

CAPÍTULO 7

TESTE BIVARIADO DE HIPÓTESE

RESUMO:

Uma vez que tenhamos preparado o teste de hipótese e coletado os dados, como avaliamos o que encontramos? Neste capítulo, discutimos as técnicas básicas utilizadas para fazer inferências estatísticas sobre a relação entre duas variáveis. Lidamos com o tópico frequentemente mal compreendido da “significância estatística” – focando tanto o que ela é como o que ela não é – e com a natureza da incerteza estatística. Apresentamos três estratégias utilizadas para examinar a relação entre duas variáveis: análise tabular, testes de médias e coeficientes de correlação. (Apresenta uma quarta técnica, análise de regressão bivariada, no capítulo 8.)

7.1 TESTE BIVARIADO DE HIPÓTESE E O ESTABELECIMENTO DE RELAÇÕES CAUSAIS

Nos capítulos anteriores, introduzimos os conceitos fundamentais do teste de hipótese. Neste capítulo, discutiremos as técnicas básicas do teste de hipótese a partir de três exemplos de testes bivariados. É importante notar que, embora esses tipos de análise tenham sido utilizados como as principais formas de testar hipóteses em revistas acadêmicas até os anos 1970, eles são raramente utilizados como os *principais*

meios para testar hipóteses nas revistas acadêmicas hoje em dia¹. Isso acontece porque essas técnicas são boas apenas para nos ajudar a observar o primeiro princípio do estabelecimento de relações causais. Nominalmente, os testes bivariados de hipótese nos ajudam a responder à pergunta: “*X* é relacionado a *Y*?”. Por definição – “bivariado” significa “duas variáveis” –, esses testes não podem nos ajudar com a importante pergunta “Controlamos por todas as variáveis colineares *Z* que podem fazer com que a relação observada entre *X* e *Y* seja espúria?”.

Apesar das limitações, as técnicas descritas neste capítulo são importantes pontos de partida para entender a lógica subjacente ao teste estatístico de hipótese. Nas seções seguintes, discutiremos como escolher qual teste bivariado realizar e, então, apresentaremos uma discussão detalhada dos três tipos. Ao longo deste capítulo, tente manter em mente o principal propósito deste exercício: estamos tentando aplicar as lições dos capítulos anteriores aos dados do mundo real. A seguir utilizaremos ferramentas mais apropriadas e sofisticadas, mas as lições aprendidas neste capítulo serão cruciais para o entendimento de métodos mais avançados. Colocando de modo simples, estamos tentando iniciar nossa caminhada no complicado mundo do teste de hipótese com dados do mundo real. Uma vez que tenhamos aprendido a caminhar, começaremos a trabalhar em entender como correr.

7.2 ESCOLHENDO O TESTE BIVARIADO DE HIPÓTESE MAIS ADEQUADO

Como discutimos nos capítulos anteriores, especialmente nos capítulos 5 e 6, pesquisadores tomam algumas importantes decisões antes de testar suas hipóteses. Uma vez que tenham coletado os dados e decidido conduzir um teste bivariado de hipótese, eles precisam considerar a natureza das suas variáveis dependente e independente do modelo. Como discutido no capítulo 5, podemos classificar variáveis em termos dos tipos de valores que elas assumem. A Tabela 7.1 apresenta quatro diferentes cenários para o teste de hipótese bivariado; cada um é mais apropriado dependendo do tipo de variável dependente e de variável independente. Para cada caso, listamos um ou mais tipos de teste bivariado de hipótese. Nos casos em que descrevemos as variáveis dependente e independente como categóricas, usamos uma forma de análise conhecida como **análise tabular** para testar nossas hipóteses. Quando nossa variável dependente é contínua e a variável independente é categórica, usamos o **teste de diferença de médias**. Quando a variável independente é contínua e a variável dependente é categórica, analistas tipicamente utilizam modelos *probit* ou *logit* (esses tipos de modelos esta-

¹ Por definição, os pesquisadores, ao conduzirem testes bivariados de hipótese, fazem um de dois pressupostos sobre o mundo. Ou assumem que não existem variáveis causalmente relacionadas com a variável dependente em questão além da variável explicativa sendo utilizada ou que, se existem variáveis omitidas, elas não são relacionadas à variável independente do modelo. Falaremos muito mais sobre variáveis independentes omitidas em modelos causais no capítulo 9. Por agora tenha em mente que, como temos discutido nos capítulos anteriores, esses pressupostos são raramente adotados quando estamos descrevendo o mundo político.

tísticos são discutidos no capítulo 11). Finalmente, quando as variáveis dependente e independente são contínuas, usamos neste capítulo o **coeficiente de correlação** e, como discutiremos no capítulo 8, o modelo de regressão bivariado.

Tabela 7.1 – Tipos de variáveis e testes biviariados de hipótese mais adequados.

Tipo da variável dependente	Tipo da variável independente	
	Catégorica	Contínua
Catégorica	<i>Análise tabular</i>	Probit/Logit (cap. 11)
Contínua	<i>Diferença de médias</i>	<i>Coefficiente de correlação;</i> modelo bivariado de regressão (cap. 8)

Nota: os testes em itálico são discutidos neste capítulo.

7.3 TODOS OS CAMINHOS LEVAM AO P

Um elemento comum no amplo leque de testes estatísticos de hipótese é o valor-*p* (o *p* significa “probabilidade”). Esse valor, que varia entre 0 e 1, é a coisa mais próxima do limite final que temos em estatística. Mas ele é mal compreendido e mal utilizado. Nesta seção, discutiremos a lógica básica do valor-*p* e o relacionaremos à discussão do capítulo 6 sobre o uso de dados amostrais para fazer inferências sobre uma população subjacente.

7.3.1 A LÓGICA DOS VALORES-P

Se pensarmos novamente nos quatro princípios para o estabelecimento de relações causais que discutimos no capítulo 3, o terceiro obstáculo era dado pela pergunta “Existe covariação entre *X* e *Y*?”. Para responder a essa pergunta, precisamos aplicar critérios aos dados do mundo real para determinar se é possível existir uma relação entre nossas duas variáveis, a variável independente *X* e a variável dependente *Y*. Os testes listados na Tabela 7.1 são comumente aceitos como possíveis testes para cada uma das combinações dos tipos de variáveis que temos. Em cada um desses testes, seguimos uma mesma lógica: comparamos a real relação entre *X* e *Y* nos nossos dados amostrais com o que esperaríamos encontrar se *X* e *Y* não fossem relacionados na população subjacente. Quanto *mais diferente* a relação empírica observada for do que esperaríamos encontrar se *não* houvesse uma relação, mais confiantes ficamos em que *X* e *Y* estão relacionados na população. A lógica dessa inferência para a população a partir da amostra é a mesma que usamos no capítulo 6 para fazer inferências sobre a média da população a partir dos dados da amostra.

A estatística que é comumente associada a esse tipo de exercício lógico é o **valor-*p***. O valor-*p*, que varia entre 0 e 1, é a probabilidade de observarmos a relação que verificamos nos dados amostrais por acaso. Em outras palavras, o valor-*p* nos diz a proba-

bilidade de encontrarmos a relação observada entre duas variáveis em nossa amostra se não existisse relação entre elas na população não observada. Assim, quanto menor o valor- p , maior é a confiança que temos que *existe* uma relação sistemática entre as duas variáveis para as quais estimamos o valor- p .

Uma característica comum entre a maioria das técnicas estatísticas é que, para uma determinada relação, quanto maior a base de dados que utilizamos para mensurar a relação, menor será nosso valor- p . Isso é consistente com as lições do capítulo 6 sobre o tamanho da amostra: quanto maior o tamanho da amostra, mais confiança podemos ter em que nossa amostra representará mais acuradamente a população² (ver seção 6.4.2).

7.3.2 AS LIMITAÇÕES DO VALOR- P

Embora os valores- p sejam indicadores poderosos de se duas variáveis são ou não relacionadas, eles também são limitados. Nesta seção revisamos algumas dessas limitações. Adicionalmente, é importante que você entenda o que um valor- p não é: a lógica do valor- p não é reversiva. Em outras palavras, $p = 0,001$ não significa que existe 0,999 de chance de que algo ocorra sistematicamente. Também é importante que você entenda que, embora o valor- p nos diga algo sobre a confiança que podemos ter na relação entre duas variáveis, ele não nos diz se a relação é causal.

Adicionalmente, pode parecer tentador assumir que, quando um valor- p é próximo de zero, ele indica que a relação entre X e Y é muito *forte*. Isso não é necessariamente verdade (embora possa ser). Como notamos previamente, valores- p representam nosso grau de confiança na existência da relação que detectamos na população subjacente. Então devemos naturalmente esperar com o aumento da nossa amostra valores- p menores. Mas amostras grandes sozinhas não tornam o relacionamento magicamente forte; elas *umentam* nossa confiança de que a relação observada em nossa amostra acuradamente representa a população subjacente. Vimos um tipo de relação similar no capítulo 6 quando calculamos os erros-padrão. Porque o número de casos é o denominador da fórmula de erro-padrão, um aumento no número de casos leva a um erro-padrão menor e a um intervalo de confiança mais estreito para nossa inferência sobre a população.

Outra limitação dos valores- p é que eles não refletem diretamente a qualidade do processo de mensuração das nossas variáveis. Assim, se estamos mais confiantes em nossa mensuração, devemos estar mais confiantes no nosso valor- p . O outro lado disso é que, se não estamos tão confiantes no processo de mensuração de uma ou das nossas duas variáveis, devemos ter menos confiança em nosso valor- p .

Finalmente, devemos ter em mente que os valores- p são sempre baseados no pressuposto de que selecionamos aleatoriamente nossa amostra da população. Matematicamente, isso é expresso por

² Adicionalmente, quanto menor o tamanho da amostra, mais provável é que tenhamos resultados que não são representativos da população.

$$p_i = P \forall i.$$

Isto se traduz em “a probabilidade de um caso individual de nossa população pertencer a nossa amostra, p_i , é igual a P para todos os casos i ”. Se esse pressuposto for válido, teremos uma verdadeira amostra aleatória. Como essa é uma exigência que quase nunca é alcançada, devemos considerar esse fato em nossa avaliação do valor- p . Quanto mais distantes estivermos de uma verdadeira amostra aleatória, menos confiança devemos ter em nosso valor- p .

7.3.3 DOS VALORES- P À SIGNIFICÂNCIA ESTATÍSTICA

Como sublinhamos na seção anterior, valores- p mais baixos aumentam nossa confiança de que de fato exista uma relação entre duas variáveis. Um modo comum de se referir a tal situação é afirmar que a relação entre as duas variáveis é uma **relação estatisticamente significativa**. Embora esse tipo de afirmação soe como uma afirmação autorizada, ela é sempre uma afirmação que deve ser colocada em perspectiva. Em outras palavras, uma declaração de significância estatística depende de outros tantos fatores. Um desses fatores é o conjunto de pressupostos da seção anterior. A “significância estatística” é alcançada somente na medida em que os pressupostos subjacentes ao cálculo do valor- p sejam mantidos. Adicionalmente, existe uma variedade de diferentes padrões para definir qual é um valor- p estatisticamente significativo. Muitos cientistas sociais usam como padrão o valor- p de 0,05. Se p é menor que 0,05, eles consideram uma relação estatisticamente significativa. Outros usam um padrão mais restrito de 0,01 ou um padrão mais relaxado de 0,1³.

Nunca é demais enfatizar que encontrar que X e Y têm uma relação estatisticamente significativa *não* significa necessariamente que a relação entre X e Y é forte ou, principalmente, que a relação é causal. Para avaliar se uma relação é forte ou não, precisamos utilizar nosso conhecimento substantivo sobre o que significa uma quantidade determinada de mudança no valor de Y . Discutiremos a avaliação da força das relações em detalhe no capítulo 9. Para avaliar se uma relação é causal, precisamos examinar quão bem nossa teoria se sai em termos de superar os quatro obstáculos causais do capítulo 3.

7.3.4 A HIPÓTESE NULA E OS VALORES- P

No capítulo 1, introduzimos o conceito de hipótese nula. Nossa definição foi “uma hipótese nula é também uma afirmação baseada na teoria, mas sobre o que esperaríamos observar se nossa teoria for incorreta”. Assim, seguindo a lógica previamente sublinhada, se nossa hipótese derivada da teoria é que existe covariação entre X e Y , então a hipótese nula correspondente é que não existe covariação entre X e Y . Nesse

³ Mais recentemente, tem ocorrido uma tendência de reportar o valor- p estimado e deixar os leitores fazerem suas próprias avaliações sobre a significância estatística.

contexto, outra interpretação do valor- p é que ele transmite o nível de confiança com o qual podemos rejeitar a hipótese nula.

7.4 TRÊS TESTES BIVARIADOS DE HIPÓTESE

Agora passaremos à apresentação de três exemplos específicos de testes bivariados de hipóteses. Em cada um dos casos, testamos se existe uma relação entre X e Y . Fazemos isso com dados amostrais e, então, baseando-nos no que achamos, produzimos inferências sobre a população subjacente.

7.4.1 EXEMPLO 1: ANÁLISE TABULAR

A apresentação tabular de dados para duas variáveis ainda é amplamente utilizada. Na literatura de ciência política mais recente, estudiosos a têm utilizado como uma primeira etapa antes de fazer uma análise mais aprofundada com uma análise multivariada. Vale notar neste ponto que, nas tabelas, na maioria das vezes a variável dependente é exposta nas linhas, enquanto a variável independente é exposta nas colunas. Todas as vezes que você observar uma tabela, é muito importante gastar algum tempo para garantir que você entendeu o que ela quer transmitir. Podemos dividir esse processo em três partes:

1. Descubra qual variável está definida nas linhas e nas colunas da tabela.
2. Descubra o que as células individuais representam. Algumas vezes elas serão o número de casos que acontecem em uma determinada linha e coluna; outras vezes os valores das células serão proporções (variando de 0 a 1) ou percentuais (variando de 0 a 100). Se esse for o caso, é crítico que você descubra se o pesquisador calculou os percentuais ou proporções para a tabela ou para cada linha ou coluna.
3. Descubra quais padrões gerais (se existirem) você observa na tabela.

Tabela 7.2 – Residências com filiação sindical e voto na eleição presidencial americana de 2008.

Candidato	De uma residência não sindicalizada	De uma residência sindicalizada	Total
McCain	47,1	33,4	45,0
Obama	52,9	66,6	55,0
Total	100,0	100,0	100,0

Nota: todos os dados representam o percentual das colunas.

A Tabela 7.2 nos proporciona uma boa oportunidade para exemplificar esses três pontos. Nessa tabela estamos testando a teoria de que ser filiado a um sindicato faz

com que as pessoas estejam mais favoráveis a apoiar candidatos da esquerda⁴. Podemos dizer, a partir do título da tabela e dos cabeçalhos das colunas e das linhas, que essa tabela compara os votos de pessoas de uma residência com filiação sindical com os de pessoas de residências sem filiação sindical na eleição presidencial americana de 2008. Podemos usar a informação da tabela para testar a hipótese de que eleitores de residências sindicais estão mais favoráveis a apoiar Barack Obama, o candidato presidencial do partido democrata⁵. Como primeiro passo na leitura dessa tabela, determinamos que as colunas indicam os valores da variável independente (se o indivíduo é ou não de uma residência sindicalista) e que as linhas indicam valores da variável dependente (voto presidencial). O segundo passo é bastante direto; a tabela contém uma nota de rodapé que nos diz que as “células informam os percentuais das colunas”. Esse é o formato mais fácil para prosseguir ao passo 3, porque o percentual das colunas corresponde à comparação que queremos fazer. Queremos comparar o voto presidencial das pessoas oriundas de uma residência sindicalista com o das pessoas que não são oriundas de residências sindicalistas. O padrão é bastante claro: pessoas de residências sindicalistas apoiam esmagadoramente Obama (66,6 para Obama e 33,4 para McCain), enquanto pessoas de famílias não sindicalistas são marginalmente favoráveis a Obama (52,9 para Obama e 47,1 para McCain). Se pensarmos em termos de variáveis independente (X) e dependente (Y), a comparação que temos que fazer é entre a distribuição da variável dependente ($Y =$ voto presidencial) e os valores da variável independente ($X =$ tipo de residência).

Tabela 7.3 – Gênero e voto na eleição presidencial americana de 2008: cenário hipotético.

Candidato	Homem	Mulher	Total da linha
McCain	?	?	45,0
Obama	?	?	55,0
Total da coluna	100,0	100,0	100,0

Nota: todos os dados representam o percentual das colunas.

Na Tabela 7.2, seguimos a convenção de colocar os valores da variável independente nas colunas e da variável dependente nas linhas. Então, tornamos a comparação entre as colunas simples ao colocar como valor das células o percentual da coluna. Adirir a essas normas é uma atitude sábia, porque elas facilitam a comparação que queremos fazer e porque esse é um modo como muitos leitores esperam encontrar a informação.

⁴ Gaste um tempo para avaliar essa teoria nos termos dos dois primeiros obstáculos causais que discutimos no capítulo 3. O mecanismo causal é que candidatos de esquerda tendem a apoiar políticas que sejam valorizadas pelos sindicatos. Ele é crível? E quanto ao segundo obstáculo? Podemos eliminar a possibilidade de que apoiar um candidato de esquerda torna mais provável que alguém seja filiado a um sindicato?

⁵ O que você pensa sobre a operacionalização dessas duas variáveis? Quão bem isso se sai diante do conteúdo discutido no capítulo 5?

Em nosso próximo exemplo acompanharemos passo a passo o teste da hipótese de que o gênero (X) está relacionado ao voto (Y) nas eleições presidenciais americanas. Para testar a hipótese sobre gênero e voto presidencial, utilizamos os dados do National Annenberg Election Survey (NAES) conduzido em 2008. Este é um conjunto de dados apropriado para o teste desta hipótese porque é proveniente de uma amostra selecionada aleatoriamente da população subjacente de interesse (americanos adultos). Antes de observarmos os resultados obtidos a partir dos dados, pense brevemente sobre a mensuração das variáveis de interesse e o que esperaríamos achar se não existisse uma relação entre as duas variáveis.

A Tabela 7.3 apresenta informações parciais sobre um exemplo hipotético em que sabemos que 45% da nossa amostra de entrevistados disse ter votado em John McCain e 55% dos entrevistados disseram ter votado em Barack Obama. Mas, como os pontos de interrogação nessa tabela indicam, não conhecemos a divisão de votos entre os gêneros. Considere o que esperaríamos observar, caso não exista uma relação entre gênero e voto presidencial em 2008, dado o que sabemos a partir da Tabela 7.3. Em outras palavras, quais valores devem substituir os pontos de interrogação na Tabela 7.3, caso não exista uma relação entre nossas variáveis independente (X) e dependente (Y)?

Tabela 7.4 – Gênero e voto na eleição presidencial americana de 2008: expectativas para o cenário hipotético caso não houvesse relação entre gênero e preferência.

Candidato	Homem	Mulher	Total da linha
McCain	45,0	45,0	45,0
Obama	55,0	55,0	55,0
Total da coluna	100,0	100,0	100,0

Nota: todos os dados representam o percentual das colunas.

Se não existe uma relação entre gênero e voto presidencial, então devemos esperar não observar nenhuma grande diferença no modo em que homens e mulheres votaram por John McCain e Barack Obama. Como sabemos que 45% dos nossos casos votaram em McCain e 55% em Obama, o que podemos esperar observar para homens e mulheres? Devemos esperar observar a mesma proporção de homens e de mulheres votando por cada candidato. Em outras palavras, devemos esperar que os pontos de interrogação fossem substituídos com os valores da Tabela 7.4. Essa tabela expõe os valores esperados para as células para a hipótese nula de que não existe relação entre gênero e voto presidencial.

Tabela 7.5 – Gênero e voto na eleição presidencial americana de 2008.

Candidato	Homem	Mulher	Total da linha
McCain	?	?	1.434
Obama	?	?	1.755
Total da coluna	1.379	1.810	3.189

Nota: os dados representam o número de respondentes.

A Tabela 7.5 mostra o número total de respondentes que se encaixam em cada uma das colunas e linhas. Se fizermos os cálculos, podemos observar que o número na coluna à extrema direita da Tabela 7.5 é equivalente ao percentual da Tabela 7.3. Podemos agora combinar a informação da Tabela 7.5 com nossas expectativas da Tabela 7.4 para calcular o número de respondentes que esperamos observar em cada uma das células se gênero e voto presidencial não forem relacionados. Mostramos esses cálculos na Tabela 7.6. Na Tabela 7.7, observamos o número real de respondentes de cada uma das quatro células.

Finalmente, na Tabela 7.8, comparamos o número de casos observados (*O*) com o número de casos que esperaríamos observar (*E*) se não existisse relação entre nossas variáveis dependente e independente.

Tabela 7.6 – Gênero e voto na eleição presidencial americana de 2008: calculando os valores esperados das células caso não haja relação entre gênero e preferência.

Candidato	Homem	Mulher
McCain	$(45\% \text{ de } 1379) = 0,45 \times 1379 = 620,55$	$(45\% \text{ de } 1810) = 0,45 \times 1810 = 814,5$
Obama	$(55\% \text{ de } 1379) = 0,55 \times 1379 = 758,45$	$(55\% \text{ de } 1810) = 0,55 \times 1810 = 995,5$

Nota: os dados representam o valor esperado se essas duas variáveis não forem relacionadas.

Tabela 7.7 – Gênero e voto na eleição presidencial americana de 2008.

Candidato	Homem	Mulher	Total da linha
McCain	682	752	1434
Obama	697	1058	1755
Total da coluna	1379	1810	3189

Nota: os dados representam o número de respondentes.

Tabela 7.8 – Gênero e voto na eleição presidencial americana de 2008.

Candidato	Homem	Mulher
McCain	$O = 682; E = 620,55$	$O = 752; E = 814,5$
Obama	$O = 697; E = 758,45$	$O = 1058; E = 995,5$

Nota: dados representam o número observado (*O*); o número esperado se não existisse relação (*E*).

Podemos observar um padrão. Entre os homens, a proporção observada de votos para Obama é menor do que a que esperaríamos se não existisse relação entre as duas variáveis. Também, entre os homens, a proporção de votos para McCain é maior do que a que esperaríamos se não existisse relação. Para as mulheres o padrão é invertido – a proporção de votos para Obama (McCain) é maior (menor) do que a que esperaríamos se não existisse relação entre gênero e voto na eleição presidencial dos Estados Unidos. O padrão dessas diferenças segue a linha da teoria de que mulheres apoiam mais os candidatos do partido democrata do que os homens. Embora essas diferenças estejam presentes, ainda não determinamos se elas são suficientes para que tenhamos maior confiança em nossa teoria. Em outras palavras, queremos saber se essas diferenças são ou não estatisticamente significantes.

Para responder a essa pergunta, usamos o **teste qui-quadrado (χ^2) de associação**. Karl Pearson originalmente desenvolveu esse teste quando estava testando teorias sobre a influência da hereditariedade e dos estímulos comportamentais no desenvolvimento humano no começo do século XX. A fórmula do qui-quadrado é dada por

$$x^2 = \sum \frac{(O - E)^2}{E}$$

O sinal de soma na fórmula significa que somamos cada uma das células da tabela; então, para uma tabela 2x2, somamos as quatro células. Se pensarmos sobre a contribuição individual de uma célula nessa fórmula, podemos observar a lógica subjacente ao teste x^2 . Se o valor observado, O , é exatamente igual ao valor esperado, E , então não existe relação entre as variáveis e a contribuição dessa célula será igual a zero (porque $O - E$ seria igual a zero). Assim, se todos os valores observados fossem exatamente iguais aos valores esperados, portanto, se não existisse relação entre as duas variáveis, então $x^2 = 0$. Quanto mais os valores de O diferem dos valores de E , maior é o valor de x^2 . Porque o numerador do lado direito da fórmula do x^2 ($O - E$) é elevado ao quadrado, qualquer diferença entre O e E contribuirá positivamente para o valor geral x^2 .

Abaixo podemos observar os cálculos do x^2 para os valores da Tabela 7.8:

$$\begin{aligned} x^2 &= \sum \frac{(O - E)^2}{E} \\ &= \frac{(682 - 620,55)^2}{620,55} + \frac{(752 - 814,5)^2}{814,5} + \frac{(697 - 758,45)^2}{758,45} + \frac{(1.058 - 999,5)^2}{999,5} \\ &= \frac{3.776,1}{620,55} + \frac{3.906,25}{814,5} + \frac{3.776,1}{758,45} + \frac{3.906,25}{999,5} \\ &= 6,09 + 4,8 + 4,98 + 3,92 = 19,79. \end{aligned}$$

Então o valor do nosso x^2 para nossos dados é 19,79. O que fazemos com isso? Comparamos o valor da nossa estatística, 19,79, com algum valor-padrão predeterminado, chamado **valor crítico**, de x^2 . Se nosso valor é maior do que o valor crítico, então

concluimos que existe relação entre as duas variáveis; e, se o valor calculado é menor que o valor crítico, não podemos chegar a essa conclusão.

Como obtemos esse valor crítico? Primeiro, precisamos de uma informação conhecida como **graus de liberdade** (gl) para o nosso teste⁶. Nesse caso, o cálculo dos graus de liberdade é bastante simples: $gl = (r - 1)(c - 1)$, em que r é o número de linhas da tabela e c é o número de colunas da tabela. No nosso exemplo da Tabela 7.8, existem duas linhas e duas colunas, então $(2 - 1)(2 - 1) = 1$.

Você pode encontrar uma tabela com os valores críticos de χ^2 no Apêndice A. Se adotarmos o valor- p padrão de 0,05, observamos que o valor crítico do χ^2 para $gl=1$ é 3,841. Portanto, um χ^2 com valor calculado de 19,79 está muito acima do valor mínimo requerido para obter um valor- p de 0,05. De fato, observando a tabela dos valores críticos, podemos ver que nossa estatística excede o valor crítico necessário para um valor- p de 0,001.

Até este momento, conseguimos estabelecer que a relação entre nossas duas variáveis atende aos padrões de significância estatística convencionalmente aceitos (isto é, $p < 0,05$). Embora esse resultado seja favorável à nossa hipótese, ainda não estabelecemos uma relação causal entre gênero e voto presidencial. Para observar isso, pense novamente nos quatro obstáculos para estabelecer uma relação causal que discutimos no capítulo 3. Até agora, claramente superamos o terceiro obstáculo, por meio da demonstração de que X (gênero) e Y (voto) covariam. A partir do que sabemos sobre política, podemos facilmente superar o primeiro obstáculo, “Existe um mecanismo crível que conecta X a Y ?”. Pode ser mais possível que mulheres votem em candidatos como Obama, porque, entre outras coisas, elas dependem mais da rede de segurança social do Estado de bem-estar social do que os homens. Se examinarmos o segundo obstáculo, “Podemos eliminar a possibilidade de Y ser a causa de X ?”, podemos facilmente observar que superamos esse obstáculo a partir da lógica. Sabemos com confiança que uma mudança na preferência de voto não leva a mudança do gênero da pessoa. Encontramos o percalço mais sério na rota do estabelecimento da causalidade quando encontramos o quarto obstáculo, “Controlamos por todas as variáveis colineares Z que podem tornar a associação entre X e Y espúria?”. Infelizmente, nossa resposta aqui é que não sabemos ainda. De fato, com análises bivariadas, não podemos saber se alguma variável Z é relevante, porque, por definição, existem apenas duas variáveis na análise. Então, até que tenhamos evidências de que as variáveis Z foram controladas, nosso *scoreboard* dos obstáculos causais é $[s \ s \ n]$.

7.4.2 EXEMPLO 2: DIFERENÇA DE MÉDIAS

No nosso segundo exemplo, examinamos uma situação na qual temos uma variável dependente contínua e uma variável independente categórica. Nesse tipo de teste bivariado de hipótese, observamos se as médias são diferentes para os diferentes valores

⁶ Definimos graus de liberdade na próxima seção.

da variável independente. Seguimos a lógica básica do teste de hipótese: comparamos nossos dados do mundo real com o que esperaríamos encontrar se não existisse relação entre nossas variáveis dependente e independente. Usamos médias das amostras e os desvios-padrão para fazer inferências sobre a população não observada.

A teoria que utilizamos como exemplo nesta seção vem dos estudos sobre governos parlamentaristas. Quando cientistas políticos estudam fenômenos entre diferentes formas de governo, uma distinção fundamental que eles fazem entre os tipos de democracias é se o regime é parlamentarista ou não. Um regime democrático é chamado de “parlamentarista” quando a câmara baixa do Legislativo é o ramo mais poderoso no governo e seleciona diretamente o chefe do governo⁷. Uma das características mais interessantes da maioria dos regimes parlamentaristas é que a câmara baixa pode remover o governo do poder por meio do voto de confiança. Como resultado, cientistas políticos têm tido muito interesse nos determinantes de quão longo são os governos parlamentaristas quando existe a possibilidade do voto de confiança.

Um fator importante que diferencia as democracias parlamentaristas é se o partido ou os partidos que estão no governo ocupam a maioria dos assentos no Legislativo⁸. Por definição, a oposição pode derrotar um governo minoritário e retirá-lo do poder por ele não controlar a maioria das cadeiras no Legislativo. Assim, uma teoria bastante razoável sobre a duração dos governos em parlamentarismos é que governos de maioria durarão mais do que governos de minoria.

Podemos passar da teoria para um teste de hipótese utilizando o banco de dados produzido por Michael D. McDonald e Silvia M. Mendes intitulado *Governments, 1950-1995*. Os dados dos autores cobrem governos de 21 países ocidentais. A fim de tornar os dados comparáveis, limitaremos a amostra aos governos formados após uma eleição⁹. Nossa variável independente, “tipo de governo”, assume dois valores:

⁷ Uma parte importante do desenho de pesquisa é determinar quais casos são cobertos pela nossa teoria. Neste caso, nossa teoria, que apresentaremos brevemente, se aplicará apenas a democracias parlamentaristas. Como exemplo, considere se os Estados Unidos e o Reino Unido se adequam a essa descrição no início de 2007. Em 2007, o chefe de governo nos Estados Unidos era o presidente George W. Bush, que foi eleito por meio da eleição presidencial, e não pela câmara baixa. Portanto, os Estados Unidos em 2007 não se adequam a nossa teoria. Para o Reino Unido, pode ser tentador em um primeiro momento apontar a rainha Elizabeth II como a chefe de governo. Mas, se considerarmos que reis e rainhas ingleses têm tido um papel praticamente cerimonial na política do Reino Unido, devemos considerar como chefe de governo o primeiro-ministro, Tony Blair, que foi eleito pela câmara baixa do Legislativo, a House of Commons. Se, adicionalmente, considerarmos os poderes da Câmara dos Comuns comparados relativamente com os dos demais ramos do governo no início de 2007, veremos que o Reino Unido se adequa ao nosso critério de governo parlamentarista.

⁸ Pesquisadores geralmente definem um partido como pertencente ao governo se ao menos um dos seus membros ocupa um posto no gabinete (ministérios). Por sua vez, partidos que não estão no governo são da oposição.

⁹ Também temos que limitar nossa análise aos casos em que os governos possuem um limite legal máximo de quatro anos para permanecer no poder antes de convocar novas eleições. Essa limitação significa que, estritamente falando, só somos capazes de fazer inferências sobre a população de casos que se adequam a esse critério.

“governo de maioria” ou “governo de minoria”. Nossa variável dependente, “duração do governo”, é uma variável contínua que mensura o número de dias que cada governo durou. Embora essa variável tenha uma variação hipotética de um dia a 1.461 dias, os dados reais variam de 31 em 1953 para o governo italiano a 1.749 dias para o governo holandês entre o final da década de 1980 e o começo da de 1990.

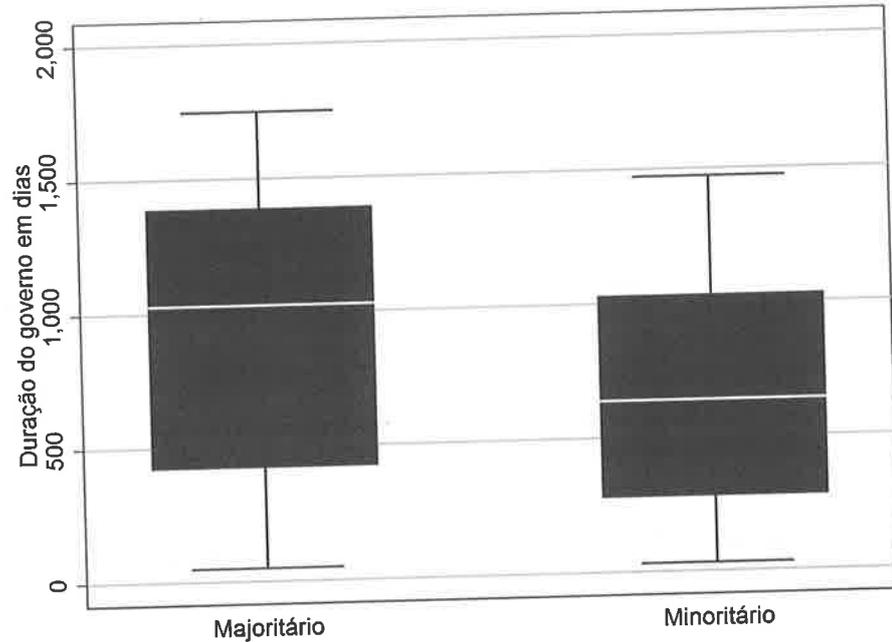


Figura 7.1 – Box-plot para a duração de governos majoritários e minoritários.

Para termos uma ideia melhor dos dados que estamos comparando, podemos utilizar dois gráficos que introduzimos no capítulo 5 para visualizar a distribuição de variáveis contínuas. A Figura 7.1 apresenta o gráfico *box-plot* para a duração de governos majoritários e minoritários e a Figura 7.2 apresenta o gráfico de densidade *kernel* para a duração de governos majoritários e minoritários. Observamos nesses dois gráficos que governos de maioria parecem durar muito mais do que governos de minoria.

Para definir se as diferenças observadas nesses dois gráficos são estatisticamente significantes, podemos utilizar o teste de diferença de médias. Nesse teste comparamos o que observamos nos dois gráficos com o que esperaríamos encontrar se não existisse relação entre o tipo de governo e a duração do governo. Se não existisse nenhuma relação entre as duas variáveis, então a duração dos dois tipos de governo seria proveniente da mesma distribuição subjacente. Se esse fosse o caso, a média e o valor médio da duração do governo seriam iguais para governos de minoria e de maioria.

Para testar a hipótese de que essas médias são provenientes da mesma distribuição subjacente, utilizamos outro teste desenvolvido por Karl Pearson para esse propósito.

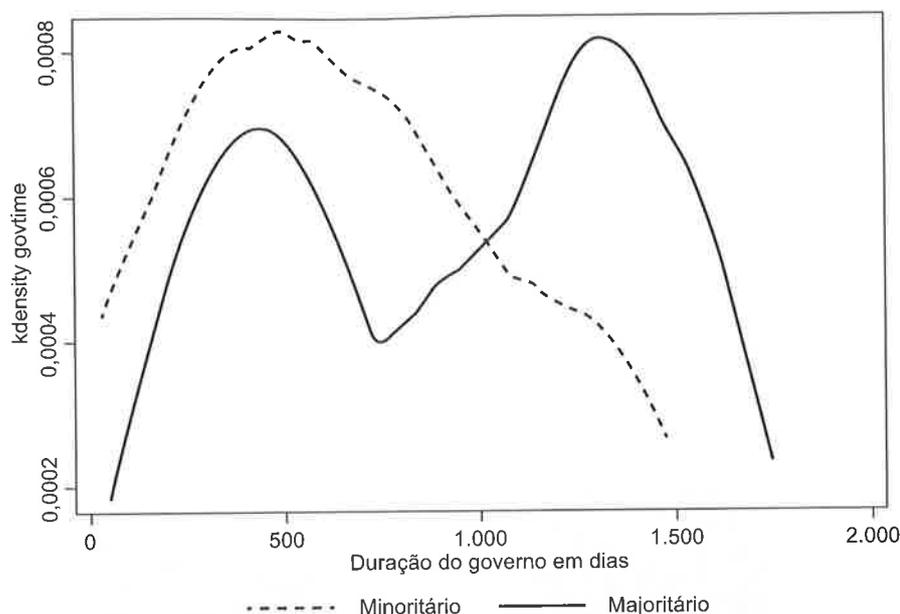


Figura 7.2 – Gráfico de densidade *kernel* para a duração de governos majoritários e minoritários.

Esse teste estatístico é conhecido como teste-*t* porque utiliza a distribuição *t*. A fórmula para este teste em particular é

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

em que \bar{Y}_1 é a média da nossa variável dependente para o primeiro valor da variável independente e \bar{Y}_2 é a média da variável dependente para o segundo valor da variável independente. Podemos observar a partir dessa fórmula que quanto maior a diferença entre o valor da média da variável dependente entre os dois valores da variável independente, maior será o valor de *t*.

No capítulo 6, introduzimos a noção de erro-padrão, que consiste em uma medida de incerteza sobre uma estimação estatística. A lógica básica é que quanto maior for o erro-padrão, mais incerteza (ou menos confiança) teremos na nossa habilidade de fazer afirmações precisas. Similarmente, quanto menor for o erro-padrão, maior é a nossa confiança sobre nossa habilidade de fazer afirmações precisas.

Para melhor entender a contribuição das partes de cima e de baixo do cálculo de *t* para a diferença de médias, observe novamente as Figuras 7.1 e 7.2. Quanto mais distantes forem as duas médias e menos dispersas as distribuições (mensuradas pelo desvio-padrão s_1 e s_2), maior nossa confiança de que \bar{Y}_1 e \bar{Y}_2 são diferentes entre si.

Tabela 7.9 – Tipo de governo e duração do governo.

Tipo de governo	Número de observações	Duração média	Desvio-padrão
Majoria	124	930,5	466,1
Minoria	53	674,4	421,4
Combinado	177	853,8	467,1

A Tabela 7.9 apresenta as estatísticas descritivas para a duração do governo por tipo de governo. A partir dos valores expostos na tabela, podemos calcular a estatística do teste- t para nosso teste de hipótese. O erro-padrão das diferenças entre as duas médias (\bar{Y}_1 e \bar{Y}_2), $se(\bar{Y}_1 - \bar{Y}_2)$, é calculado com a seguinte fórmula:

$$se(\bar{Y}_1 - \bar{Y}_2) = \sqrt{\left(\frac{(n_1 - 1)s_1^2 + (n_2 - 1)s_2^2}{n_1 + n_2 - 2}\right)} \times \sqrt{\left(\frac{1}{n_1} + \frac{1}{n_2}\right)},$$

em que n_1 e n_2 são o tamanho das amostras e s_1^2 e s_2^2 são a variância das amostras. Se nomearmos o número de dias no governo para governos majoritários Y_1 e o número de dias no governo para governos minoritários Y_2 , então podemos calcular o erro-padrão como

$$se(\bar{Y}_1 - \bar{Y}_2) = \sqrt{\left(\frac{(124 - 1)(466,1)^2 + (53 - 1)(421,4)^2}{124 + 53 - 2}\right)} \times \sqrt{\left(\frac{1}{124} + \frac{1}{53}\right)}$$

$$se(\bar{Y}_1 - \bar{Y}_2) = 74,39.$$

Agora que temos o erro-padrão, podemos calcular a estatística- t :

$$t = \frac{\bar{Y}_1 - \bar{Y}_2}{se(\bar{Y}_1 - \bar{Y}_2)} = \frac{930,5 - 674,4}{74,39} = \frac{256,1}{74,39} = 3,44.$$

Uma vez calculada a estatística- t , precisamos de mais uma informação antes de obter nosso valor- p . No caso, precisamos dos graus de liberdade (gl). Os graus de liberdade refletem a ideia básica de que ganharemos confiança no padrão observado à medida que a quantidade de dados em que esse padrão é baseado cresce. Em outras palavras, à medida que o tamanho da nossa amostra aumenta, nos tornamos mais confiantes sobre nossa habilidade de afirmar coisas sobre a população subjacente. Se formos ao Apêndice B, no qual temos os valores críticos para a estatística- t , podemos observar essa lógica. Essa tabela também segue a mesma lógica básica da tabela do χ^2 . Nas colunas da tabela estão definidos os valores- p que queremos obter, e, para conseguir tal valor- p , necessitamos obter um valor t determinado. As linhas da tabela- t indicam os graus de liberdade. À medida que os graus de liberdade aumentam, a estatística- t necessária diminui. Calculamos os graus de liberdade para uma estatística- t de diferença de médias baseada na soma da amostra total menos dois. Assim, nosso grau de liberdade é

$$n_1 + n_2 - 2 = 124 + 53 - 2 = 175.$$

Desde o valor- p , podemos observar nas linhas onde $gl=100$ e verificar o valor- t mínimo necessário para alcançar cada um dos valores p^{10} . Na segunda coluna da tabela- t , podemos observar que, para ter um valor- p de 0,10 (que existe 10%, ou 1 em 10, de chance de observarmos essa relação na nossa amostra de modo aleatório, se não existir relação entre X e Y na população subjacente), devemos ter uma estatística- t maior ou igual a 1,29. Dado que $3,44 > 1,29$, podemos proceder para a próxima coluna de $p = 0,05$ e ver que $3,44$ também é maior que 1,66. De fato, se formos até o final da linha para $gl = 100$, podemos observar que nossa estatística- t é maior que 3,174, que é o valor- t necessário para ter $p=0,001$ (que significa que existe 0,1%, ou 1 em 1000, de chance de observarmos essa relação na nossa amostra aleatoriamente, caso não exista relação entre X e Y na população subjacente). Isso indica que temos bastante confiança de que superamos o terceiro obstáculo causal na nossa avaliação da teoria de que existe uma relação entre governos de maioria e a duração do governo.

7.4.3 EXEMPLO 3: COEFICIENTE DE CORRELAÇÃO

No nosso último exemplo de teste bivariado de hipótese, observamos a situação em que nossas variáveis independente e dependente são contínuas. Testamos a hipótese de que existe uma relação positiva entre o crescimento da economia e o desempenho do partido do presidente em exercício nas eleições presidenciais americanas.

No capítulo 5, discutimos a variação (ou variância) de uma única variável e, no capítulo 1, introduzimos o conceito de covariação. Nos três exemplos que apresentamos até agora, encontramos que existe covariação entre pertencer a uma residência sindicalista e o voto presidencial, gênero e voto presidencial e tipo de governo e duração do governo. Todos esses exemplos utilizaram ao menos uma variável categórica. Quando nossas variáveis independente e dependente são contínuas, podemos facilmente perceber a covariação por meio da análise visual utilizando gráficos. Considere a Figura 7.3, que expõe um gráfico de dispersão do voto no partido do incumbente e o crescimento econômico. Gráficos de dispersão são úteis para uma visualização inicial da relação entre duas variáveis contínuas. Sempre que examinar um gráfico de dispersão, você deve descobrir o que são os eixos e, então, o que cada um dos pontos representa. Nesses gráficos, a variável dependente (neste caso, o voto no partido do presidente em exercício) deve ser exposta no eixo vertical, enquanto a variável independente (neste caso, o crescimento econômico) deve ser exposta no eixo horizontal. Cada ponto no gráfico de dispersão representa o valor para duas variáveis para um determinado caso. Então, na Figura 7.3, estamos olhando para os valores do voto no partido do incumbente e do crescimento econômico para cada um dos anos em que houve uma eleição presidencial nos Estados Unidos e em que os dados estão disponíveis para as duas variáveis.

¹⁰ Embora nosso grau de liberdade seja igual a 175, utilizamos a linha de $gl=100$ para ter uma ideia grosseira do valor- p . Com um *software* estatístico, podemos calcular o valor exato de p .

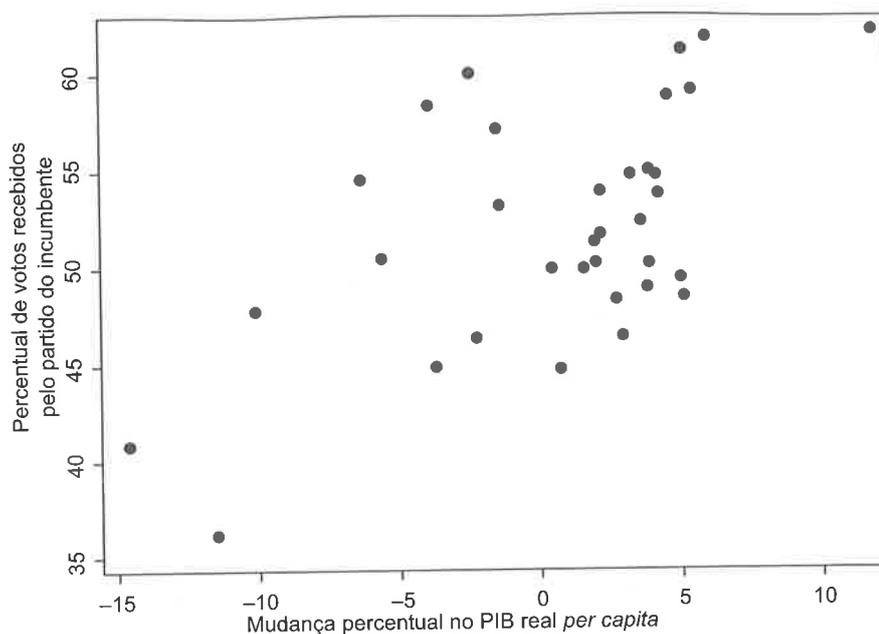


Figura 7.3 – Gráfico de dispersão da mudança no PIB e voto no partido do incumbente.

Quando observamos esse gráfico, queremos avaliar se existe ou não um padrão. Como nossa teoria é que nossa variável independente causa a variável dependente, devemos nos mover da esquerda para a direita no eixo horizontal (que representa o aumento nos valores da variável independente) e ver se existe um aumento ou um decréscimo correspondente nos valores da variável dependente. No caso da Figura 7.3, ao nos movermos da esquerda para a direita, de maneira geral observamos um padrão de aumento dos valores no eixo vertical. Isso indica que, como esperado pela nossa hipótese, quando a economia vai bem (valores mais à direita no eixo horizontal), também há uma chance maior de observar um aumento no percentual de votos para o partido do incumbente nas eleições presidenciais americanas (valores maiores no eixo vertical).

A **covariância** é um modo estatístico de resumir um padrão de associação geral (ou a falta dele) entre duas variáveis contínuas. A fórmula da covariância para duas variáveis X e Y é

$$COV_{XY} = \frac{\sum_{i=1}^n (X_i - \bar{X})(Y_i - \bar{Y})}{n}$$

Para entender melhor a intuição por detrás da fórmula da covariância, é útil pensar em termos de valores relativos dos casos individuais em relação à média de X (\bar{X}) e a média de Y (\bar{Y}). Se um caso individual tiver valor para a variável independente maior do que a média de X ($X_i - \bar{X} > 0$) e o valor para a variável dependente maior que a média de Y ($Y_i - \bar{Y} > 0$), a contribuição desse caso ao numerador da equação da covariância será positiva. Se um caso individual tiver um valor para a variável independente menor

do que a média de X ($X_i - \bar{X} < 0$) e um valor para a variável dependente menor que a média de Y ($Y_i - \bar{Y} < 0$), a contribuição desse caso ao numerador da equação da covariância também será positiva, porque a multiplicação de dois números negativos gera um produto positivo. Se um caso tem uma combinação de um valor maior do que a média e outro menor do que a média, sua contribuição ao numerador na fórmula da covariância será negativa, porque a multiplicação de um número positivo por um número negativo gera um produto negativo. A Figura 7.4 ilustra isso; observamos o mesmo gráfico para as variáveis “crescimento econômico” versus “voto no candidato do partido do incumbente”, mas adicionamos linhas que mostram o valor médio de cada variável. Em cada um desses quadrantes, podemos observar a contribuição dos casos ao numerador. Se um gráfico contém a maioria dos casos nos quadrantes superior direito e inferior esquerdo, a covariância tende a ser positiva. Por outro lado, se um gráfico contém a maioria dos casos nos quadrantes superior esquerdo e inferior direito, a covariância tende a ser negativa. Se um gráfico contém um número balanceado de casos nos quatro quadrantes, a covariância será próxima de zero, porque os valores positivos e negativos cancelarão uns aos outros. Quando a covariância entre as duas variáveis é positiva, descrevemos a situação como relação positiva entre as variáveis, e quando a covariação entre as duas variáveis é negativa, descrevemos a situação como uma relação negativa.

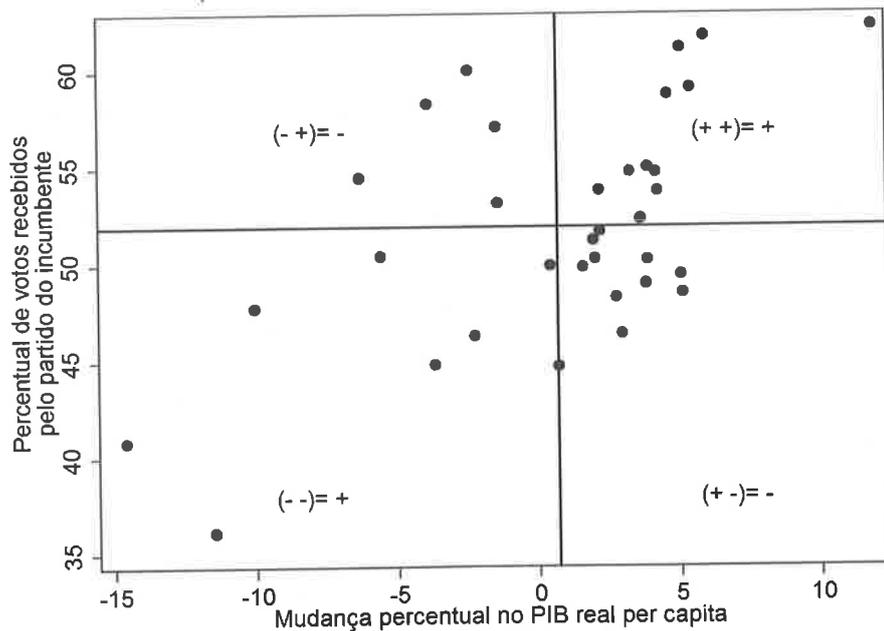


Figura 7.4 – Gráfico de dispersão da mudança no PIB e voto no partido do incumbente com quadrantes de média delimitada.

A Tabela 7.10 apresenta o cálculo para cada ano na fórmula da covariância para os dados que apresentamos na Figura 7.4. Para cada ano, começamos com o cálculo da diferença entre cada X e \bar{X} e a diferença de cada Y e \bar{Y} . Se começarmos com o ano de 1876, podemos observar que o valor para crescimento (X_{1876}) foi 5,11 e o valor

para voto (Y_{1876}) foi 48,516. O valor para crescimento é maior do que a média e o valor para votos é menor do que a média, $X_{1876} - \bar{X} = 5,11 - 0,7025294 = 4,407471$ e $Y_{1876} - \bar{Y} = 48,516 - 51,94718 = -3,431181$. Na Figura 7.4, o ponto que representa 1876 está no quadrante inferior direito. Quando multiplicamos esses dois desvios da média, temos $(X_{1876} - \bar{X})(Y_{1876} - \bar{Y}) = -15,12283$.

Tabela 7.10 – Contribuição individual de cada ano eleitoral ao cálculo da covariância.

Ano	Crescimento X_i	Voto (Y_i)	$X_i - \bar{X}$	$Y_i - \bar{Y}$	$(X_i - \bar{X})(Y_i - \bar{Y})$
1876	5,11	48,516	4,407471	-3,43118	-15,1228
1880	3,879	50,22	3,176471	-1,72718	-5,48633
1884	1,589	49,846	0,886471	-2,10118	-1,86263
1888	-5,553	50,414	-6,25553	-1,53318	9,590831
1892	2,763	48,268	2,060471	-3,67918	-7,58083
1896	-10,024	47,76	-10,7265	-4,18718	44,91387
1900	-1,425	53,171	-2,12753	1,223824	-2,60372
1904	-2,421	60,006	-3,12353	8,058824	-25,172
1908	-6,281	54,483	-6,98353	2,535824	-17,709
1912	4,164	54,708	3,461471	2,760824	9,556509
1916	2,229	51,682	1,526471	-0,26518	-0,40478
1920	-11,463	36,148	-12,1655	-15,7992	192,2053
1924	-3,872	58,263	-4,57453	6,315824	-28,8919
1928	4,623	58,756	3,920471	6,808824	26,69379
1932	-14,586	40,851	-15,2885	-11,0962	169,6442
1936	11,836	62,226	11,13347	10,27882	114,439
1940	3,901	54,983	3,198471	3,035824	9,709992
1944	4,233	53,778	3,530471	1,830824	6,463669
1948	3,638	52,319	2,935471	0,371824	1,091477
1952	0,726	44,71	0,023471	-7,23718	-0,16986
1956	-1,451	57,094	-2,15353	5,146824	-11,0838
1960	0,455	49,913	-0,24753	-2,03418	0,503519
1964	5,087	61,203	4,384471	9,255824	40,58189
1968	5,049	49,425	4,346471	-2,52218	-10,9626
1972	5,949	61,791	5,246471	9,843824	51,64533
1976	3,806	48,951	3,103471	-2,99618	-9,29855
1980	-3,659	44,842	-4,36153	-7,10518	30,98944
1984	5,424	59,123	4,721471	7,175824	33,88044
1988	2,21	53,832	1,507471	1,884824	2,841316
1992	2,949	46,379	2,246471	-5,56818	-12,5087
1996	3,258	54,737	2,555471	2,789824	7,129312
2000	2,014	50,262	1,311471	-1,68518	-2,21006
2004	1,989	51,233	1,286471	-0,71418	-0,91877

Repetimos esse mesmo cálculo para todos os casos (cada ano de eleição presidencial). Cada caso negativo como esse contribui para que a relação geral entre X e Y seja negativa, enquanto cada resultado positivo contribui para que a relação geral entre X e Y seja positiva. A soma para todos os 34 anos em que ocorreram eleições na Tabela 7.10 é 616,59088, indicando que os valores positivos superam os valores negativos. Quando dividimos esse valor por 34, temos a covariância da amostra, que é igual a 18,6846. Isso nos informa que temos uma relação positiva, mas não nos informa o quanto podemos confiar que essa relação não é diferente de uma que observaríamos se nossas variáveis independente e dependente não fossem relacionadas na nossa população subjacente de interesse. Para sabermos isso, utilizamos um terceiro teste desenvolvido por Karl Pearson, o coeficiente de correlação de Pearson. Também conhecido como **r de Pearson**, ele é dado por

$$r = \frac{\text{COV}_{XY}}{\sqrt{\text{var}_X \text{var}_Y}}$$

A Tabela 7.11 é uma tabela de covariância. Em uma tabela de covariância, as células da diagonal principal (do canto superior esquerdo para o canto inferior direito) são as células para as quais as colunas e as linhas se referem à mesma variável. Neste caso, a célula é a variância para a referida variável. Cada uma das células fora da diagonal principal expõe a covariância de um par de variáveis. Em tabelas de covariância, as células acima da diagonal principal são frequentemente deixadas em branco, porque os valores dessas células espelham os valores das células correspondentes abaixo da diagonal principal. Por exemplo, na Tabela 7.11, a covariância entre crescimento e voto é a mesma que a covariância entre voto e crescimento, então a célula no canto superior direito dessa tabela é deixada em branco.

Tabela 7.11 – Covariância para crescimento econômico e voto presidencial no candidato do partido incumbente, 1880-2004.

	Voto	Crescimento
Voto	35,4804	
Crescimento	18,6846	29,8997

Utilizando os dados da Tabela 7.11, podemos calcular o coeficiente de correlação:

$$r = \frac{\text{COV}_{XY}}{\sqrt{\text{var}_X \text{var}_Y}}$$

$$r = \frac{18,6846}{\sqrt{35,4804 \times 29,8997}}$$

$$r = \frac{18,6846}{\sqrt{1060,853316}}$$

$$r = \frac{18,6846}{32,57074325}$$

$$r = 0,57366207.$$

Existem alguns pontos que merecem ser destacados a respeito do coeficiente de correlação. Se todos os pontos de um gráfico se alinharem perfeitamente com uma inclinação positiva, o coeficiente de correlação será igual a 1. Se todos os pontos estiverem perfeitamente alinhados com uma inclinação negativa, o coeficiente será igual a -1 . Em qualquer outro caso, o valor do coeficiente ficará entre $+1$ e -1 . Essa padronização do coeficiente de correlação é um útil aperfeiçoamento em relação à covariância. Adicionalmente, podemos calcular a estatística- t para um coeficiente de correlação por:

$$t_r = \frac{r\sqrt{n-2}}{\sqrt{1-r^2}},$$

com $n-2$ graus de liberdade, onde n é o número de casos. Temos, nesse caso, que nosso grau de liberdade é igual a $34 - 2 = 32$.

Para o nosso exemplo,

$$\begin{aligned} t_r &= \frac{r\sqrt{n-2}}{\sqrt{1-r^2}}, \\ t_r &= \frac{0,57366207\sqrt{34-2}}{\sqrt{1-(0,57366207)^2}}, \\ t_r &= \frac{0,57366207 \times 5,656854249}{\sqrt{1-(0,329088171)}}, \\ t_r &= \frac{3,245122719}{\sqrt{0,670911829}}, \\ t_r &= \frac{3,245122719}{0,819092076}, \\ t_r &= 3,961853391. \end{aligned}$$

Com o gl igual a 34 ($n = 34$) menos dois, ou 32, podemos consultar a tabela- t no Apêndice B. Observando a linha para gl = 30, podemos observar que nossa estatística- t de 3,96 é maior até mesmo que o valor crítico para valor- p igual a 0,001 (que é 3,385). Isso nos informa que a probabilidade de essa relação ocorrer devido ao acaso é menor que 0,001, ou 1 em 1.000. Quando estimamos nosso coeficiente de correlação com um *software* estatístico, temos um valor- p mais preciso de 0,0004. Assim, podemos ter bastante confiança em que a covariação entre crescimento econômico e voto no candidato do partido do presidente em exercício existe e que nossa teoria supera com sucesso o nosso terceiro obstáculo causal¹¹.

¹¹ O primeiro obstáculo causal é facilmente superado se voltarmos à discussão sobre a teoria do voto econômico dos capítulos anteriores. O segundo obstáculo causal também é superado com facilidade a partir da lógica, pensando sobre o momento em que cada variável é mensurada. Como o crescimento econômico é mensurado antes da eleição, é difícil imaginar que Y causa X.

7.5 CONCLUSÃO

Introduzimos três métodos para conduzir testes bivariados de hipótese – a análise tabular, o teste de diferença de médias e o coeficiente de correlação. Cada um dos testes é mais apropriado para uma dada situação, dependendo da métrica de mensuração das nossas variáveis dependente e independente. A Tabela 7.1 deve servir como uma referência útil para você nesse sentido.

Ainda não introduzimos o último método de conduzir testes bivariados de hipótese considerados neste livro, nominalmente a análise de regressão bivariada. Esse é o tópico do nosso próximo capítulo e servirá como o ponto de partida para a regressão múltipla (que discutiremos no capítulo 9).

CONCEITOS INTRODUZIDOS NESTE CAPÍTULO

- Análise tabular – tipo de teste bivariado de hipótese que é apropriado para duas variáveis categóricas.
- Coeficiente de correlação – medida de associação linear entre duas variáveis contínuas.
- Covariância – medida estatística não padronizada que sumariza o padrão geral de associação (ou a falta dela) entre duas variáveis
- Graus de liberdade – número de informações que temos além do mínimo necessário para se fazer uma inferência em um caso específico.
- r de Pearson – coeficiente de correlação normalmente empregado.
- Relação estatisticamente significativa – resultado, com base nos dados observados, de que a relação entre duas variáveis não ocorre aleatoriamente e, portanto, de que ela existe na população mais ampla.
- Teste de diferença de médias – método de teste bivariado de hipótese que é apropriado para uma variável independente categórica e uma variável dependente contínua.
- Teste qui-quadrado (χ^2) de associação – teste estatístico para uma relação entre duas variáveis categóricas.
- Valor crítico – padrão predeterminado para um teste estatístico com o qual comparamos nosso valor calculado. Se o valor calculado é maior que o valor crítico, então concluímos que existe uma relação entre as duas variáveis; se o valor calculado é menor do que o valor crítico, não podemos tirar tal conclusão.
- Valor- p – a probabilidade de observarmos uma relação que ocorre aleatoriamente.

EXERCÍCIOS

1. Indique a forma de teste bivariado apropriada para as seguintes perguntas de pesquisa:
 - a) Você deseja testar a teoria de que ser mulher acarreta menores salários.
 - b) Você deseja testar a teoria de que o percentual de graduados na faculdade é positivamente relacionado com o comparecimento às urnas.
 - c) Você deseja testar a teoria de que indivíduos com renda alta têm maior probabilidade de votar.
2. Explique por que cada uma das seguintes afirmações é verdadeira ou falsa:
 - a) Um *software* de computador deu um valor-*p* de 0,000, então sei que minha teoria foi verificada.
 - b) Um *software* de computador deu um valor-*p* de 0,01, então sei que encontrei uma relação bastante forte.
 - c) Um *software* de computador deu um valor-*p* de 0,07, então sei que tal relação ocorre em razão do acaso.
 - d) Um *software* de computador deu um valor-*p* de 0,50, então sei que existe somente 50% de chance de essa relação ser sistemática.

VALORES MORAIS - O ABISMO TRANSATLÂNTICO						
Q1 – Com que frequência você vai à igreja?						
	Grã-Bretanha				Estados Unidos	
	Todos os eleitores	Eleitores trabalhistas	Eleitores conservadores	Eleitores liberais-democratas	Eleitores de Bush	Eleitores de Kerry
Mais de uma vez por semana	2%	2%	3%	1%	63%	35%
Uma vez por semana	10%	10%	13%	7%	58%	41%
Uma vez por mês	5%	6%	4%	6%	50%	50%
Algumas vezes por ano	36%	36%	38%	40%	44%	55%
Nunca	47%	46%	43%	44%	34%	64%

Q2 – Qual das opções abaixo representa de modo mais acurado sua posição do que a lei deveria dizer sobre o aborto?						
Sempre legal: direito absoluto de escolha	38%	45%	34%	46%	24%	74%

	Grã-Bretanha			Estados Unidos		
	Todos os eleitores	Eleitores trabalhistas	Eleitores conservadores	Eleitores liberais-democratas	Eleitores de Bush	Eleitores de Kerry
Quase sempre legal: algumas restrições	36%	35%	40%	32%	37%	62%
Quase sempre ilegal: somente em circunstâncias excepcionais	19%	14%	18%	17%	72%	27%
Sempre ilegal	4%	4%	3%	3%	77%	22%
Q3 – Qual das opções abaixo representa de modo mais acurado sua posição sobre como deveriam ser as leis quanto a casamentos de pessoas do mesmo sexo?						
O casamento deve ser legalizado	28%	33%	18%	31%	22%	77%
A união civil deve ser legalizada, mas não o casamento	37%	37%	39%	47%	51%	48%
Nunca reconhecer legalmente casais do mesmo sexo	29%	23%	39%	20%	69%	30%

Fontes: para a Grã-Bretanha, pesquisa Populus para a *The Times* (5-7 nov.); para os Estados Unidos, pesquisas conduzidas pelo National Election Poll (2 nov.)

Figura 7.5 – O que há de errado com essa tabela?

3. Observe a Figura 7.5. Qual é a variável dependente? Qual é a variável independente? O que essa tabela nos diz sobre política?
4. O que torna a Figura 7.5 tão confusa?
5. Conduza uma análise tabular a partir da informação apresentada na seguinte discussão sobre um resultado de uma pesquisa hipotética: “Realizamos um *survey* com oitocentos entrevistados que tinham maior probabilidade de serem eleitores do partido democrata em seu estado. Entre esses entrevistados, 45% eram favoráveis a Obama, enquanto 55%, a Clinton. Quando dividimos os entrevistados a partir da mediana da idade (40 anos), encontramos algumas nítidas diferenças: entre a metade mais nova da amostra, encontramos que 72,2% eram favoráveis a Obama ser nomeado candidato do partido democrata e, entre a metade mais velha dos entrevistados, encontramos um apoio de 68,2% a Clinton”.

6. Para o exemplo do exercício 5, teste a teoria de que a idade está relacionada à preferência sobre qual candidato democrata deve ser indicado.
7. Muitas pessoas nos Estados Unidos pensam que o escândalo do Watergate em 1972 causou uma grande mudança na forma como os cidadãos americanos veem políticos incumbentes. Use os dados da Tabela 7.12 para produzir um teste de diferença de médias da hipótese nula de que o índice de reeleição média é igual para o período antes e o período depois do escândalo do Watergate. Em razão do momento no tempo em que as eleições e o escândalo aconteceram, a eleição de 1972 deve ser codificada como pré-escândalo. Faça esse teste para a Câmara e para o Senado. Mostre todos os cálculos.

Tabela 7.12 – Taxas de reeleição dos incumbentes nas eleições para o Congresso nos Estados Unidos, 1964-2006.

Ano	Câmara	Senado
1964	87	85
1966	88	88
1968	97	71
1970	85	77
1972	94	74
1974	88	85
1976	96	64
1978	94	60
1980	91	55
1982	90	93
1984	95	90
1986	98	75
1988	98	85
1990	96	96
1992	88	83
1994	90	92
1996	94	91
1998	98	90
2000	98	79
2002	96	86
2004	98	96
2006	94	79

8. Utilizando o banco de dados “BES2005 Subset”, produza uma tabela que mostre a combinação dos valores para as variáveis “LabourVote” (Y) e “IraqWarApprovalDich” (X). Leia a descrição dessas duas variáveis e escreva o que essa tabe-

la nos diz sobre a política no Reino Unido em 2005. Calcule o teste de hipótese χ^2 para essas duas variáveis. Escreva o que essa análise diz sobre a política no Reino Unido em 2005.

9. Utilizando o banco de dados "BES2005 Subset", teste a hipótese de que os valores para a variável "BlairFeelings" (Y) são diferentes entre os valores da variável "IraqWarApprovalDich" (X). Leia a descrição dessas duas variáveis e escreva o que essa tabela nos diz sobre a política no Reino Unido em 2005.
10. Utilizando o banco de dados "BES2005 Subset", produza um gráfico de dispersão para os valores das variáveis "BlairFeelings" (Y) e "SelfLR" (X). Calcule o coeficiente de correlação e o valor- p para a hipótese de que essas duas variáveis estão relacionadas. Leia a descrição dessas duas variáveis e escreva o que essa tabela nos diz sobre a política no Reino Unido em 2005.