{\hat{\pi}_1(1 - \hat{\pi}_1)}{n_1} + \frac{\hat{\pi}_2(1 - \hat{\pi}_2)}{n_2}}.$$

Portanto, a diferença entre as duas proporções tem o erro padrão estimado igual a:

$$ep = \sqrt{(ep_1)^2 + (ep_2)^2} \\ = \sqrt{\frac{\hat{\pi}_1(1 - \hat{\pi}_1)}{n_1} + \frac{\hat{\pi}_2(1 - \hat{\pi}_2)}{n_2}}.$$

Para a Tabela 7.2, $\hat{\pi}_2 - \hat{\pi}_1$ tem o erro padrão estimado igual a:

$$ep = \sqrt{\frac{(0,522)(0,478)}{604} + \frac{(0,509)(0,491)}{597}} \\ = 0,0288.$$

Para amostras com esses tamanhos, a diferença de proporções amostrais não iria variar muito de estudo para estudo.

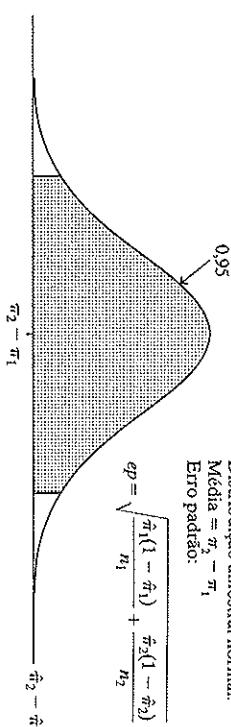


Figura 7.2 Para amostras aleatórias grandes, a distribuição amostral do estimador $\hat{\pi}_2 - \hat{\pi}_1$ da diferença de proporções é aproximadamente normal.

Intervalo de confiança para a diferença de proporções

Assim como com uma única proporção, o intervalo de confiança pega a estimativa por ponto, soma e subtraia a margem de erro que é um escoré-z vezes o erro padrão estimado, isto é

$$(\hat{\pi}_2 - \hat{\pi}_1) \pm 1,96(ep)$$

para o intervalo de 95% de confiança.

Intervalo de confiança para $\pi_2 - \pi_1$

Para amostras aleatórias grandes e independentes, um intervalo de confiança $\pi_2 - \pi_1$ entre duas proporções populacionais é:

$$(\hat{\pi}_2 - \hat{\pi}_1) \pm z(ep), \text{ onde}$$

$$ep = \sqrt{\frac{\hat{\pi}_1(1 - \hat{\pi}_1)}{n_1} + \frac{\hat{\pi}_2(1 - \hat{\pi}_2)}{n_2}}.$$

O escoré-z depende do nível de confiança. Ele vale 1,96 para uma confiança de 95%.

EXEMPLO 7.2 Oração e pacientes de cirurgia coronária (continuação)

Para a Tabela 7.2, estimamos a diferença $\pi_2 - \pi_1$ entre a probabilidade de complicações para os pacientes com e sem orações.

Visto que $\hat{\pi}_1 = 0,522$ e $\hat{\pi}_2 = 0,509$, a diferença estimada é igual a $\hat{\pi}_2 - \hat{\pi}_1 = -0,013$. Houve uma queda de 0,013 na proporção de complicações entre aqueles que não receberam orações.

Para determinar a precisão dessa estimativa, formamos um intervalo de confiança. Previamente determinamos o $ep = 0,0288$. Um intervalo de 95% de confiança para $\pi_2 - \pi_1$ é, então:

$$(\hat{\pi}_2 - \hat{\pi}_1) \pm 1,96(ep), \text{ ou } (0,509 - 0,522) \\ \pm 1,96(0,0288) = -0,013 \pm 0,057 \text{ ou } (-0,07, 0,04)$$

Parce que a diferença está próxima de 0, assim a probabilidade de complicações é similar para os dois grupos.

Interpretando um intervalo de confiança a partir da comparação de proporções

A amostra é grande o suficiente para usar a fórmula se pelo menos dez observações estão na categoria para a qual a proporção é estimada e pelo menos dez observações estão na outra. A maioria dos estudos facilmente satisfaz isso.

Quando o intervalo de confiança para $\pi_2 - \pi_1$ contém 0, como no exemplo anterior, é plausível que $\pi_2 - \pi_1 = 0$. Isto é, é possível que $\pi_1 = \pi_2$. Não existe evidência suficiente para concluir se π_1 ou π_2 é

maior. Para o intervalo de confiança para $\pi_2 - \pi_1$ de $(-0,07, 0,04)$, inferimos que π_2 pode ser tão menor quanto 0,07 ou tão maior quanto 0,04 do que π_1 .

Quando um intervalo de confiança para $\pi_2 - \pi_1$ contém somente valores *negativos*, isso sugere que $\pi_2 - \pi_1$ é negativo. Em outras palavras, inferimos que π_2 é menor do que π_1 . Quando um intervalo de confiança para $\pi_2 - \pi_1$ contém somente valores positivos, concluímos que $\pi_2 - \pi_1$ é positivo; isto é, π_2 é maior do que π_1 .

A denominação de Grupo 1 e Grupo 2 é feita de forma arbitrária. Se considerarmos o Grupo 1 como o sem oração em vez do grupo com oração, então a diferença estimada seria $+0,013$ em vez de $-0,013$. O intervalo de confiança teria sido $(-0,04, 0,07)$, os simétricos dos pontos extremos que obtivemos. Da mesma forma, não interessa se formarmos um intervalo de confiança para $\pi_2 - \pi_1$ ou para $\pi_1 - \pi_2$. Se o intervalo de confiança para $\pi_2 - \pi_1$ é $(-0,07, 0,04)$, então o intervalo de confiança para $\pi_1 - \pi_2$ é $(-0,04, 0,07)$.

A magnitude dos valores no intervalo de confiança diz a você quanto grande é qualquer diferença verdadeira. Se todos os valores no intervalo de confiança estão próximos de 0, como no intervalo $(-0,07, 0,04)$, inferimos que $\pi_2 - \pi_1$ é pequena, em termos práticos, mesmo se não for exatamente igual a 0.

Como no caso de uma amostra, também da amostra maiores contribuem para um ep menor, uma margem de erro menor e intervalos de confiança mais precisos (menores). Além disso, níveis de confiança mais altos geram intervalos de confiança maiores. Para o estudo da oração, um intervalo de 99% de confiança seria igual a $(-0,09, 0,06)$. Ele é mais amplo (menos preciso) do que um intervalo de 95% de confiança de $(-0,07, 0,04)$.

Testes de significância sobre $\pi_2 - \pi_1$
Para comparar as proporções populacionais π_1 e π_2 , um teste de significância espe-

cifica que $H_0: \pi_1 = \pi_2$. Para a diferença das proporções dos parâmetros, esta hipótese é $H_0: \pi_2 - \pi_1 = 0$, *nenhuma diferença ou nenhum efeito*.

Sob a suposição H_0 de que $\pi_1 = \pi_2$, estimamos o valor comum de π_1 e π_2 pela proporção amostral das duas amostras. Esse valor é indicado por $\hat{\pi}$. Para ilustrar, utilizando os dados da Tabela 7.2 do estudo da oração, tem-se: $\hat{\pi}_1 = 315/504 = 0,522$ e $\hat{\pi}_2 = 304/597 = 0,509$. Para as duas amostras consideradas como um todo, segue que:

$$\begin{aligned}\hat{\pi} &= (315 + 304)/(504 + 597) \\ &= 619/1201 = 0,515.\end{aligned}$$

A proporção $\hat{\pi}$ é chamada de *estimativa agrupada ou combinada*, porque agrupa observações das duas amostras.

A estatística-teste mensura o número de erros padrão entre a estimativa e o valor H_0 . Tratando $\pi_2 - \pi_1$ como o parâmetro, testamos se $\pi_2 - \pi_1 = 0$; isto é, o valor da hipótese nula do parâmetro $\pi_2 - \pi_1$ é 0. O valor estimado de $\pi_2 - \pi_1$ é $\hat{\pi}_2 - \hat{\pi}_1$. A estatística-teste é:

$$\begin{aligned}z &= \frac{\text{Estimativa} - \text{valor da hipótese nula}}{\text{Erro padrão}} \\ &= \frac{(\hat{\pi}_2 - \hat{\pi}_1) - 0}{\hat{\pi}_0}.\end{aligned}$$

Em vez de usar o erro padrão do intervalo de confiança, você deveria usar uma fórmula alternativa baseada na suposição declarada em H_0 de que $\pi_1 = \pi_2$. Usamos a notação ep_0 porque é um ep que ocorre na suposição de H_0 . Este erro padrão é:

$$\begin{aligned}ep_0 &= \sqrt{\frac{\hat{\pi}(1 - \hat{\pi})}{n_1} + \frac{\hat{\pi}(1 - \hat{\pi})}{n_2}} \\ &= \hat{\pi}(1 - \hat{\pi}) \left(\frac{1}{n_1} + \frac{1}{n_2} \right).\end{aligned}$$

Para os dados da Tabela 7.2, a estimativa para o erro padrão para o teste é igual a:

Tabelas de contingência e probabilidades condicionais

A Tabela 7.2 é um exemplo de uma **tabela de contingência**. Cada linha é uma categoria da variável explicativa (se houve oração) que define os dois grupos comparados. Cada coluna é uma categoria da variável resposta (se complicações ocorreram). As células da tabela contêm frequências para as quatro combinações possíveis dos resultados.

Os parâmetros π_1 e π_2 estimados usando a tabela de contingência são chamados de **probabilidades condicionais**. Esse termo se refere às probabilidades para uma variável resposta avaliada sob duas condições, a saber, os dois níveis da variável explicativa. Por exemplo, sob a condição de que estão sendo feitas orações para o sujeito, a probabilidade condicional de desenvolver complicações é estimada em $315/604 = 0,52$.

Esta seção estudou as variáveis respondidas binárias. Ao contrário, a variável resposta poderia ter várias categorias. Por exemplo, as categorias da resposta poderiam ser (sem complicações, complicações leves, complicações severas). Então, iríamos comparar os dois grupos em termos das probabilidades condicionais das observações em cada uma das três categorias. Da mesma forma, o número de grupos comparados poderia exceder a dois. O Capítulo 8 mostra como analisar tabelas de contingência que apresentam mais do que duas linhas ou colunas.

7.3 DADOS QUANTITATIVOS: COMPARANDO DUAS MÉDIAS

Para comparar duas médias da população μ_1 e μ_2 , podemos fazer inferências sobre a sua diferença. Seria interessante, talvez, revisar as Seções 5.3 (página 140) e 6.2 (página 172) sobre inferência para a média no caso de uma amostra.

Intervalo de confiança para $\mu_2 - \mu_1$

Para amostras aleatórias grandes ou pequenas de distribuições com populações normais, a distribuição amostral de $(\bar{Y}_2 - \bar{Y}_1)$ tem uma forma normal. Como de costume, a inferência para médias com erros padrão estimados usa a distribuição t para estatísticas-teste e para a margem de erro em intervalos de confiança. Um intervalo de confiança pega a estimativa por ponto, soma e subtrai a margem de erro que é um escorre- t vezes o erro padrão.

Intervalo de confiança para $\mu_2 - \mu_1$

Para amostras aleatórias independentes de dois grupos que têm distribuições populacionais normais, um intervalo de confiança para $\mu_2 - \mu_1$ é

$$(\bar{Y}_2 - \bar{Y}_1) \pm t(ep),$$

$$\text{onde } ep = \sqrt{\frac{s_1^2}{n_1} + \frac{s_2^2}{n_2}}.$$

O escorre- t é escolhido de modo a fornecer o nível de confiança desejado.

$$ep = \sqrt{\frac{s_1^2}{n_1} + \frac{s_2^2}{n_2}} \\ = \sqrt{\frac{(32)^2}{1219} + \frac{(16)^2}{733}} = 1.09.$$

A fórmula para os graus de liberdade para o escorre- t , chamada de *aproximação de Welch-Satterthwaite*, é complexa. Os gl dependem dos desvios padrão das amostras s_1 e s_2 assim como dos tamanhos das amostras n_1 e n_2 . Se $s_1 = s_2$ e $n_1 = n_2$, isto se simplifica a $gl = (n_1 + n_2 - 2)$. Esta é a soma dos valores dos gl para a inferioridade separada de cada grupo; isto é, $gl = (n_1 - 1) + (n_2 - 1) = n_1 + n_2 - 2$.

Geramente, o gl está em algum lugar entre $n_1 + n_2 - 2$ e o mínimo de $(n_1 - 1)$ e $(n_2 - 1)$. Um software pode facilmente encontrar esse valor do gl , o escorre- t e o intervalo de confiança.

Na prática, o método é robusto a violações da suposição de normalidade. Isto é especialmente verdadeiro quando ambos n_1 e n_2 são pelo menos aproximadamente 30, pelo Teorema Central do Límite.

Como de costume, você deve ser cauteloso com valores atípicos ou assimetria extrema que podem tornar a média uma medida inadequada para representar os dados.

EXEMPLO 7.3 Comparando o trabalho doméstico de homens e mulheres

Para a Tabela 7.1 (página 212), sobre o tempo diário que trabalhadores de tempo integral gastam cozinhando e limpando, representamos a média da população da Grã-Bretanha por μ_1 para homens e μ_2 para mulheres. Aquela tabela apresentou médias amostrais de 23 minutos para 1219 homens e de 37 minutos para 733 mulheres com desvios padrão amostrais de 32 e 16. A estimativa por ponto de $\mu_2 - \mu_1$ é igual a $\bar{Y}_2 - \bar{Y}_1 = 37 - 23 = 14$. A Seção 7.1 encontrou que o erro padrão estimado desta diferença se iguala a:

$$ep = \sqrt{\frac{s_1^2}{n_1} + \frac{s_2^2}{n_2}} \\ = \sqrt{\frac{(32)^2}{1219} + \frac{(16)^2}{733}} = 1.09.$$

Os tamanhos da amostra são muito grandes, assim o escorre- t para a margem de erro é essencialmente o escorre- z . Portanto, o intervalo de 95% de confiança para $\mu_2 - \mu_1$ é

$$(\bar{Y}_2 - \bar{Y}_1) \pm 1.96(ep) = 14 \pm 1.96(1.09)$$

ou ainda 14 ± 2 , que é $(12, 16)$.

Podemos estar 95% confiantes de que a quantia média do tempo diário da população gasto cozinhando e limpando está entre 12 e 16 minutos a mais para as mulheres do que para homens.

Interpretando um intervalo de confiança na comparação de médias

O intervalo de confiança $(12, 16)$ contém somente valores positivos. Visto que cal-

culamos a diferença entre a média para mulheres e a média para homens, podemos concluir que a média populacional é maior para as mulheres. Um intervalo de confiança para $\mu_2 - \mu_1$ que contém sólamente valores positivos sugere que $\mu_2 - \mu_1$ é positivo, significando que μ_2 é maior do que μ_1 . Um intervalo de confiança para $\mu_2 - \mu_1$ que contém somente valores negativos sugere que μ_2 é menor do que μ_1 .

Quando o intervalo de confiança contém 0, não existe evidência suficiente para concluir se μ_1 ou μ_2 é maior. É plausível, então, que $\mu_1 = \mu_2$. A identificação de qual é o grupo 1 e qual é o grupo 2 é arbitrário, como quando estimamos $\mu_2 - \mu_1$ ou $\mu_1 - \mu_2$. Por exemplo, um intervalo de confiança de $(12, 16)$ para $\mu_2 - \mu_1$ é equivalente a um de $(-16, -12)$ para $\mu_1 - \mu_2$.

Testes de significância sobre $\mu_2 - \mu_1$
Para comparar as médias populacionais μ_1 e μ_2 , podemos, também, conduzir um teste de significância de $H_0: \mu_1 = \mu_2$. Para a diferença das médias dos parâmetros, esta hipótese é $H_0: \mu_2 - \mu_1 = 0$ (sem efeito).

Como sempre, a estatística-teste mensura o número de erros padrão entre a estimativa e o valor H_0 .

$$t = \frac{\text{valor da hipótese nula}}{\text{valor da hipótese nula}}.$$

Tratando $\mu_2 - \mu_1$ como o parâmetro, testamos que $\mu_2 - \mu_1 = 0$. Sua estimativa é $\bar{Y}_2 - \bar{Y}_1$. O erro padrão é o mesmo do intervalo de confiança. A estatística-teste é

$$t = \frac{(\bar{Y}_2 - \bar{Y}_1) - 0}{ep},$$

onde $ep = \sqrt{\frac{s_1^2}{n_1} + \frac{s_2^2}{n_2}}$.

EXEMPLO 7.4 Teste comparando a média do trabalho doméstico para homens e mulheres

Usando os dados da Tabela 7.1 (página 212), testamos, agora, a diferença entre a o tempo médio de cozinar e lavar da população, μ_1 para homens e μ_2 para mulheres.

Vimos que a estimativa $\bar{Y}_2 - \bar{Y}_1 = 37 - 23 = 14$ tem $ep = 1.09$. A estatística-teste é igual a:

$$t = \frac{(\bar{Y}_2 - \bar{Y}_1) - 0}{ep} = \frac{(37 - 23)}{1.09} = 12.8.$$

Com amostras grandes, visto que a distribuição t é essencialmente a mesma que a normal padrão, $t = 12.8$ é enorme. Ela fornece um valor p que é zero com muitas casas decimais. Concluímos que as médias das populações diferem. As médias amostrais mostram que a diferença toma a direção de uma média maior para as mulheres.

Na prática, os testes de significância são muito mais comuns para comparações de duas amostras do que para análises de uma amostra. Geralmente, é artificial testar se a média da população é igual a um determinado valor em particular, como, por exemplo, testar $H_0: \mu = \mu_0$. Entretanto, é normalmente relevante testar se existe uma diferença entre duas médias populacionais, como no teste de $H_0: \mu_1 = \mu_2$. Por exemplo, podemos não ter ideia do que supor para o tempo médio de trabalho doméstico para homens, mas podemos querer saber se essa média (qualquer que seja seu valor) é a mesma, maior ou menor do que o tempo médio para as mulheres.

Correspondência entre intervalos de confiança e testes

Para médias, a equivalência entre testes bilaterais e intervalos de confiança mencionada nas Seções 6.2 (página 172) e 6.4 (página 185) também se aplica ao caso

de duas amostras. Por exemplo, visto que o valor p -bilateral do Exemplo 7.4 é menor do que 0,05, rejeitamos H_0 : $\mu_2 - \mu_1 = 0$, ao nível $\alpha = 0,05$. De forma similar, um intervalo de 95% de confiança para $\mu_2 - \mu_1$ não contém 0, o valor H_0 . Aquele intervalo é $(12, 16)$.

Como na inferência de uma amostra, os intervalos de confiança são mais informativos do que os testes. O intervalo de confiança nos diz não somente que a média da população difere para homens e mulheres, mas também nos mostra quanto grande é provável que essa diferença seja e qual a sua direção.

7.4 COMPARANDO MÉDIAS COM AMOSTRAS DEPENDENTES

Amostras dependentes ocorrem quando cada observação na amostra 1 se equipara com a observação na amostra 2. Os dados são, geralmente, chamados de dados de pares emparelhados em virtude dessa equiparação.

Diferenças dos escores pareadas para amostras emparelhadas

A dependência ocorre geralmente quando cada amostra tem os mesmos sujeitos. Exemplos são estudos observacionais *longitudinais* que observam a resposta de uma pessoa em vários pontos no tempo e estudos experimentais que tomam *medidas repetidas* dos sujeitos. Um exemplo do último é um estudo *transversal*, no qual um sujeito recebe um tratamento por um período e, depois, outro tratamento. O próximo exemplo ilustra essa situação.

EXEMPLO 7.5 Uso do telefone celular e tempo de reação do motorista

Um experimento recente³ usou uma amostra de estudantes universitários para investigar se o uso do telefone celular prejudica a reação dos motoristas. Em uma máquina que simulou situações de direção, em pe-

riodos irregulares um alvo brilhava na cor vermelha ou verde. Os participantes foram instruídos para pressionar o freio o mais rápido possível assim que detectassem uma luz verde. Sob a condição do telefone celular, o estudante mantinha uma conversa sobre política no telefone celular com alguém em uma sala separada. Na condição de controle, eles escutavam uma transmissão no rádio ou livros em fita enquanto simulavam estar dirigindo.

Para cada estudante, em uma condição particular, o resultado registrado na Tabela 7.3 é o seu tempo médio de resposta (em milésimos de segundos) em várias tentativas. A Figura 7.3 mostra os diagramas de caixa e bigodes para as duas situações. O estudante 28 é um valor atípico sob cada condição.

Para os dados emparelhados, cada observação de uma amostra é pareada com uma observação na outra amostra. Para cada par, formamos:

$$\text{Diferença} = \text{Observação na amostra 2} - \text{Observação na amostra 1.}$$

A Tabela 7.3 mostra a diferença dos escores para o experimento do telefone celular.

Considere \bar{Y}_d a representação da média amostral das diferenças dos escores. Isto estima μ_d , a diferença média na população. Na verdade, o parâmetro μ_d é idêntico a $\mu_2 - \mu_1$, diferença entre as médias populacionais para os dois grupos. A média das diferenças é igual à diferença entre as médias.

Para dados emparelhados, a diferença entre as médias dos dois grupos é igual à média da diferença dos escores.

Inferências comparando médias a partir de diferenças pareadas

Podemos basear as análises sobre $\mu_2 - \mu_1$ nas inferências sobre μ_d , usando uma amostra da diferença dos escores. Isso simplifica a análise porque reduz um problema de duas amostras para um problema de uma amostra.

Tabela 7.3 Tempos de reação (em milésimos de segundos) na tarefa de dirigir sobre a condição de uso ou não do telefone celular. A diferença do escore é o tempo de reação para frear usando o telefone celular, tal como $636 - 604 = 32$ milésimos de segundo

| Estudante | Telefone Celular? | | Telefone Celular? | | | | |
|-----------|-------------------|-----|-------------------|-----------|-----|-----|-----------|
| | Não | Sim | Diferença | Estudante | Não | Sim | Diferença |
| 1 | 604 | 636 | 32 | 17 | 525 | 626 | 101 |
| 2 | 556 | 623 | 67 | 18 | 508 | 501 | -7 |
| 3 | 540 | 615 | 75 | 19 | 529 | 574 | 45 |
| 4 | 522 | 672 | 150 | 20 | 470 | 468 | -2 |
| 5 | 459 | 601 | 142 | 21 | 512 | 578 | 66 |
| 6 | 544 | 600 | 56 | 22 | 487 | 560 | 73 |
| 7 | 513 | 542 | 29 | 23 | 515 | 525 | 10 |
| 8 | 470 | 554 | 84 | 24 | 499 | 647 | 148 |
| 9 | 556 | 543 | -13 | 25 | 448 | 456 | 8 |
| 10 | 531 | 520 | -11 | 26 | 558 | 688 | 130 |
| 11 | 599 | 609 | 10 | 27 | 589 | 679 | 90 |
| 12 | 537 | 559 | 22 | 28 | 814 | 960 | 146 |
| 13 | 619 | 595 | -24 | 29 | 519 | 558 | 39 |
| 14 | 536 | 565 | 29 | 30 | 462 | 482 | 20 |
| 15 | 554 | 573 | 19 | 31 | 521 | 527 | 6 |
| 16 | 467 | 554 | 87 | 32 | 543 | 536 | -7 |

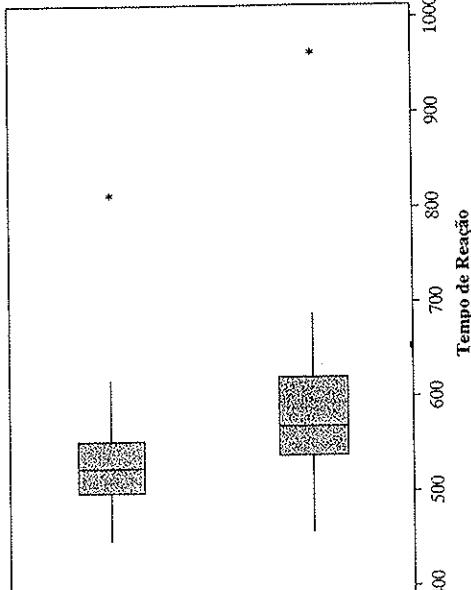


Figura 7.3 Diagramas de caixa e bigodes do experimento do uso ou não do telefone celular nos tempos de reação para frear.

Considere n a representação do número de observações em cada amostra. Isso se iguala ao número da diferença dos escores. O intervalo de confiança para μ_d é:

$$\bar{y}_d \pm t \left(\frac{s_d}{\sqrt{n}} \right).$$

Aqui, \bar{y}_d e s_d são média amostral e desvio padrão da diferença dos escores, e t é o escor-e-t para o nível de confiança escolhido, tendo $gl = n - 1$. Este intervalo de confiança tem a mesma forma do que o da Seção 6.3 (página 182) para uma única amostra.

Aplicamos a fórmula para uma única amostra de n diferenças em vez de sobre dois conjuntos originais de observações.

Para testar $H_0: \mu_1 = \mu_2$, expressamos a hipótese em termos de diferenças dos escores como $H_0: \mu_d = 0$. A estatística-teste é:

$$t = \frac{\bar{y}_d - 0}{ep}, \quad \text{onde } ep = s_d / \sqrt{n},$$

que compara a média amostral das diferenças ao valor da hipótese nula de 0, em termos do número de erros padrão entre eles. O erro padrão é o mesmo usado para um intervalo de confiança. Visto que esse

$$s_d = \sqrt{\frac{(32 - 50,6)^2 + (67 - 50,6)^2 + \dots}{32 - 1}} = 52,5.$$

O erro padrão de \bar{y}_d é $ep = s_d / \sqrt{n} = 52,5 / \sqrt{32} = 9,28$.

Para um intervalo de 95% de confiança para $\mu_d = \mu_2 - \mu_1$ com $gl = n - 1 = 31$, usamos $t_{0,025} = 2,04$. O intervalo de confiança é igual a

$$\bar{y}_d \pm 2,04(ep) = 50,6 \pm 2,04(9,28), \quad \text{que é } (31,7; 69,5).$$

Inferimos que o tempo médio da reação da população usando o celular está entre 32 e 70 milésimos de segundo-acima do que aquele sem o uso celular. O intervalo de confiança não contém 0. Concluímos, assim, que o tempo médio de reação da população é maior quando envolve o uso do celular.

A seguir, considere o teste de significância $H_0: \mu_d = 0$ (e, por conseguinte, médias

res de observações, ele é chamado de teste t para diferenças pareadas.

EXEMPLO 7.6 Uso do telefone celular e tempo de reação do motorista (continuação)

Agora, analisamos os dados de pares equilados da Tabela 7.3 para o experimento de dirigir com e sem o uso do telefone celular. Os tempos médios de reação foram 534,6 milésimos de segundo sem o uso do celular e 585,2 milésimos de segundo usando o celular. As 32 diferenças dos escores (32, 67, 75,...) da Tabela 7.3 têm uma média amostral de:

$$\bar{y}_d = (32 + 67 + 75 + \dots + (-7))/32 = 50,6.$$

Isto se iguala à diferença entre as médias amostrais de 585,2 e 534,6 para as duas condições. O desvio padrão amostral das 32 diferenças dos escores é:

$$\bar{y}_d = (32 + 67 + 75 + \dots + (-7))/32 = 50,6.$$

Isto se iguala à diferença entre as médias amostrais de 585,2 e 534,6 para as duas condições. O desvio padrão amostral das 32 diferenças dos escores é:

$$t = \frac{(\bar{y}_d - 0)}{ep} = \frac{50,6}{9,28} = 5,5,$$

com $gl = 31$. O valor-p bilateral é igual a 0,000005. Existe uma forte evidência de que o tempo médio de reação é maior quando o celular é usado. A Tabela 7.4 mostra como o SPSS apresenta esses resultados para a opção do teste t para amostras emparelhadas.

As inferências para diferenças pareadas fazem as suposições usuais para os procedimentos t : as observações (as diferenças dos escores) são obtidas aleatoriamente da população que é normal. Os intervalos de confiança e testes bilaterais funcionam bem,

Tabela 7.4 Saída do SPSS para a análise de valores pareados comparando os tempos de reação do motorista com e sem o uso do telefone celular

| Variável | Nº de pares | Média | DP | EP da média |
|-------------|-------------|--------|-------|-------------|
| SEM CELULAR | 32 | 534,56 | 66,45 | 11,75 |
| COM CELULAR | 534,56 | 89,65 | 15,85 | |

| Média | DP | EP da media | valor t | gl | Sig. bilateral |
|-------|-------|-------------|---------|----|----------------|
| 50,63 | 52,49 | 9,28 | 5,46 | 31 | 0,000 |

IC de 95% (31,70; 69,55)

mesmo se a suposição de normalidade é violada (propriedade da robustez), a não ser que o tamanho da amostra seja pequeno e a distribuição seja altamente assimétrica ou tenha valores atípicos severos. Para o estudo sobre dirigir com o uso ou não de celulares, um sujeito era um valor atípico nos dois tempos de reação. Contudo, a diferença usada na análise, não é um valor atípico. O artigo sobre o estudo não indica se os sujeitos foram selecionados aleatoriamente. Os sujeitos no experimento eram provavelmente de uma amostra voluntária, portanto as conclusões inferenciais são aproximadas.

Amostras independentes versus amostras dependentes

Usar amostras dependentes pode ter certos benefícios. Primeiro, fontes conhecidas de tendenciosidade potencial são controladas.

Usar os mesmos sujeitos em cada amostra, por exemplo, mantém outros fatores fixos que poderiam afetar a análise. Suponha que sujeitos mais jovens tendam a ter os tempos de reação mais rápidos. Se o grupo 1 tem uma média amostral mais baixa do que o grupo 2, não é porque os sujeitos do grupo 1 sejam mais jovens, porque ambos os grupos têm os mesmos sujeitos.

7.5 OUTROS MÉTODOS PARA COMPARAR MÉDIAS*

A Seção 7.3 apresentou inferência para comparar duas médias com amostras independentes. Um método de inferência levemente diferente pode ser usado quando esperamos variabilidade similar para os dois grupos. Por exemplo, sob a hipótese nula de “sem efeito”, geralmente esperamos que todas as distribuições da variável resposta sejam idênticas para os dois

desvios padrão quanto as médias sejam idênticos.

Comparando médias com a suposição de desvios padrão iguais

Na comparação das médias populacionais, esse método faz a suposição adicional de que os desvios padrão populacionais são iguais, isto é, $\sigma_1 = \sigma_2$. Nesse caso, existe uma expressão mais simples para o t -valor exato da distribuição t para essa estatística. Embora pareça desagradável fazer uma suposição adicional, os intervalos de confiança e testes bilaterais são bem robustos contra violações dessa hipótese e a da normalidade, principalmente quando os tamanhos das amostras são similares e não muito pequenos.

O valor comum σ de σ_1 e σ_2 é estimado por:

$$s = \sqrt{\frac{(n_1 - 1)s_1^2 + (n_2 - 1)s_2^2}{n_1 + n_2 - 2}} = \sqrt{\frac{\sum(y_1 - \bar{y}_1)^2 + \sum(y_2 - \bar{y}_2)^2}{n_1 + n_2 - 2}}.$$

Aqui, $\sum(y_1 - \bar{y}_1)^2$ representa a soma dos quadrados em torno da média para os valores do primeiro exemplo e $\sum(y_2 - \bar{y}_2)^2$ representa a soma dos quadrados em torno da média para as observações do segundo exemplo. A estimativa junta as informações dos dois exemplos para fornecer uma única estimativa da variabilidade. Ela é chamada de *estimativa combinada*. O termo dentro da raiz quadrada é uma média ponderada das variâncias das duas amostras. Quando $n_1 = n_2$, é a média aritmética simples. A estimativa s entre s_1 e s_2 . Com s como a estimativa de σ_1 e σ_2 , o erro padrão estimado de $\bar{y}_2 - \bar{y}_1$ fica reduzido a:

$$ep = \sqrt{\frac{s^2}{n_1} + \frac{s^2}{n_2}} = s \sqrt{\frac{1}{n_1} + \frac{1}{n_2}}.$$

O intervalo de confiança para $\mu_2 - \mu_1$ tem a forma usual:

$$(\bar{y}_2 - \bar{y}_1) \pm t(ep).$$

O escore- t vem da tabela t para o nível de confiança desejado, com $gl = n_1 + n_2 - 2$. O gl é igual ao número total de observações ($n_1 + n_2$) menos o número dos parâmetros estimados para calcular s (a saber, as duas médias, μ_1 e μ_2 , estimadas por \bar{y}_1 e \bar{y}_2). Para testar $H_0: \mu_1 = \mu_2$, a estatística- t teste tem a forma usual:

$$t = \frac{(\bar{y}_1 - \bar{y}_2)}{ep}.$$

Agora, o ep usa a fórmula combinada, como no intervalo de confiança. A estatística-teste tem uma distribuição t com $gl = n_1 + n_2 - 2$.

EXEMPLO 7.7 Comparando uma terapia ao grupo de controle

Os Exemplos 5.5 (página 144) e 6.4 (página 177) descreveram um estudo que usou uma terapia cognitivo-comportamental para tratar de uma amostra de meninas adolescentes que sofriam de anorexia. O estudo observou a mudança média no peso após um período do tratamento. Estudos desse tipo geralmente também têm um grupo de controle que recebe o tratamento ou um tratamento padrão. Então, os pesquisadores podem analisar como a mudança no peso se comporta em relação ao grupo do tratamento e o grupo de controle.

Na verdade, o grupo da anorexia tinha um grupo de controle. As meninas adolescentes do estudo foram designadas aleatoriamente ao tratamento cognitivo-comportamental (Grupo 1) ou ao grupo de controle (Grupo 2). A Tabela 7.5 resume os resultados. (Os dados de ambos os grupos são exibidos na Tabela 12.21 na página 439.)

Se H_0 é verdadeira, que o tratamen-

Tabela 7.5 Resumo dos resultados comparando o grupo de tratamento com o de controle para o estudo da anorexia

| Grupo | Tamanho da amostra | Média | Desvio padrão |
|------------|--------------------|-------|---------------|
| Tratamento | 29 | 3,01 | 7,31 |
| Controle | 26 | -0,45 | 7,99 |

Concluímos que a mudança média do peso para a terapia cognitivo-comportamental poderá ser tanto quanto 0,7 libras mais baixas ou tanto quanto 7,6 libras mais altas do que a mudança média do peso para o grupo de controle. Visto que o intervalo contém 0, é plausível que as médias populacionais sejam idênticas. Isso é consistente com o valor p excedendo a 0,05 no teste. Se a mudança média no peso da população é menor do que a do grupo de terapia cognitivo-comportamental, ela é um pouco menor (menos do que 1 libra), mas se a mudança média da população é maior, ela poderá ser de aproximadamente 8 libras. Como os tamanhos da amostra não são grandes, o intervalo de confiança é relativamente grande. ■

$$s = \sqrt{\frac{(n_1 - 1)s_1^2 + (n_2 - 1)s_2^2}{n_1 + n_2 - 2}} = \sqrt{\frac{28(7,31)^2 + 25(7,99)^2}{29 + 26 - 2}} = \sqrt{\frac{3092,2}{53}} = 7,64.$$

Agora, $\bar{y}_1 - \bar{y}_2 = 3,01 - (-0,45) = 3,46$ tem um erro padrão estimado de:

$$ep = s \sqrt{\frac{1}{n_1} + \frac{1}{n_2}} = 7,64 \sqrt{\frac{1}{29} + \frac{1}{26}} = 2,06.$$

Considerando $\mu_1 = \mu_2$ representando os ganhos médios de peso para essas terapias para as populações hipotéticas de onde as amostras foram retiradas. Testamos $H_0: \mu_1 = \mu_2$ contra $H_a: \mu_1 \neq \mu_2$:

$$t = \frac{\bar{y}_1 - \bar{y}_2}{ep} = \frac{3,01 - (-0,45)}{2,06} = 1,68.$$

A estatística tem $gl = n_1 + n_2 - 2 = 29 + 26 - 2 = 53$. Da tabela t (Tabela B) o valor- p bilateral é 0,10. Existe somente uma fraça evidência de que o uso da terapia cognitivo-comportamental tenha sucesso. Quando $gl = 53$, o escore- t para um intervalo de 95% de confiança para $(\mu_1 - \mu_2)$ é $t_{0,025} = 2,006$. O intervalo é:

$$(\bar{y}_1 - \bar{y}_2) \pm t(ep) = 3,46 \pm 2,006(2,06), \text{ que é } 3,46 \pm 4,14 \text{ ou } (-0,7; 7,6).$$

Um delineamento experimental alternativo *equipara* os sujeitos nas duas amostras, como, por exemplo, pegar duas meninas com o mesmo peso e aleatoriamente

decidir qual menina receberá determinada terapia. Esse plano com pares equiparados é um exemplo simples de um **delineamento aleatorizado por blocos**. Cada par de sujeitos forma um *bloco* e dentro dos blocos os sujeitos são aleatoriamente designados aos tratamentos. Com esse delineamento, usamos os métodos da seção anterior para variáveis dependentes.

Inferências relatadas pelo software

A Tabela 7.6 ilustra a forma como o SPSS apresenta os resultados dos testes *t* para duas amostras. A tabela mostra os resultados dos dois testes para comparar médias, que diferem na forma de assumirem os desvios padrão iguais da população. O teste *t* recém apresentado assume que $\sigma_1 = \sigma_2$. A estatística *t* que o software apresenta para o caso de "variâncias supostamente diferentes" é a estatística *t* da Seção 7.3,

$$t = (\bar{y}_2 - \bar{y}_1)/ep, \text{ com } ep = \sqrt{\frac{s_1^2}{n_1} + \frac{s_2^2}{n_2}}.$$

Quando $n_1 = n_2$, as estatísticas-teste supondo "variâncias iguais" e "variâncias diferentes" coincidem. Elas são geralmente semelhantes se n_1 e n_2 estão próximos ou se s_1 e s_2 estão próximos.

Se os dados mostram evidência de uma diferença potencialmente grande nos desvios padrão (com, digamos, um desvio padão sendo, pelo menos, o dobro do outro) é melhor usar o teste *t* aproximado (Seção 7.3) que não necessita da suposição de $\sigma_1 = \sigma_2$. Ele pode gerar um valor estatístico *t*

$$\begin{aligned} \text{Tamanho do efeito} &= \frac{\bar{y}_1 - \bar{y}_2}{s} \\ &= \frac{3,01 - (-0,45)}{7,64} = 0,45. \end{aligned}$$

Tabela 7.6 Saída do SPSS para os testes *t* de duas amostras

Teste *t* para a igualdade de médias

Sig. t g1 (bilateral) diferença Erro Padrão da diferença

MUDANÇA Supondo variâncias iguais 1,68 53 0,099 3,46 2,06 NO PESSO Supondo variâncias diferentes 1,67 50 0,102 3,46 2,07

muito diferente do método que supõe $\sigma_1 = \sigma_2$ se s_1 e s_2 são bem diferentes e os tamanhos das amostras desiguais.

Muitos livros e softwares apresentam uma estatística representada por *F* para testar que os desvios padrão populacionais são iguais. Não é apropriado conduzir esse teste para determinar qual teste *t* usar. Na verdade, não recomendamos esse teste mesmo se o seu propósito principal é comparar a variabilidade de dois grupos. Esse teste supõe que as distribuições populacionais são normais e ele não é robusto a violações dessa suposição.

Tamanho do efeito

No Exemplo 7.7, do estudo da anorexia, a diferença estimada entre os ganhos médios de peso de 3,46 é grande ou pequena em termos práticos? Lembre que o tamanho de uma diferença estimada depende das unidades da mensuração. Esses dados estavam em libras, mas, se convertermos para quilogramas, a diferença estimada seria de 1,57 e, se convertida a onças, seria de 55,4.

Uma forma padronizada para descrever a diferença é dividí-la pelo desvio padrão estimado para cada grupo. Isto é chamado de **tamanho do efeito**. Com médias amostrais de 3,01 e -0,45 libras e uma estimativa combinada do desvio padrão de $s = 7,64$ libras, a diferença padronizada é:

$$\text{Tamanho do efeito} = \frac{\bar{y}_1 - \bar{y}_2}{s}$$

$= \frac{3,01 - (-0,45)}{7,64} = 0,45.$

A diferença entre as médias amostrais é menor do que a metade de um desvio padrão, que é um valor relativamente pequeno. Obteríamos o mesmo valor para o tamanho do efeito se mensurássemos esses dados em unidades diferentes, como quilogramas ou onças.

Um modelo para médias

Na segunda parte deste livro, aprendemos sobre métodos avançados para analisar associações entre variáveis. Basearmos as análises explicitamente em um modelo. Para duas variáveis, um **modelo** é uma aproximação simples para o relacionamento verdadeiro entre essas variáveis na população.

Considere $N(\mu, \sigma)$ a representação de uma distribuição normal com média μ e desvio padrão σ . Considere y_1 a representação de uma observação aleatoriamente selecionada do Grupo 1 e y_2 uma observação aleatoriamente selecionada do Grupo 2. A hipótese testada acima para comparar medias supondo que $\sigma_1 = \sigma_2$ pode ser expressa como o modelo:

$H_0: y_1 \text{ e } y_2 \text{ têm uma distribuição } N(\mu, \sigma).$

$H_A: y_1 \text{ tem uma distribuição } N(\mu_1, \sigma)$ e $y_2 \text{ tem uma distribuição } N(\mu_2, \sigma)$, com $\mu_1 \neq \mu_2$.

$H_A: y_1$ tem uma distribuição $N(\mu_1, \sigma)$ e y_2 tem uma distribuição $N(\mu_2, \sigma)$, com $\mu_1 \neq \mu_2$.

Sob H_0 , as médias populacionais são iguais, com um valor comum μ . Sob H_A , as médias populacionais diferem. Este é um caso especial de um modelo que o Capítulo 12 usa para comparar várias médias.

As distribuições amostrais e as inferências resultantes são derivadas sob a estrutura suposta do modelo. Mas os modelos são meramente simplificações convenientes da realidade. Não esperamos que as distribuições sejam exatamente normais, por exemplo. Uma das partes-chave de se ficar mais à vontade usando

os métodos estatísticos é estar mais informado sobre quais suposições são mais importantes em um modelo e como verificar tais suposições. Geralmente, existem benefícios no uso de modelos mais simples. Eles têm menos parâmetros para estimar e as inferências podem ser mais poderosas. Entretanto, quando tal modelo está muito errado, é melhor usar um modelo mais complexo.

O primeiro teste de significância que discutimos para comparar médias usou um modelo um pouco mais complexo: $H_0: y_1$ tem uma distribuição $N(\mu, \sigma_1)$, $H_A: y_1$ tem uma distribuição $N(\mu_2, \sigma_2)$, com $\mu_1 \neq \mu_2$.

Novamente, sob H_0 as médias da população são iguais. Mas, agora, nenhuma suposição é feita sobre os desvios padrão serem iguais. Se existe motivo para esperar que os desvios padrão sejam muito diferentes ou se os dados indicam isto (com um dos desvios padrão da amostra sendo pelo menos o dobro do outro), então é melhor usarmos análises baseadas neste modelo. Se os dados mostram que nesse modelo pode estar muito errado, como, por exemplo, quando as distribuições dos dados amostrais são tão assimétricas que a média é um representante inadequado, é melhor, então, usar um modelo diferente. A seção final deste capítulo apresenta um modelo que não assume a normalidade.

7.6 OUTROS MÉTODOS PARA COMPARAR PROPORÇÕES*

A Secção 7.2 apresentou métodos para amostras grandes para comparar proporções com amostras independentes. Esta seção apresenta métodos para comparar proporções com (1) amostra dependente e (2) amostras pequenas.

Comparando proporções dependentes

A Seção 7.4 apresentou métodos para comparar médias com amostras dependentes. O exemplo seguinte ilustra métodos para comparar proporções com amostras dependentes.

EXEMPLO 7.8 Comparando dois sistemas de reconhecimento da voz

Nos últimos anos tem havido aprimoramentos impressionantes nos sistemas para reconhecimento automático da voz. Quando você, nos dias de hoje, liga para vários centros de serviços, antes de falar com um ser humano é solicitado a você que responda a várias perguntas verbalmente, quanto no passado você tinha que usar o disco do telefone.

As pesquisas comparando a qualidade dos diferentes sistemas de reconhecimento da voz geralmente usam, como um teste de avaliação, uma série de palavras isoladas, verificando quão seguido cada sistema comete erros no reconhecimento da palavra. A Tabela 7.7 mostra um exemplo de um desses testes, comparando dois sistemas de reconhecimento da voz, chamados de dissegmentação generalizada de mímina distorção (SGMD) e densidade contínua do modelo oculto de Markov (DCMOM).

As linhas da Tabela 7.7 são as categorias (correto, incorreto) para cada palavra usando o SGMD. As colunas são as mesmas categorias para o DCMOM. As frequências marginais das linhas (1979, 21), os totais de (correto, incorreto) para o SGMD. As fre-

quências marginais das colunas (1937, 63) são os totais para o DCMOM.

Iremos comparar a proporção das respostas corretas para esses dois sistemas de reconhecimento da voz. As amostras são dependentes porque os dois sistemas usaram as mesmas 2000 palavras. Consideraremos estas 2000 palavras como uma amostra aleatória de palavras possíveis nas quais o sistema poderia ter sido testado. Considere π_1 a representação da proporção populacional de palavras corretamente identificadas com o SGMD e considere π_2 a representação da proporção populacional de palavras corretamente identificadas com o DCMOM. As estimativas da amostra são $\hat{\pi}_1 = 1979/2000 = 0,9895$ e $\hat{\pi}_2 = 1937/2000 = 0,9685$.

Se as proporções de palavras corretamente identificadas foram idênticas para os dois sistemas, o número de observações da primeira linha da Tabela 7.7 seria igual ao número de observações da primeira coluna. A primeira célula (aquele contendo 1921 na Tabela 7.7) é comum tanto na primeira linha quanto na primeira coluna, assim a outra frequência da célula na primeira linha seria igual à outra frequência na primeira coluna. Isto é, o número de palavras julgadas corretas pelo SGMD, mas incorretas pela DCMOM. Podemos testar $H_0: \pi_1 = \pi_2$ usando as frequências dessas duas células. Se H_0 é verdadeira, então, destas palavras, nós esperamos que $\frac{1}{2}$ sejam corretas para o SGMD e incorretas para DCMOM e $\frac{1}{2}$ sejam incorretas para SGMD e corretas para o DCMOM.

Como no teste emparelhado para uma média, reduzimos a inferência para um único parâmetro. Para a população nas duas células recém-mencionadas, testamos se metade está em cada célula. Na Tabela 7.7, dos $58 + 16 = 74$ palavras julgadas

Tabela 7.7 Resultados do teste de avaliação utilizando 2000 palavras para dois sistemas de reconhecimento da voz

| SGMD | Correto | | Incorreto | Total |
|-----------|---------|-----------|-----------|-------|
| | Correto | Incorreto | | Total |
| Correto | 1921 | 58 | 1979 | 1979 |
| Incorreto | 16 | 5 | 21 | 21 |
| Total | 1937 | 63 | 2000 | 2000 |

porção amostral para essas 74 observações é $\sqrt{(0,50)(0,50)/74} = 0,058$.

Da Seção 6.3 (página 182), a estatística z para testar que a proporção populacional é igual a 0,50 é:

$$z = \frac{\text{Proporção amostral} - \text{proporção } H_0}{\text{erro padrão}} = \frac{0,784 - 0,50}{0,058} = 4,88.$$

O valor- p bilateral é igual a 0,000. Isto fornece uma forte evidência contra $H_0: \pi_1 = \pi_2$. Baseado nas proporções amostrais, a evidência favorece a proporção populacional maior de reconhecimentos corretos pelo sistema SGMD. ■

Teste McNemar para comparar proporções dependentes

Existe uma fórmula simples para essa estatística-teste z para comparar duas proporções dependentes. Para uma tabela da forma da Tabela 7.7, represente as frequências das células nas duas células relevantes por n_{12} para aquelas na linha 1 e na coluna 2 e por n_{21} para aquelas na linha 2 e na coluna 1. A estatística-teste é igual a:

$$z = \frac{n_{12} - n_{21}}{\sqrt{n_{12} + n_{21}}}.$$

Quando $n_{12} + n_{21}$ excede 20, essa estatística tem aproximadamente uma distribuição normal padrão se H_0 é verdadeira. Este teste é geralmente chamado de teste McNemar. Para amostras pequenas, use a distribuição binomial para realizar o teste. Para a Tabela 7.7, teste McNemar usa $n_{12} = 58$, o número de palavras reconhecidas corretamente pelo SGMD e incorretamente pelo DCMOM, e $n_{21} = 16$, o número para o inverso. A estatística-teste é igual a:

$$z = \frac{58 - 16}{\sqrt{58 + 16}} = 4,88.$$

O valor- p é 0,000.

Intervalo de confiança para a diferença das proporções dependentes

Um intervalo de confiança para a diferença das proporções é mais informativo do que um teste de significância. Para amostras grandes, ele é:

$$(\hat{\pi}_2 - \hat{\pi}_1) \pm z(ep),$$

onde o erro padrão é estimado usando:

$$ep = \sqrt{(n_{12} + n_{21}) - (n_{12} - n_{21})^2/n}.$$

Para a Tabela 7.7, $\hat{\pi}_1 = 1979/2000 = 0,9895$ e $\hat{\pi}_2 = 1937/2000 = 0,9685$. A diferença entre $\hat{\pi}_1 - \hat{\pi}_2 = 0,9895 - 0,9685 = 0,021$. Para $n = 2000$ observações com $n_{12} = 58$ e $n_{21} = 16$,

$$ep = \sqrt{(58 + 16) - (58 - 16)^2/2000}/2000 = 0,0043.$$

Um intervalo de 95% de confiança para $\pi_1 - \pi_2$ é igual a $0,021 \pm 1,96(0,0043)$ ou $(0,013, 0,029)$. Concluímos que a proporção da população correta com o sistema SGMD está entre aproximadamente 0,01 e 0,03 maior do que a proporção da população correta com o sistema DCMOM. Em resumo, a diferença entre as proporções da população parece ser muito pequena.

O teste exato de Fisher para comparar proporções dependentes

As inferências para proporções com amostras independentes introduzidas na Seção 7.2 são válidas para amostras relativamente grandes. A seguir, estudaremos métodos para amostras pequenas.

O teste de significância bilateral para comparar proporções com a estatística z funciona muito bem se cada amostra tem pelo menos aproximadamente 5 a 10 resultados de cada tipo (isto é, pelo menos 5 a 10 observações em cada célula da tabela de contingência). Para tamanhos amo-

ções) são calculadas para cada amostra. A estatística-teste compara as médias amostrais dos postos. Para amostras grandes, a estatística-teste t tem uma distribuição aproximadamente normal padrão. Para pequenas amostras, um valor- p exato é baseado em quanto incomum é a diferença observada entre as classificações médias (sob a suposição de que H_0 é verdadeira) quando comparada a diferenças entre os postos para todas as demais classificações possíveis.

Outro teste não paramétrico é o teste de Mann-Whitney. Ele observa todos os pares de observações, tal que a primeira observação é de um grupo e a segunda é do outro grupo. A estatística-teste é basada no número de pares para os quais a observação do primeiro grupo é maior. O teste é equivalente ao teste de Wilcoxon, dando o mesmo valor- p . (Frank Wilcoxon desenvolveu testes equivalentes aos de Henry Berthold Mann e Donald Ransom Whitney aproximadamente no mesmo período da década de 1940.)

Para o Exemplo 7.5, na comparação das mudanças de peso entre os grupos de terapia cognitivo-comportamental e o de controle no estudo da anorexia (página 222), o teste t paramétrico tinha um valor- p bilateral igual a 0,10. A versão para grandes amostras do teste de Wilcoxon-Mann-Whitney apresenta um resultado similar, com um valor- p de 0,11.

Alguns softwares também podem apresentar um intervalo de confiança correspondente para a diferença entre as medianas populacionais. O método supõe que as duas distribuições tenham a mesma forma, mas não necessariamente normal. A mudança mediana do peso foi de 1,4 libras para o grupo de terapia cognitivo-comportamental e -0,35 libras para o grupo de controle. O software apresenta um intervalo de 95% de confiança para a diferença entre as medianas de (-0,6, 8,1) libras.

Tamanho do efeito: proporção de melhores respostas para um grupo

A Seção 7.5 mencionou que o tamanho da diferença entre dois grupos é algumas vezes resumido pelo *tamanho do efeito*, o qual para duas amostras é definido como $(\bar{y}_1 - \bar{y}_2)/s$. Quando as distribuições apresentam assimetrias acentuadas ou têm valores atípicos, as médias são tão úteis e o resultado do tamanho do efeito pode não ser apropriado. Uma medida do tamanho do efeito não paramétrica é a proporção dos pares das observações (uma para cada grupo) para a qual a observação do primeiro grupo era maior. Se y_1 representa uma observação aleatoriamente selecionada do Grupo 1 e y_2 representa uma observação aleatoriamente selecionada do Grupo 2, então essa medida estima $P(y_1 > y_2)$.

Para ilustrar, suponha que o estudo da anorexia tinha 4 meninas, 2 usando a nova terapia e 2 no grupo de controle. Suponha que as mudanças do peso foram:

Grupo com terapia (y_1): 4, 10
Grupo de controle (y_2): 2, 6

Existem quatro pares de observações, com uma em cada grupo:

$y_1 = 4, y_2 = 2$ (A do grupo 1 é maior)
 $y_1 = 4, y_2 = 6$ (A do grupo 2 é maior)
 $y_1 = 10, y_2 = 2$ (A do grupo 1 é maior)
 $y_1 = 10, y_2 = 6$ (A do grupo 1 é maior)

A observação do Grupo 1 é maior em 3 dos 4 pares, assim a estimativa de $P(y_1 > y_2)$ é de 0,75. Se duas observações tivessem o mesmo valor, iríamos contá-la como y_1 sendo maior para $\frac{1}{2}$ do par (em vez de 1 ou 0). Sob H_0 (sem efeito), $P(y_1 > y_2) = 0,50$. Quanto mais longe $P(y_1 > y_2)$ está de 0,50, mais forte o efeito. Para todo o conjunto de dados da anorexia analisado no Exemplo 7.7 na página 226, a estimativa da amostra de $P(y_1 > y_2)$ é de 0,63. A probabilidade estimada de que uma menina usando a te-

rapia cognitivo-comportamental tenha um ganho de peso maior do que uma menina usando a terapia de controle é de 0,63.

Quando os dois grupos têm distribuições normais com o mesmo desvio padrão, existe uma conexão entre esse tamanho do efeito e o do paramétrico, $(\mu_1 - \mu_2)/\sigma$. Por exemplo, quando $(\mu_1 - \mu_2)\sigma = 0$, então $P(y_1 > y_2) = 0,50$; quando $(\mu_1 - \mu_2)/\sigma = 0,5$, então $P(y_1 > y_2) = 0,64$; quando $(\mu_1 - \mu_2)/\sigma = 1$, então $P(y_1 > y_2) = 0,71$; quando $(\mu_1 - \mu_2)/\sigma = 2$, então $P(y_1 > y_2) = 0,92$. O efeito é relativamente forte se $P(y_1 > y_2)$ for maior do que aproximadamente 0,70 ou menor do que aproximadamente 0,30.

Tratando as variáveis ordinais como quantitativas

Os cientistas sociais geralmente usam os métodos de estatística paramétrica para dados quantitativos com variáveis que são somente ordinais. Eles fazem isto atribuindo escores às categorias ordenadas. O Exemplo 6.2 (página 175), sobre ideologia política, mostrou um exemplo disso. Algumas vezes a escolha dos escores é direta. Para categorias (liberal, moderado, conservador) para a ideologia política, todo o conjunto de escores igualmente espalhados é lógico, como (1, 2, 3) ou (0, 5, 10). Quando a escolha não for clara, como com as categorias (não muito feliz, moderadamente feliz, muito feliz) para a felicidade, é uma boa ideia executar um estudo de sensibilidade. Escolha dois ou três conjuntos razoáveis de escores potenciais, como, por exemplo, (0, 5, 10), (0, 6, 10), (0, 7, 10), e verifique se as conclusões finais são similares para cada um. Se não, qualquer relatório deveriaressaltar como as conclusões dependem dos escores escolhidos.

De forma alternativa, os métodos não paramétricos são válidos com os dados originais. A razão é que os métodos não paramétricos não usam escores quantitativos, mas classificações das observações, e elas são informações ordinárias. Entretanto, esta abordagem funciona melhor quando a variável resposta é contínua (ou aproximadamente), assim cada observação tem a sua própria classificação. Quando usados com respostas categóricas ordenadas, tais métodos são geralmente menos sensíveis do que quando usamos os métodos paramétricos que tratam a resposta como quantitativa, como o próximo exemplo ilustra.

EXEMPLO 7.10 O consumo do álcool e má-formação do bebê

A Tabela 7.9 refere a um estudo do consumo de álcool por grávidas e da má-formação congênita. Após os três primeiros meses de gravidez, as mulheres da amostra completaram um questionário sobre o consumo de álcool. Depois do nascimento da criança, as observações foram registradas sobre a presença ou ausência de má-formação congênita dos órgãos genitais. O consumo de álcool foi mensurado como o número médio de drinques por dia.

O consumo de álcool está associado à má-formação? Uma abordagem para investigar isso é comparar o consumo médio de álcool de mães para os casos em que a má-formação ocorreu ao consumo por mães onde ela não ocorreu. O consumo de álcool foi mensurado agrupando valores de álcool de mães para os casos em que a má-formação é variável quantitativa. Para encontrar as médias, atribuímos escores ao consumo de álcool que são meios pontos das categorias; isto é, 0,5, 1,5, 4,0, 7,0, o último escore ($para \geq 6$) sendo arbitrário. As médias amostrais são, então, 0,28 para o grupo da ausência e 0,40 para o grupo da presença, e a estatística t de 2,56 tem um valor- p de 0,01. Existe uma forte evidência de que as mães cujos bebês sofreram má-formação tinham uma média mais alta do consumo de álcool. Uma abordagem alternativa não paramétrica atribui classificações aos sujeitos e as usa como as categorias dos escores. Para todos os sujeitos em uma categoria,

Tabela 7.9 Má-formação dos bebês e o consumo de álcool pelas mães

| Má-Formação | Consumo de álcool | | | | |
|-------------|-------------------|-------|-----|-----|-----|
| | 0 | < 1 | 1-2 | 3-5 | ≥ 6 |
| Ausência | 17066 | 14464 | 788 | 126 | 37 |
| Presença | 48 | 38 | 5 | 1 | 1 |
| Total | 17114 | 14502 | 793 | 127 | 38 |

JUNE. SKJELVÅG, B. I., KURN, E. L. *Biometrics*, v. 43, p. 471-76, 1987.

atribuímos a média das classificações que se aplicaria a uma classificação completa da amostra. Elas são chamadas de *escores do meio*. Por exemplo, os 17114 sujeitos no nível 0 para o consumo de álcool dividem a classificação 1 a 17114. Atribuímos a cada um deles a média dessas classificações, que é o escore do meio ($1 + 17114)/2 = 857,5$. Os 14502 sujeitos no nível < 1 para o consumo de álcool dividem as classificações 17115 a 31615 + 14502 = 31616, para um escore do meio de $(17115 + 31616)/2 = 24365,5$. Da mesma forma, os escores do meio para as três últimas categorias são 32013, 32473 e 32555,5. Usados, em um teste Wilcoxon para grandes amostras, esses escores geram muito menos evidência de um efeito (valor- $p = 0,55$).

Tabela 7.10 Resumo dos métodos de comparação para dois animais novos amostrados

| | Tipo de Variável resposta |
|------------|---------------------------|
| Categórica | Quantitativa |

1. Parâmetro $\pi_2 - \pi_1$
2. Estimativa por ponto $\hat{\pi}_2 - \hat{\pi}_1$
3. Erro padrão $\sqrt{\frac{\hat{\pi}_1(1-\hat{\pi}_1)}{n_1} + \frac{\hat{\pi}_2(1-\hat{\pi}_2)}{n_2}}$

| | | |
|---------------------------|---|--|
| 4. Intervalo de confiança | $(\hat{\pi}_2 - \hat{\pi}_1) \pm z(ep)$ | $(\bar{y}_2 - \bar{y}_1) \pm t(ep)$ |
| Teorema da média | $\sqrt{\frac{\hat{\pi}_1(1-\hat{\pi}_1)}{n_1}} + \sqrt{\frac{\hat{\pi}_2(1-\hat{\pi}_2)}{n_2}}$ | $\sqrt{\frac{s^2}{n_1} + \frac{s^2}{n_2}}$ |

Leste de significância

- | 1. Suposições | Aleatorização |
|----------------------|--|
| 2. Hipóteses | ≥ 10 observações em cada categoria, para cada grupo |
| 3. Estatística-teste | Distribuições normais (robusta, especialmente para n grande) |
| | $H_0: \pi_1 = \pi_2$ $(\pi_2 - \pi_1 = 0)$ $H_a: \pi_1 \neq \pi_2$ |
| | $H_0: \mu_1 = \mu_2$ $(\mu_2 - \mu_1 = 0)$ $H_a: \mu_1 \neq \mu_2$ |

4. Valor- p

Floabilidade bilateral da normal padrão ou
(Use a alternativa unilateral)

Este capítulo introduziu métodos para comparação de dois grupos. Para variáveis resposta quantitativas, as inferências se aplicam à diferença $\mu_2 - \mu_1$ entre as médias populacionais. Para variáveis resposta categóricas, as inferências se aplicam à diferença $\pi_2 - \pi_1$ entre as proporções populacionais.

Em cada caso, o teste de significância analisa se 0 é uma diferença plausível. Se o intervalo de confiança contém 0 , é plausível que os parâmetros sejam iguais. A Tabela

7.8 RESUMO DO CAPÍTULO

- Para comparar proporções, com amostras independentes e pequenas o teste adequado é o exato de Fisher. Para amostras dependentes, o teste de McNemar compara o número de sujeitos que estão na categoria 1 na primeira amostra e na categoria 2 na segunda ao número de sujeitos que estão na categoria 2 na primeira amostra e na categoria 1 na segunda.
 - Os métodos estatísticos não paramétricos não fazem suposição sobre a forma da distribuição da população. A maioria dos métodos usa os escores (postos) das observações.

Por que isso acontece? As categorias adjacentes que têm relativamente poucas observações necessariamente têm escorres do meio similares. Os escorres do meio (8557.5, 24365.5, 32013, 32473, 32555.5) são similares para as três categorias finais, visto que essas categorias têm consideravelmente menos observações do que as duas primeiras categorias. Uma consequência é

Diferença estimada \pm (escore)(ep),

- Para amostras **dependentes**, cada observação em uma amostra se equipara a uma na outra amostra. Para variáveis quantitativas, comparamos médias analisando a diferença das médias dos escores calculada entre as observações pareadas. O intervalo das **diferenças pareadas** e procedimentos dos testes são métodos de uma amostra dos Capítulos 5 e 6 aplicados à diferença dos escores.
 - Outra abordagem para comparar médias faz a suposição extra de que as distribuições da população normal têm desvios padrão iguais. Essa abordagem agrupa os desvios padrão das duas amostras para encontrar uma estimativa comum.
 - Para comparar proporções, com amostras independentes e pequenas o teste adequado é o **exato de Fisher**. Para amostras dependentes, o teste de **McNemar** compara o número de sujeitos que estão na categoria 1 na primeira amostra e na categoria 2 na segunda ao número de sujeitos que estão na categoria 2 na primeira amostra e na categoria 1 na segunda.
 - Os métodos estatísticos **não paramétricos** não fazem suposição sobre a forma da distribuição da população. A maioria dos métodos usa os escores (postos) das observações.

Nesse estágio, você pode estar confuso sobre qual método usar para qualquer situação dada. Talvez possa ajudar se você seguir a seguinte lista de verificações. Pergunte a você mesmo se a análise é sobre

- Médias ou proporções (variável resposta quantitativa ou categórica)?
- Amostras independentes ou dependentes?
- Intervalo de confiança ou teste de significância?

EXERCÍCIOS

Praticando o básico

7.1 Uma matéria da Associated Press (23 de fevereiro de 2007) sobre o levantamento de dados anual dos calouros da UCLA indicou que 73% dos calouros da faculdade em 2006 consideravam que ser financeiramente próspero era muito importante, comparado com 42% em 1966 (o primeiro ano em que o levantamento de dados foi feito). A matéria também relatou que 81% dos jovens entre 18 e 25 anos nos Estados Unidos consideraram ficar rico como principal objetivo na vida. Os percentuais amostrais de 42% em 1966 e 73% em 2006 são baseados em amostras independentes ou amostras dependentes? Explique.

7.2 *Transatlantic Trends* é um levantamento de dados anual da opinião pública norte-americana e europeia (veja www.transatlantictrends.org), com uma amostra aleatória de aproximadamente 1000 adultos de cada um de 13 países europeus a cada ano. Em 2002, 38% dos europeus expressaram uma atitude positiva sobre o tratamento das questões internacionais pelo presidente George W. Bush. Em 2006, 18% expressaram uma atitude positiva.

(a) Explique o significado desses resultados se eles forem baseados em (a) amostras independentes, (b) amostras dependentes.

(b) Se compararmos os resultados de 2002 e 2006, identifique a variável resposta e a variável explicativa e especifique se a variável resposta é quantitativa ou categórica.

7.3 O National Health Interview Survey (Levantamento Nacional com Entrevi-

- 2002 e encontre e interprete o erro padrão da estimativa.
- (b) Mostre que a média estimada em 2002 era de 1,17 vezes a média estimada de 1962. Expressse isto em termos de percentual de aumento.
- (c) Os pesos médios estimados para homens eram de 166 libras em 1962 e 191 libras em 2002. Encontre e interprete a diferença e a razão.

- 7.6** A U.S. Census Bureau (Agência do Censo dos Estados Unidos) relatou em 2002 que o rendimento líquido mediano nos Estados Unidos foi estimado em aproximadamente \$39000 para domicílios brancos e \$36000 para domicílios negros.
- (a) Identifique a variável resposta e a variável explicativa.
- (b) Compare os grupos usando uma (i) diferença, (ii) razão.

- 7.7** De acordo com o U.S. Department of Justice (Departamento de Justiça dos Estados Unidos), em 2002 a taxa de encarceramento nas prisões nacionais era de 832 por 100000 moradores masculinos e 38 por 100000 moradores femininos.
- (a) Encontre o risco relativo de estar preso, comparando homens a mulheres. Interprete.
- (b) Encontre a diferença das proporções encarceradas. Interprete.

- (c) Quai das medidas você acha que representa melhor estes dados? Por que?
- 7.8** De acordo com o U.S. National Center for Health Statistics (Centro Nacional da Estatística da Saúde dos Estados Unidos), a probabilidade anual de que um homem com idade entre 20 a 24 seja uma vítima de homicídio é aproximadamente 0,00164 para negros e 0,00015 para brancos.
- (a) Compare estas taxas usando a diferença de proporções.

- (b) Compare estas taxas usando o risco relativo.
- (c) Qual das duas medidas parece resumir melhor os resultados quando ambas as proporções estão muito próximas a 0? Explique.

- 7.9** Uma matéria da Associated Press (7 de agosto de 2006) sobre uma pesquisa investigando o impacto sobre os adolescentes de letras de músicas com conteúdo sexual relatou: "Os adolescentes que disseram que escutavam muitas músicas com mensagens sexuais degradantes tinham aproximadamente duas vezes mais probabilidade de iniciar relações sexuais... dentro dos dois anos seguintes do que os adolescentes que escutavam pouca ou nenhuma música com mensagens sexuais degradantes". Os percentuais relatados foram 51% e 29%.
- (a) Um intervalo de 95% de confiança para a diferença entre as proporções populacionais correspondentes é (0,18; 0,26). Explique como interpretá-lo.
- (b) O valor-*p* é < 0,001 para testar a hipótese nula de que as proporções populacionais correspondentes são iguais. Interprete.

- 7.10** Para uma amostra aleatória de canadenses, 60% indicam que aprovam o desempenho do primeiro ministro. Uma pesquisa similar, um mês depois, teve uma avaliação favorável de 57%. Um intervalo de 99% de confiança para a mudança nas proporções populacionais foi de (-0,07; 0,01). Explique por que (a) pode não ter tido mudança no apoio, (b) se uma diminuição no apoio ocorreu, pode ter sido muito importante, (c) se um aumento do apoio ocorreu, ele foi provavelmente pequeno para ter uma importância substancial.
- 7.11** O College Alcohol Study (Estudo do Álcool na Faculdade) da Harvard School of Public Health (Escola de Saúde Pública de Harvard) entrevistou amostras aleatórias de estudantes do quarto ano da faculdade várias vezes desde 1993. Dos estudantes que disseram consumir álcool, o percentual que alegou que beber "para ficar bêbado" é um motivo importante para consumir álcool foi de 39,9% de 12708 estudantes em 1993 e 48,2% dos 8783 estudantes em 2001. Para comparar os resultados entre 1993 e 2001:

- (a) Mostre que o erro padrão para a diferença da estimativa entre as proporções populacionais correspondentes em 2001 e em 1993 é igual a 0,0069.
- (b) Mostre que o intervalo de 95% de confiança para a diferença é (0,07; 0,10). Interprete.

7.12 No estudo mencionado no exercício anterior, o percentual que disse que mantiveram atividades sexuais não planejadas por causa da ingestão de álcool foi de 19,2% em 1993 e 21,3% em 2001.

- (a) Especifique as suposições, notação e hipóteses para um teste bilateral comparando as proporções populacionais correspondentes.
- (b) A estatística-teste foi $Z = 3.8$ e o valor- $p = 0,0002$. Interprete o valor- p .

(c) Alguém pode argumentar que o resultado em (b) reflete *significância estatística*, mas não *significância prática*. Explique a base desse argumento e justifique por que você tem mais informação em um intervalo de 95% de confiança, que é (0,009; 0,03).

7.13 Para o Levantamento do Uso do Tempo da Tabela 7.1 (página 212), para aqueles que trabalham em tempo integral, 55% dos 1219 homens e 74% das 733 mulheres relataram que gastam algum tempo cozinhando e limpando em um dia típico. Encontre e interprete um intervalo de 95% de confiança para a diferença na participação das tarefas.

7.14 A Tabela 7.11 resume as respostas de Pesquisas Sociais Gerais de 1977 e de 2006 à pergunta ("FEFAM"): "É melhor para todos envolvidos se o homem é o empregador fora de casa e a mulher é a que toma conta da casa e da família". Considere π_1 a representação da proporção da população que concordou com essa afirmação em 1977 e considere π_2 a representação da proporção da população em 2006.

- (a) Mostre que $\hat{\pi}_1 - \hat{\pi}_2 = 0,30$, com erro padão 0,0163.
- (b) Mostre que um intervalo de 95% de confiança para $\pi_1 - \pi_2$ é (0,27; 0,33). Interprete.
- (c) Explique como os resultados iriam diferir para a comparação das pro-

porções daqueles que *não* concordam nos dois anos.

| <input checked="" type="checkbox"/> Tabela 7.11 | | | |
|---|----------|----------|-------|
| Ano | Concorda | Discorda | Total |
| 1977 | 989 | 514 | 1503 |
| 2006 | 704 | 1264 | 1968 |

7.15 Considere o exercício anterior sobre o papel da mulher. Em 2004, dos 411 respondentes homens, 153 (37,2%) responderam *sim*. Das 472 respondentes mulheres, 166 (35,2%) responderam *sim*.

- (a) Estabeleça uma notação e especifique as hipóteses para a suposição de nenhuma diferença entre as proporções da população de homens e mulheres que iriam responder *sim*.
- (b) Estime a proporção da população presumindo H_0 , encontre o erro padrão da diferença das proporções amostrais e encontre a estatística-teste.
- (c) Encontre o valor- p para a alternativa bilateral. Interprete.

(d) Dos 652 respondentes tendo menos educação do que o grau universitário, 40,0% responderam *sim*. Dos 231 respondentes tendo pelo menos grau universitário, 25,6% responderam *sim*. Qual variável, gênero ou nível de educação parece ter tido maior influência na opinião? Em outras palavras, a opinião tende a diferir mais entre homens e mulheres ou entre aquele com maior ou menor nível de educação?

7.16 Em um levantamento de dados conduzido pela Wright State University, foi perguntado aos formandos se eles haviam, alguma vez, usado maconha. A Tabela 7.12 mostra a saída do software. Tratando essas observações como uma amostra aleatória da população de interesse:

- (a) Faça uma pergunta de pesquisa que poderia ser respondida com essa saída.
- (b) Interprete o intervalo de confiança apresentado.
- (c) Interprete o valor- p apresentado.

| <input checked="" type="checkbox"/> Tabela 7.12 | | | |
|---|-----|------|--------------------|
| Amostra | Sim | N | Proporção amostral |
| 1. Mulher | 445 | 1120 | 0,3973 |
| 2. Homem | 515 | 1156 | 0,4455 |

Estimativa para $p(1) - p(2)$: (-0,0887, -0,0482)
IC 95% para $p(1) - p(2)$: (-0,0887, -0,0077)
Teste para a diferença = 0 (versus $\neq 0$):
 $z = -2,33$ valor- $p = 0,020$

7.17 Um estudo sobre o comportamento compulsivo de fazer compras (comprado incontrolável de comprar) realizou um levantamento de dados nacional por telefone em 2004 com adultos com 18 anos e acima.⁷ De 800 homens, 44 foram julgados como compradores compulsivos de acordo com a Escala de Compras Compulsivas. Das 1501 mulheres, 90 foram julgadas como compradoras compulsivas. Conduta uma inferência para analisar se um sexo tem maior probabilidade do que o outro de ser um comprador compulsivo. Interprete.

- 7.18 A Tabela 7.13 mostra os resultados de uma Pesquisa Social Geral recente com duas variáveis, sexo e se a pessoa acredita na vida após a morte ("AFTERLIF"). Conduza todas as etapas de um teste de significância, usando $\alpha = 0,05$, para comparar as proporções populacionais de mulheres e homens que responderam que acreditam na vida após a morte. Se você cometer um erro na sua decisão, que tipo de erro seria? Do Tipo I ou do Tipo II?

7.19 Uma PSG relatou que as 486 mulheres tinham uma média de 8,3 bons amigos ($s = 15,6$) e 354 homens tinham uma média de 8,9 bons amigos ($s = 15,5$).

| <input checked="" type="checkbox"/> Tabela 7.14 | | | |
|---|--------------------|-------|---------------|
| Horas do trabalho doméstico | | | |
| Gênero | Tamanho da amostra | Média | Desvio padrão |
| Homens | 292 | 8,4 | 9,5 |
| Mulheres | 391 | 12,8 | 11,6 |

7.20 A Tabela 7.14 resume o número de horas gastas no trabalho doméstico, por-semana e por gênero, baseado na PSG de 2002 (variável "RHWWORK").

- (a) Estime a diferença entre as médias populacionais para mulheres e homens.
- (b) Mostre que o erro padrão estimado da diferença da amostra é de 0,81. Interprete.

(c) Mostre que um intervalo de 99% de confiança para a diferença é de (2,3; 6,5). Interprete.

| <input checked="" type="checkbox"/> Tabela 7.15 | | | |
|---|-----|-----------------|-------|
| Acredita na vida após a morte | | | |
| Sexo | Sim | Não ou Indeciso | Total |
| Mulher | 435 | 147 | 582 |
| Homem | 375 | 134 | 509 |

7.21 Um estudo de 30 dias avaliou o grau de dependência que os adolescentes têm quando iniciam sua experiência com o fumo.⁸ O estudo usou uma amostra aleatória de 332 estudantes da 7^a série de duas cidades de Massachusetts que nunca haviam fumado antes do início do estudo. A variável resposta foi construída da Hooked on Nicotine Checklist (HONC). Esta é uma lista de 10 perguntas como: "Você já tentou parar, mas não conseguiu?". O escorrido HONC é o número total de perguntas às quais o estudante respondeu *sim*.

Quanto mais alto o escorrido, maior a dependência da nicotina. Havia 75 fumantes e 257 ex-fumantes no final do estudo. As médias da HONC descrevendo a dependência da nicotina foram 5,9 (s = 3,3); Interprete.

7.22

= 3,3) para os fumantes e 1,0 ($s = 2,3$) para ex-fumantes.

(a) Encontre e interprete uma estimativa por ponto para comparar as médias da HONC para fumantes e ex-fumantes.

(b) O software relata um intervalo de 95% de confiança como sendo (4,1; 5,7). Interprete.

(c) A distribuição dos dados amostrais da HONC para os ex-fumantes era aproximadamente normal? Como isto afeta a inferência?

7.22 Considere o Exercício 7.17 sobre o comportamento compulsivo de comprar. O total da fatura do cartão de crédito apresentou uma média de \$3399 com desvio padrão de \$595 para 100 compradores compulsivos e uma média de \$2837 com desvio padrão de \$6335 para outros 1682 respondentes.

(a) Estime a diferença entre as médias para compradores compulsivos e outros respondentes e encontre o erro padrão.

(b) Compare as médias populacionais usando um teste de significância bilateral. Interprete.

7.23 Uma PSG recente perguntou: "Em quantos dias, nos últimos 7 dias, você esteve triste?" O software relatou médias amostrais de 1,8 para mulheres e 1,4 para homens, com um intervalo de 95% de confiança comparando-as de (0,2; 0,6), uma estatística t de 4,8 e um valor- p de 0,000. Interprete esses resultados.

7.24 Para a PSG de 2006, uma comparação entre mulheres e homens quanto ao número de horas por dia assistindo à televisão forneceu os seguintes resultados:

| Grupo | N | Média | Desvio Padrão | EP da média |
|----------|------|-------|---------------|-------------|
| Mulheres | 1117 | 2,99 | 2,34 | 0,070 |
| Homens | 870 | 2,86 | 2,22 | 0,075 |

- (a) Realize todas as etapas de um teste de significância para analisar se as médias populacionais diferem

para homens e mulheres. Interprete o valor- p e relate a sua conclusão para um nível $\alpha = 0,05$.

(b) Se você fosse construir um intervalo de 95% de confiança comparando as médias, ele iria conter 0? Responda com base no resultado em (a), sem encontrar o intervalo.

(c) Você acha que a distribuição do número de horas assistindo à televisão é aproximadamente normal? Por que ou por que não? Isto afeta a validade de suas inferências?

7.25 Para a PSG de 2004, a Tabela 7.15 mostra a saída do software para avaliar o número de horas assistindo à televisão por dia por raça.

Tabela 7.15

| Raça | N | Média | Desv. | EP da média |
|--------|-----|-------|-------|-------------|
| Negra | 101 | 4,09 | 3,63 | 0,3616 |
| Branca | 724 | 2,59 | 2,31 | 0,0859 |

Diferença = $\mu_{\text{negra}} - \mu_{\text{branca}}$
Estimativa para a diferença: 1,50
IC de 95% para a diferença: (0,77; 2,23)
Teste t da diferença = 0: Valor- $t = 4,04$,
valor- $p = 0,000$

(a) Interprete o intervalo de confiança encontrado. Você pode concluir que uma das médias populacionais é mais alta? Se pode, qual? Explique.

(b) Interprete o valor- p encontrado.

(c) Explique a conexão entre o resultado do teste de significância e o resultado do intervalo de confiança.

7.26 Um estudo⁹ comparou características da personalidade entre filhos adultos de alcoólatras e um grupo de controle equiparado por idade e gênero. Para os 29 pares de mulheres, os autores relataram uma média de 24,8 para o bem-estar dos filhos dos alcoólatras e uma média de 29,0 para o grupo de controle. Eles relataram $t = 2,67$ para o teste comparando as médias. Supondo que esse é o resultado de uma análise de amostras dependentes, identifique o g da estatística- t , determine e interprete o valor- p .

7.27 Um experimento de diferenças pareadas¹⁰, tratando do tempo de reação a um ruído, sob duas condições, utilizou uma amostra de crianças de 9 meses e encontrou uma diferença média de 70,1 com um desvio padrão de 49,4 para a diferença. Na sua argumentação, os autores relataram uma estatística t de 4,9, tendo um valor- $p < 0,01$ para uma alternativa bilateral. Mostre como eles construíram a estatística t e confirme o valor- p .

7.28 Como parte do seu projeto de aula, uma estudante da Universidade da Flórida selecionou aleatoriamente 10 colegas estudantes para investigar suas atividades sociais mais comuns. Como parte do estudo, ela pediu aos estudantes para declarar quantas vezes elas fizeram cada uma das seguintes atividades durante o ano anterior: ir ao cinema, ir a um evento esportivo ou ir a uma festa. A Tabela 7.16 mostra os dados.

(a) Interprete o valor- p .
(b) Explique a conexão entre os resultados do teste e o intervalo de confiança.

7.29 Considere o exercício anterior. Para comparar ida a festas e a eventos esportivos, o software mostra um intervalo de 95% de confiança de (-3,33; 28,93) e um valor- p de 0,106.

(a) Interprete o valor- p .
(b) Explique a conexão entre os resultados do teste e o intervalo de confiança.

7.30 Uma psicóloga clínica quer escolher entre duas terapias para tratar a depressão. De seis pacientes, ela seleciona aleatoriamente três para receber a terapia A e os outros três recebem a terapia B. Ela utiliza pequenas amostras por razões éticas, pois se o seu experimento indicar que uma terapia é superior, então ela será usada nos demais pacientes com os mesmos sintomas. Após um mês de tratamento, a melhora é medida pela mudança na escala padronizada de gravidade da depressão. Os escores da melhora são 10, 20, 30 para os pacientes que recebem a terapia A e 30, 45, 45 para os pacientes que recebem a terapia B.

(a) Usando um método que supõe um desvio padrão comum para as duas terapias, mostre que o t combinado = 9,35 e o $p = 7,64$.

- (b) Quando os tamanhos da amostra são muito pequenos, pode valer a pena sacrificar alguma confiança para conseguir maior precisão.

dada. Relate o valor- p e interprete-o no contexto.

Tabela 7.16

| Atividade | Estudante | | | Atividade |
|-----------|-----------|----------|--------|-----------|
| | Cinema | Esportes | Festas | |
| | 1 | 10 | 5 | |
| | 2 | 4 | 0 | |
| | 3 | 12 | 20 | |
| | 4 | 2 | 6 | |
| | 5 | 12 | 2 | |
| | 6 | 7 | 8 | |
| | 7 | 45 | 12 | |
| | 8 | 1 | 25 | |
| | 9 | 25 | 0 | |
| | 10 | 12 | 12 | |

7.31 Considere o exercício anterior. Para comparar ida a festas e a eventos esportivos, o software mostra um intervalo de (-3,33; 28,93) e um valor- p de 0,106.

(a) Interprete o valor- p .
(b) Explique a conexão entre os resultados do teste e o intervalo de confiança.

7.32 Considere o exercício anterior. Para comparar ida a festas e a eventos esportivos, o software mostra um intervalo de (-3,33; 28,93) e um valor- p de 0,106.

(a) Interprete o valor- p .
(b) Explique a conexão entre os resultados do teste e o intervalo de confiança.

7.33 Considere o exercício anterior. Para comparar ida a festas e a eventos esportivos, o software mostra um intervalo de (-3,33; 28,93) e um valor- p de 0,106.

- (a) Interprete o valor- p .
(b) Explique a conexão entre os resultados do teste e o intervalo de confiança.

7.34 Considere o exercício anterior. Para comparar ida a festas e a eventos esportivos, o software mostra um intervalo de (-3,33; 28,93) e um valor- p de 0,106.

(a) Interprete o valor- p .
(b) Explique a conexão entre os resultados do teste e o intervalo de confiança.

- (a) Interprete o valor- p .
(b) Explique a conexão entre os resultados do teste e o intervalo de confiança.

(c) Mostre como a estatística-teste apresentada na saída computacional foi obtida da outra informação

Mostre que um intervalo de 90% de confiança para $(\mu_2 - \mu_1)$ é (3,7; 36,3). Interprete.

- (c) Estime e resuma o tamanho do efeito.
- 7.31 Considere o exercício anterior. Para evitar tendenciosidade das amostras não sendo balanceadas com um n tão pequeno, a psicóloga delineta novamente o experimento. Ela forma três pares de sujeitos, tal que os pacientes equiparados em qualquer par dado sejam similares em saúde e status socioeconômico. Para cada par, ela seleciona aleatoriamente um sujeito para cada terapia. A Tabela 7.17 mostra os escores da melhora e a Tabela 7.18 mostra os resultados usando o SPSS para analisar os dados.

- (a) Compare as médias (i) encontrando a diferença das médias amostrais para as duas terapias, (ii) encontrando a média da diferença dos escores. Compare.
- (b) Verifique o desvio padrão das diferenças e o erro padrão para a diferença média.
- (c) Verifique o intervalo de confiança mostrado para a diferença média populacional. Interprete.
- (d) Verifique a estatística-teste, o g_1 e o valor- p para comparar as médias. Interprete.

Tabela 7.17

| | Par | Terapia A | Terapia B |
|---|-----|-----------|-----------|
| 1 | 10 | 30 | |
| 2 | 20 | 45 | |
| 3 | 30 | 45 | |

- 7.32 Um estudo¹¹ sobre bulimia entre universitárias considerou o efeito do abuso sexual na infância em vários componentes de uma Escala do Ambiente Familiar. Para uma medida da coesão da família, a média amostral para os estudantes bulímicos era de 2,0 para as 13 estudantes que sofreram abuso sexual e de 4,8 para as 17 estudantes que não sofreram abuso sexual. A Tabela 7.19 mostra os resultados do software de uma comparação de médias de duas amostras.

- (b) Explique como interpretar os resultados dos testes de significância desta saída.
- 7.33 Para o levantamento de dados dos estudantes descritos no Exercício 1.11 (página 25), as respostas sobre a ideologia política tinham uma média de 3,18 e um desvio padrão de 1,72 para os 51 estudantes não vegetarianos e uma média de 2,22 e desvio padrão de 0,67 para os 9 estudantes vegetarianos. Quando usamos um software para comparar as médias com um teste de significância, obtemos:

Tabela 7.19

| Variável: coesão | N | Média | DP | Erro Padrão |
|------------------|------|-------|-------|-------------|
| sim | 13 | 2,0 | 2,1 | 0,58 |
| não | 17 | 4,8 | 3,2 | 0,78 |
| Desiguals | 2,89 | 27,5 | 0,007 | |
| Iguais | 2,73 | 28 | 0,011 | |

- (a) Teste t para amostras emparelhadas.
- Tabela 7.18

Número de Pares

| Variável | 3 | Média | DP | EP da média |
|-------------------------|--------|-------------|---------|----------------------|
| TERAPIA A | 20,000 | 10,000 | 5,774 | |
| TERAPIA B | 40,000 | 8,660 | 5,000 | |
| Diferenças Pareadas | | | | |
| Média | DP | EP da media | Valor-t | g_1 Sig. bilateral |
| 20,000 | 5,00 | 2,887 | 6,93 | 2 0,020 |
| IC de 95% (7,58; 32,42) | | | | |

- (a) Supondo os desvios padrão populacionais iguais, construa um intervalo de 95% de confiança para a diferença na coesão média familiar para estudantes que sofreram abuso sexual e das que não sofreram. Interprete.

- (b) Explique como interpretar os resultados dos testes de significância desta saída.
- 7.33 Para o levantamento de dados dos estudantes descritos no Exercício 1.11 (página 25), as respostas sobre a ideologia política tinham uma média de 3,18 e um desvio padrão de 1,72 para os 51 estudantes não vegetarianos e uma média de 2,22 e desvio padrão de 0,67 para os 9 estudantes vegetarianos. Quando usamos um software para comparar as médias com um teste de significância, obtemos:

| Variâncias | T | GL | Valor-P |
|------------|-------|------|---------|
| Desiguais | 2,915 | 30,9 | 0,0066 |
| Iguais | 1,636 | 58,0 | 0,1073 |

- Explique por que os resultados dos dois testes diferem tanto e dê a sua própria conclusão sobre se as médias populacionais são iguais.

- 7.34 Em 2006, a PSG perguntou sobre o número de horas por semana gastas na web ("WWWTIME"). As 1569 mulheres apresentaram uma média de 4,9 com um desvio padrão de 8,6. Os 1196 homens apresentaram uma média de 6,2 com um desvio padrão de 9,9. Use esses resultados para fazer uma inferência comparando mulheres e homens em WWWTIME na população, supondo desvios padrão populacionais iguais.

- 7.35 Dois novos cursos foram propostos para ajudar os estudantes que sofrem de fobia severa a matemática, tendo um escor de pelo menos 8 em uma medida de fobia de matemática que está entre 0 e 10 (com base em respostas a 10 questões). Uma amostra de 10 estudantes foi aleatoriamente aloçada para os dois cursos. Após o curso, a queda no escore de

- fobia da matemática foi registrada. Os valores amostrais foram:

- Curso A: 0, 2, 2, 3, 3
Curso B: 3, 6, 6, 7, 8

- (a) Faça uma comparação inferencial das médias supondo desvios padrão populacionais iguais. Interprete os seus resultados.

- (b) Usando software, relate e interprete o valor- p para o teste bilateral de Wilcoxon.

- (c) Encontre e interprete o tamanho do efeito $(\bar{Y}_B - \bar{Y}_A)/s$.

- (d) Estime e interprete o tamanho do efeito $P(Y_B > Y_A)$.

- 7.36 Uma PSG perguntou às pessoas se elas acreditavam no paraíso ou no inferno. Dos 1120 sujeitos entrevistados, 833 acreditavam em ambos, 160 acreditavam em nenhum, 125 acreditavam no paraíso, mas não no inferno e 2 acreditavam no inferno, mas não no paraíso.

- (a) Exiba os dados em uma tabela de contingência, cruzando a crença no paraíso (*sim, não*) com a crença no inferno (*sim, não*).

- (b) Estime a proporção populacional de quem acredita no paraíso e de quem acredita no inferno.

- (c) Mostre todas as etapas do teste McNemar para comparar as proporções populacionais e interprete.

- (d) Construa um intervalo de 95% de confiança para comparar as proporções populacionais e interprete.

- 7.37 Uma PSG perguntou às pessoas a opinião sobre o gasto do governo com a saúde e com policiamento. Em cada situação o gasto deve aumentar ou diminuir? A Tabela 7.20 mostra as opiniões.

- (a) Encontre a proporção amostral a favor do aumento do gasto para cada item.
- (b) Teste se as proporções populacionais são iguais. Determine o valor- p e interprete.
- (c) Construa um intervalo de 95% de confiança para a diferença das proporções. Interprete.

| <input checked="" type="checkbox"/> Tabela 7.20 | | Gasto com policiamento | |
|---|----------|------------------------|--|
| Gasto com saúde | Aumentar | Diminuir | |
| Aumentar | 292 | 25 | |
| Diminuir | 14 | 9 | |

7.38 Um estudo¹² usou dados do Estudo Longitudinal do Envelhecimento para investigar como a saúde e as características sociais de pessoas idosas são influenciadas pela convivência com os seus filhos. Considere a Tabela 7.21, que mostra se um idoso mora com um filho em um dado momento e, então novamente, quatro anos mais tarde. O autor suspeitava que, à medida que as pessoas envelhecessem e a saúde deteriorava, elas teriam maior probabilidade de viver com um filho. Os dados confirmam essa suspeita? Justifique a sua resposta com uma análise inferencial.

- 7.39 Um estudo¹³ investigou a orientação sexual de adultos que foram criados em famílias lésbicas. Vinte e cinco crianças de mães lésbicas e um grupo de controle de 20 crianças de mães heterossexuais foram vistos com a idade de 10 anos e, novamente, com a idade de 10 anos e, de 24 anos. Com a idade mais avançada, eles foram entrevistados sobre sua identidade sexual, com respostas possíveis *Bissexual/Lésbica/Homossexual* ou *Heterossexual*. A Tabela 7.22 mostra os resultados em um formato de saída do SAS para a realização do teste exato de Fisher.
- (a) Por que o teste exato de Fisher é usado para comparar esses grupos?
- (b) Determine e interprete o valor-p para a alternativa de que a proporção da população identificada como *bissexual/lésbica/homossexual* é maior para aqueles com mães lésbicas.
- 7.40 Considere o exercício anterior. Aos jovens adultos foi perguntado, também, se elas já tinham tido um relacionamento sexual com pessoas do mesmo sexo. A Tabela 7.23 mostra os resultados. Use software para testar se esta probabilidade é maior para aqueles criados por mães lésbicas. Interprete.

Tabela 7.23

| Mãe | Relacionamento com o mesmo sexo | |
|---------------|---------------------------------|-----|
| | Sim | Não |
| Lésbica | 6 | 19 |
| Heterossexual | 0 | 20 |

Conceitos e aplicações

7.41 Para o arquivo de dados do Exercício 1.11 da Página 25, compare a ideologia política dos estudantes identificados com o partido Democrata com aqueles identificados com o Republicano:

- (a) usando resumos gráficos e numéricos.
- (b) usando métodos estatísticos inferenciais. Interprete.

7.42 Usando software com o conjunto de dados dos estudantes (Exercício 1.11, na página 25), construa um intervalo de confiança e conduza um teste:

- (a) Para comparar as opiniões de homens e mulheres sobre a legalização do aborto. Interprete.
- (b) Para comparar o tempo médio semanal gasto assistindo à televisão ao gasto praticando esportes e outros exercícios físicos.

7.43 Para o arquivo de dados criado no Exercício 1.12 (página 26), com as variáveis escolhidas pelo seu professor, formule uma questão de pesquisa e conduza análises estatísticas inferenciais. Prepare um relatório que resuma suas descobertas. Neste relatório, use, também, métodos gráficos e numéricos para descrever os dados e, se necessário, verificar as posições que você fez para a sua análise.

7.44 O Exercício 3.6 (página 80), mostrou dados, dos países industrializados, sobre a emissão de dióxido de carbono, um responsável importante do aquecimento global. Existem diferenças de emissões entre países europeus e não europeus? Realize uma investigação para responder a essa pergunta.

7.45 Proponha uma hipótese nula e uma alternativa sobre o relacionamento entre

o tempo gasto na internet ("WWWRH" na PSG) e um previsor binário disponível na PSG que você acredite estar relacionado com o uso da internet. Usando os dados mais recentes da PSG dessas variáveis disponíveis em sda.berkeley.edu/GSS, realize um teste. Prepare um breve relatório resumindo as suas análises. (Nota: o site da PSG faz a comparação das médias de grupos, clicando em [Comparison of means].)

7.46 Passe os olhos por um ou dois jornais diários como o *The New York Times* (cópia impressa ou online). Copie um artigo sobre um estudo que comparou dois grupos. Prepare um breve relatório que responda as seguintes perguntas:

(a) Qual foi o propósito do estudo?

(b) Identifique a variável explicativa e a resposta.

(c) Você pode dizer se a análise estatística usou (1) amostras independentes ou (2) uma comparação das proporções ou uma comparação das médias?

7.47 Um estudo recente¹⁴ considerou se um tempo maior, gasto por adolescentes, assistindo à televisão estava associado a uma probabilidade maior de cometer atos agressivos ao longo dos anos. Os pesquisadores amostraram aleatoriamente 707 famílias em dois condados ao norte do estado de Nova Iorque e fizeram observações subsequentes ao longo de 17 anos. Eles observaram se um adolescente amostrado cometeu, mais tarde, algum ato agressivo contra outra pessoa, de acordo com um relatório pessoal daquela pessoa ou de sua mãe. Dos 88 casos com menos do que uma hora diária assistindo à televisão, 5 haviam cometido atos agressivos. Dos 619 casos com pelo menos uma hora diária assistindo à televisão, 154 haviam cometido atos agressivos. Analise esses dados e resuma sua análise em um breve relatório.

7.48 Quando perguntado pela PSG sobre o número de pessoas com as quais o sujeito tinha discutido assuntos importantes ao longo dos últimos seis meses (variável "NUMGIVEN"), a resposta 0 foi

| <input checked="" type="checkbox"/> Tabela 7.21 | | IDENTIDADE | | | |
|---|------------------|------------------------|-------|--------|-------|
| Mãe | Primeiro momento | Quatro anos mais tarde | B/L/H | HETERO | Total |
| Lésbica | 1 | 2 | 1 | 23 | 25 |
| Heterossexual | 0 | 1 | 1 | 20 | 20 |
| Total | 2 | 4 | 3 | 45 | 45 |

ESTATÍSTICAS PARA A TABELA ORIENTAÇÃO SEXUAL DA MÃE versus DOS FILHOS

| Prob | |
|----------------------------------|-------|
| Teste Exato de Fisher (Esquerda) | 1,000 |
| (Direita) | 0,303 |
| (Bilateral) | 0,495 |

7.49 Proponha uma hipótese nula e uma alternativa sobre o relacionamento entre

dada por 8,9% dos 1531 respondentes em 1985 e por 24,6% dos 1482 respondentes em 2004. Analise esses dados inferencialmente e interprete.

7.49 Um estudo¹⁵ comparou o uso de substâncias, delinquência, bem-estar psicológico e apoio social entre vários tipos de famílias, para uma amostra urbana de adolescentes afro-americanos masculinos. A amostra continha 108 sujeitos de domicílios de mães solteiras e 44 de domicílios com os pais biológicos. Os jovens responderam a uma bateria de perguntas que tornouceu uma medida visível do apoio dos pais. Esta medida tinha médias amostrais de 46 ($s = 9$) para os domicílios de mães solteiras e 42 ($s = 10$) para os domicílios com ambos os pais biológicos. Considere a conclusão: "O suporte médio dos pais era 4 unidades mais alto para os domicílios de mães solteiras. Se as médias verdadeiras fossem iguais, uma diferença desse tamanho poderia ser esperada somente 2% das vezes. Para amostras desse tamanho, poderíamos esperar que em 95% das vezes essa diferença fique aquém de 3,4 do seu valor verdadeiro".

(a) Explique como esta conclusão se refere aos resultados de (i) um intervalo de confiança, (ii) um teste.

(b) Descreva como você explicaria os resultados do estudo a alguém que não estudou estatística inferencial. **7.50** Os resultados na Tabela 7.24 são de um estudo¹⁶ de atração física e bem-estar subjetivo. Uma amostra de estudantes universitários foi classificada por um painel (lista de jurados) de acordo com sua atraividade. A tabela apresenta o número de encontros nos últimos três meses para estudantes classificados no

quartil superior ou inferior da atratividade. Analise esses dados e interprete.

7.51 Um relatório (04/12/2002) do Pew Research Center sobre "O que o mundo pensa em 2002" relatou que "o público norte-americano está visivelmente em desacordo com o resto do mundo sobre a visão do papel dos Estados Unidos no mundo e o impacto global das ações norte-americanas". As conclusões foram baseadas em pesquisas em vários países. No Paquistão, em 2002, o percentual de sujeitos entrevistados que tinham uma visão favorável dos Estados Unidos era de 10%, e o percentual que achou que difundir as ideias e costumes norte-americanos era bom foi de 2% ($n = 2032$).

(a) Você tem informação o suficiente para fazer uma comparação inferencial das proporções? Se tiver, faça. Se não, o que mais você precisa saber?

(b) Para um levantamento de dados separado em 2000, o percentual estimado dos que tinham uma visão favorável dos Estados Unidos era de 23%. Para comparar inferencialmente os percentuais em 2000 e 2002, o que mais você precisa saber?

7.52 Um artigo da *Time Magazine* intitulado "Disparidade de gênero no Wal-Mart" (5 de julho de 2004) declarou que, em 2001, as mulheres gerentes do Wal-Mart recebiam \$14500 por ano menos, em média, do que seus colegas do sexo masculino. Se você tivesse, também, os erros padão do salário médio anual para homens e mulheres gerentes do Wal-Mart, você teria informação suficiente para determinar se esta é uma diferença "estatisticamente significativa"? Explique.

| Atratividade | Número de encontros (Homens) | | Número de encontros (Mulheres) | |
|--------------|------------------------------|---------------|--------------------------------|---------------|
| | Média | Desvio padrão | Média | Desvio padrão |
| Mais | 9,7 | 10,0 | 35 | 17,8 |
| Menos | 9,9 | 12,6 | 36 | 10,4 |

☒ Tabela 7.24

7.53 O International Adult Literacy Survey (Levantamento de Dados Internacionais de Alfabetização Adulta) (www.niflg.org/nifl/facts/IALS.html) foi um estudo realizado em 22 países nos quais amostras nacionaismente representativas de adultos foram entrevistadas e testadas, em

baseadas em pesquisas em vários países. No Paquistão, em 2002, o percentual de sujeitos entrevistados que tinham uma visão favorável dos Estados Unidos era de 10%, e o percentual que achou que difundir as ideias e costumes norte-americanos era bom foi de 2% ($n = 2032$).

(a) Você tem informação o suficiente para fazer uma comparação inferencial das proporções? Se tiver,

faça. Se não, o que mais você precisa saber?

(b) Para um levantamento de dados separado em 2000, o percentual estimado dos que tinham uma visão favorável dos Estados Unidos era de 23%. Para comparar inferencialmente os percentuais em 2000 e 2002, o que mais você precisa saber?

7.54 A Tabela 7.25 compara dois hospitais quanto às admissões de pacientes com pneumonia severa. Embora o status do paciente seja uma variável ordinal, dois pesquisadores que analisaram os dados a trataram como intervalo. O primeiro pesquisador atribuiu os escores (0, 5, 10) às três categorias. O segundo pesquisador, acreditando que a categoria meio está mais próxima da terceira categoria do que da primeira, utilizou os escores (0, 9, 10). Cada pesquisador calculou as médias para as duas instituições e identificou a instituição com a média mais alta como a que tinha maior sucesso no tratamento dos seus pacientes. Encontre as duas médias para o sistema de escores usado pelo (a) primeiro pesquisador, (b) segundo pesquisador. Interprete. (Observe que a conclusão depende da escala de escores utilizada. Portanto, se você usar métodos para variáveis quantitativas com dados ordinários, tome cuidado com a escala dos escores.)

☒ Tabela 7.25

| | | Status do paciente | | |
|------------|---|--------------------------|-----------------------------------|-----------------------------------|
| | | Morreu no hospital | Liberado após longa estadia | Liberado após breve estadia |
| Hospital A | 1 | 29 | 0 | |
| Hospital B | 8 | 8 | 14 | |

7.55 Do Exemplo 6.4 (página 177) do Capítulo 6, para o grupo da terapia cognitivo-comportamental a mudança média no peso de 3,0 libras foi significativamente diferente de zero. Contudo, o Exemplo 7.7 (página 226) mostrou que ela não é significativamente diferente da mudança média para o grupo de controle, embora aquele grupo tivesse uma mudança média amostral negativa. Como você explica este paradoxo? (Dica: das Seções 7.1 e 7.3, verifique como o valor do ep para estimar a diferença entre as duas médias se compara ao valor do ep para estimar uma única média?)

7.56 Um levantamento da Harris Poll de 2201 norte-americanos em 2003 indicou que 51% acreditavam em fantasmas e 31% acreditavam em astrologia.

(a) É válido comparar as proporções usando métodos inferenciais para amostras independentes? Explique.

(b) Você tem informação o suficiente para compará-las usando métodos inferenciais para amostras dependentes? Explique.

7.57 Um grupo de seis candidatos para três posições de gerência inclui três mulheres e três homens. A Tabela 7.26 mostra os resultados.

(a) Designe as três mulheres por F_1, F_2, F_3 e os três homens por M_1, M_2, M_3 . Identifique as 20 amostras distintas de tamanho três que podem ser formadas destes seis indivíduos.

(b) Considere $\hat{\pi}_1$ a proporção amostral de homens selecionados e $\hat{\pi}_2$ a de mulheres. Para a Tabela 7.26, $\hat{\pi}_1 - \hat{\pi}_2 = (2/3) - (1/3) = 1/3$. Das 20 amostras possíveis, mostre que 10 têm $\hat{\pi}_1 - \hat{\pi}_2 \geq 1/3$. Na ver-

dade, este é o raciocínio que fornece o valor-*p* unilateral para o teste exato de Fisher.

- (c) Encontre o valor-*p* se todos os três selecionados são homens. Interprete.

Tabela 7.26

| Escolhido para a posição | | |
|--------------------------|-----|-----|
| Gênero | Sim | Não |
| Masculino | 2 | 1 |
| Feminino | 1 | 2 |

7.61 Verdadeiro ou falso? Se você conhece o erro padrão da média amostral para cada uma de duas amostras independentes, você pode descobrir o erro padrão da diferença entre as médias amostrais mesmo se você não souber os tamanhos das amostras.

Nos Exercícios 7.62 a 7.64, selecione a(s) resposta(s) correta(s). Mais de uma resposta pode estar correta.

7.62 Um intervalo de 99% de confiança para a diferença $\pi_2 - \pi_1$ entre as proporções de homens e mulheres da Califórnia que são alcoolártas é igual a (0,02; 0,09).

(a) Estamos 99% confiantes de que a verdadeira proporção está entre 0,02 e 0,09.

(b) Estamos 99% confiantes de que a verdadeira proporção de homens da Califórnia que são alcoolártas está entre 0,02 e 0,09 acima da verdadeira proporção de mulheres alcoolártas da Califórnia.

(c) Nesse nível de confiança, existe evidência insuficiente para inferir que as proporções populacionais são diferentes.

(d) Estamos 99% confiantes de que a minoria dos residentes da Califórnia são alcoolártas.

(e) Visto que os intervalos de confiança não contêm 0, é impossível que $\pi_1 = \pi_2$.

7.63 Para comparar o rendimento médio anual dos hispânicos (μ_1) e dos brancos (μ_2), com empregos na construção civil, construímos um intervalo de 95% de confiança para $\mu_2 - \mu_1$.

(a) Se o intervalo de confiança é (-3000, 6000), então, nesse nível de confiança, concluímos que a renda média da população é maior para brancos do que para hispânicos.

(b) Se o intervalo de confiança é (-1000, 3000), então ao nível $\alpha = 0,05$ correspondente ao teste $H_0: \mu_1 = \mu_2$ contra $H_a: \mu_1 \neq \mu_2$ rejeitamos H_0 .

(c) Se o intervalo de confiança é (-1000, 3000), então é plausível que $\mu_1 = \mu_2$.

(d) Se o intervalo de confiança é (-1000, 3000), então estamos 95% confiantes de que a renda média anual dos brancos está entre \$1000 e \$3000 acima do rendimento médio anual dos hispânicos.

(e) Joana estudou um pouco e tem uma chance de 0,60 de acertar cada questão. Encontre a probabilidade de que seu escore, não obstante, seja menor do que o do João. (Dica: use a distribuição amostral da diferença das proporções amostrais.)

(f) Como as respostas para (a) e (b) dependem do número de questões? Explique.

*7.66 Considere y_{ii} a representação da observação para o sujeito i no tempo 1, y_{ij} a observação para o sujeito i no tempo 2 e $y_{ij} = y_{iz} - y_{ij}$.

(a) Considerando \bar{y}_j , \bar{y}_{ij} e \bar{y}_{ij} , a representação das médias destas observações, mostre que $\bar{y}_{ij} = \bar{y}_j - \bar{y}_{ij}$.

(b) A diferença mediana (isto é, a mediana dos valores y_{ij}) é igual à diferença entre as medianas dos valores de y_{ii} e y_{jj} ? Mostre que isto é verdade ou dê um contracexemplo para mostrar que é falso.

NOTAS

¹ www.statistics.gov.uk.

² BENSON, H. et al. *American Heart Journal*, v. 151, p. 934-52, 2006.

³ Os dados são cortesia de David Strayer, Universidade de Utah. Veja STRAYER, D., JOHNSTON, W. *Psych. Science*, v. 21, p. 462-66, 2001.

⁴ CHEN, S., CHEN, W. *IEEE Transactions on Speech and Audio Processing*, v. 3, p. 141-45, 1995.

⁵ JIN, H. et al. *Affective Disorders*, v. 94, p. 269-75, 2006.

⁶ *Journal of American College Health*, v. 50, p. 203-17, 2002.

⁷ KORAN et al. *Annu. J. Psychiatry*, v. 163, p. 1806, 2006.

⁸ DIFRANZA, J. et al. *Archives of Pediatric and Adolescent Medicine*, v. 156, p. 397-403, 2002.

⁹ BAKER, D., STEPHENSON, L. *Journal of Clinical Psychology*, v. 51, p. 694, 1995.

¹⁰ MORGAN, J., SAFFRAN, J. *Child Development*, v. 66, p. 911-36, 1995.

¹¹ KERN, J., HASTINGS, T. J. *Clinical Psychology*, v. 51, p. 499, 1995.

¹² SILVERSTEIN, M. *Demography*, v. 32, p. 35, 1995.

¹³ COLOMBOK, S., TASKER, F. *Development Psychology*, v. 32, p. 3-11, 1996.

¹⁴ JOHNSON, J. G. et al. *Science*, v. 295, p. 2468-71, 2002.

¹⁵ ZIMMERMAN, M. et al. *Child Development*, v. 66, p. 1598-613, 1995.

¹⁶ DIENER, E. et al. *Journal of Personality and Social Psychology*, v. 69, p. 120-9, 1995.