


**Tradução Não Oficial Para Fins Estritamente Didáticos**  
Não pode ser comercializado sob qualquer hipótese



## Check Out the Web Resource!

You will notice a reference throughout this version of *Statistics in Kinesiology, Fifth Edition*, to a web resource. This resource is available to supplement your ebook.

The web resource includes 70 mini lectures that cover key topics from the text, data sets and problem sets that can be completed for practice or as homework, and key term activities that highlight the vocabulary terms used throughout the book. We are certain you will enjoy this unique online learning experience.

### **Follow these steps to purchase access to the web resource:**

1. Visit <https://tinyurl.com/StatisticsInKinesiology5EWR>
2. Click the Add to Cart button and complete the purchase process.
3. After you have successfully completed your purchase, visit the book's website at [www.HumanKinetics.com/StatisticsInKinesiology](http://www.HumanKinetics.com/StatisticsInKinesiology).
4. Click the fifth edition link next to the corresponding fifth edition book cover.
5. Click the Sign In link on the left or top of the page and enter the email address and password that you used during the purchase process. Once you sign in, your online product will appear in the Ancillary Items box. Click on the title of the web resource to access it.
6. Once purchased, a link to your product will permanently appear in the menu on the left. All you need to do to access your web resource on subsequent visits is sign in to [www.HumanKinetics.com/StatisticsInKinesiology](http://www.HumanKinetics.com/StatisticsInKinesiology) and follow the link!

**Click the Need Help? button on the book's website if you need assistance along the way.**

# **STATISTICS IN KINESIOLOGY**

---

**Fifth Edition**

**Joseph P. Weir, PhD**  
University of Kansas  
**William J. Vincent, EdD**  
Brigham Young University



**HUMAN KINETICS**

## Library of Congress Cataloging-in-Publication Data

Names: Vincent, William J., author. | Weir, Joseph P., 1965- author.  
Title: Statistics in kinesiology / Joseph P. Weir, William J. Vincent.  
Description: Fifth edition. | Champaign, IL : Human Kinetics, Inc.,

[2021] | Vincent was the first named author on the previous

edition. | Includes bibliographical references and index. Identifiers:  
LCCN 2019036190 (print) | LCCN 2019036191 (ebook) |

ISBN 9781492560715 (print) | ISBN 9781492595007 (epub) |

ISBN 9781492560722 (pdf)

Subjects: MESH: Kinesiology, Applied | Statistics as Topic

Classification: LCC QP303 (print) | LCC QP303 (ebook) | NLM WE

103 | DDC 612.7/6--dc23

LC record available at <https://lcn.loc.gov/2019036190>

LC ebook record available at <https://lcn.loc.gov/2019036191>

ISBN: 978-1-4925-6071-5 (print)

Copyright © 2021 by Joseph P. Weir and William J. Vincent

Copyright © 2012 by William J. Vincent and Joseph P. Weir

Copyright © 2005, 1999, 1995 by William J. Vincent

Human Kinetics supports copyright. Copyright fuels scientific and artistic endeavor, encourages authors to create new works, and promotes free speech. Thank you for buying an authorized edition of this work and for complying with copyright laws by not reproducing, scanning, or distributing any part of it in any form without written permission from the publisher. You are supporting authors and allowing Human Kinetics to continue to publish works that increase the knowledge, enhance the performance, and improve the lives of people all over the world.

The web addresses cited in this text were current as of August 2019, unless otherwise noted.

Senior Acquisitions Editor: Amy N. Tocco Developmental Editor:  
Judy Park

Managing Editor: Julia R. Smith  
Copyeditor: Patricia L. MacDonald  
Proofreader: Pamela S. Johnson  
Indexer: Ferreira Indexing  
Graphic Designer: Denise Lowry  
Cover Designer: Keri Evans  
Cover Design Associate: Susan Rothermel Allen Photograph  
(cover): John Lund/Photodisc/Getty Images Photo Asset Manager:  
Laura Fitch

Photo Production Manager: Jason Allen Senior Art Manager: Kelly  
Hendren Illustrations: © Joseph P. Weir  
Printer: Sheridan Books

Printed in the United States of America 10 9 8 7 6 5 4 3 2 1

The paper in this book is certified under a sustainable forestry  
program.

## **Human Kinetics**

1607 N. Market St.  
Champaign, IL 61820  
Website: [www.HumanKinetics.com](http://www.HumanKinetics.com)

In the United States, email [info@hkusa.com](mailto:info@hkusa.com) or call 800-747-4457. In  
Canada, email [info@hkcanada.com](mailto:info@hkcanada.com).  
In the United Kingdom/Europe, email [hk@hkeurope.com](mailto:hk@hkeurope.com).

For information about Human Kinetics' coverage in other areas of  
the world,  
please visit our website: [www.HumanKinetics.com](http://www.HumanKinetics.com)



**Tell us what you think!**  
Human Kinetics would love to hear what we  
can do to improve the customer experience.  
Use this QR code to take our brief survey.

To Sumiko Inoue Weir (1933-1982) and Julian Paul Weir (1923-2009)

—*Joseph P. Weir, PhD*

This book is dedicated to my eternal family:  
Clarence, Orpha, Jerry, Diana, Steven, Daniel, Susan, Gail, David,  
Nancy, and all who have gone before or will come after.

—*William J. Vincent, EdD*

## **Conteúdo**

Prefácio  
Agradecimentos  
Lista de Símbolos Chaves

### **CHAPTER 1 Medida, Estatística, e Pesquisa**

O Que é Medição?  
Processo de Medição  
Variáveis e Constantes  
Delineamento de Pesquisa e Análise Estatística  
Inferência Estatística  
Resumo

### **CHAPTER 2 Organizando e Apresentando Dados**

Organizando Dados  
Exibindo Dados  
Resumo

# Prefácio

This edition of *Statistics in Kinesiology* represents the evolution in the life of this unique book. We continue to emphasize the practical use of statistics as a tool to help those in the movement sciences (e.g., physical educators, coaches, biomechanists, sport psychologists, exercise physiologists, athletic trainers, and physical therapists) analyze quantitative data. The goal is always to educate students in the proper use of statistical tools that can help them answer questions in their specific disciplines.

In updating this book, we retained all the qualities that made previous editions such a success. Specifically, the examples of statistical procedures still focus on variables in kinesiology so that students can better relate to how the procedures are used and how the procedures can help them answer questions. We retained the use of hand calculations because we think that doing some of the calculations manually on simple data is an important learning tool. Nonetheless, the mathematics shown in the examples involve only basic algebra skills. As with the previous editions, we emphasize topics that are commonly seen in our disciplines, such as correlation and bivariate regression,  $t$  tests, repeated measures analysis of variance, and the interpretation of interactions in factorial analyses of variance.

However, we have updated many chapters to keep up with changes in the field. For example, we have changed many of the figures from



dynamite plunger plots to dot plots and spaghetti plots, which more accurately convey to the reader what the data really look like and help identify outliers. We have briefly introduced free statistical software packages such as JASP and G\*Power as well as Bayesian statistical ideas, but a detailed discussion of Bayesian methods is beyond the scope of the book.

Additionally, a new web resource provides a variety of interactive activities to help students learn and understand the information provided in the text. Each chapter in the book is accompanied by a set of mini-lectures, which explain key concepts in more detail. Use the QR code located in the web resource section to access the mini-lectures for each chapter. For a complete list of lectures, please visit the homepage for the web resource at [www.HumanKinetics.com/StatisticsInKinesiology](http://www.HumanKinetics.com/StatisticsInKinesiology).

We hope this fifth edition will be a valuable tool in helping both students and researchers analyze quantitative data in the kinesiological disciplines.

— Joseph P. Weir, PhD  
— William J. Vincent, EdD

# Agradecimientos

I am indebted to many people who have had an impact on me both professionally and personally over the years. In particular, I would like to thank Dr. Terry Housh at the University of Nebraska–Lincoln, who was my PhD advisor and remains my friend and mentor, and Dr. Ronald DeMeersman, who shepherded me into the professoriate at the Teachers College of Columbia University when I was fresh out of graduate school. In addition, it has been a great pleasure to collaborate with Dr. Bill Vincent on the fourth and fifth editions of this book. He is a gentleman of the highest order. I would also like to acknowledge two former students, Dr. Jake Siedlik (currently at Creighton University) and Dr. Anthony (Tony) Ciccone (currently at Utah Valley University), who have helped me grow in my statistical expertise. Finally, I wish to thank my wife, Dr. Loree Weir, who has been extremely supportive of all my professional pursuits.

—Joseph P. Weir, PhD

My deepest acknowledgments are to my students who over the years have inspired me and encouraged me to write this book and its subsequent editions. They are the ones who have challenged me and provided the motivation to teach and to write. While administrative responsibilities are rewarding, I must honestly say that the classroom is where I find the greatest joy. It is there that the interaction takes place that inspires teachers and empowers learners.

I would like to acknowledge four people who have had a major impact on my professional life: Dr. Glen Arnett (deceased), who hired me in my first job at California State University–Northridge; Dr. Ruel Barker, chair, and Dr. Robert Conlee, dean, at Brigham Young University, who hired me as an adjunct professor after my retirement from CSUN; and Dr. Larry Hall, who continued to support me for many years at BYU.

Special thanks to the staff at Human Kinetics for guiding us through this fifth edition with expertise and skill. And to my friend and coauthor, Dr. Joe Weir: Thanks, Joe, for the great contributions you have made to this edition.

Finally I acknowledge my wife, Diana, who for 60 years has been my eternal sweetheart and the love of my life. She has supported me all the way.

—William J. Vincent, EdD

Lista de Símbolos Principais	
$\alpha$	1. Letra Grega, alpha minúscula
	2. Área de rejeição de $H_0$ na curva normal
ANCOVA	Análise de covariância
ANOVA	Análise de variância
$\beta$	Inclinação de uma linha; Letra Grega, beta minúscula
B	Letra Grega, beta maiúscula
$\chi$	Letra Grega, qui minúscula
$\chi^2$	Qui-quadrado
C	1. Coluna
	2. Número de comparações
	3. Constante
	4. Frequência acumulada
	5. Intercepto Y de uma linha
d	Desvio (a diferença entre um escore bruto e a média)
df	Graus de liberdade
$D_1$	O 10º percentil
E	Frequência esperada
ES	Efeito do tamanho
F	Frequência
F	Símbolo da ANOVA
$FW_\alpha$	Alfa familiar <sup>1</sup>
Máx	A pontuação mais alta em uma planilha de dados; também o valor da ANOVA de Kruskal-Wallis para dados classificados em ranques
$H_0$	Hipótese nula
$H_1$	Hipótese de pesquisa
HSD	Diferença honestamente significativa de Tukey
i	Tamanho do intervalo em uma distribuição de frequência agrupada
I	Intervalo de confiança de Scheffé
IQR	Intervalo interquartil
k	Número de grupos em um conjunto de dados
Mín	O escore mais baixo em uma planilha de dados
MANOVA	Análise múltipla de variância
$M_G$	A grande média na ANOVA
MS	Quadro médio
$MS_E$	Erro quadrático médio
$\mu$	1. Letra grega, mu minúscula
	2. Média de uma população
n	Número de escores em um subgrupo do conjunto de dados

<sup>1</sup> Alfa familiar é a probabilidade condicional de rejeitar uma ou mais hipóteses nulas absolutamente verdadeiras em uma família de várias hipóteses nulas absolutamente verdadeiras.

N	Número total de escores em um conjunto de dados
O	Frequência observada
$\omega$	Letra grega, ômega minúscula
$\omega^2$	Ômega ao quadrado
p	1. Probabilidade de erro
	2. Proporção
P	Percentil
$Q_1$	O 25º percentil
r	Coeficiente de correlação de Pearson
R	1. Amplitude
	2. Linhas
	3. Coeficiente de correlação múltipla
$R_1$	Correlação intraclasse
$R_2$	Coeficiente alfa na correlação intraclasse
$\rho$	1. Letra grega, rho minúscula
	2. Coeficiente de correlação de ranque de Spearman
SD	Desvio padrão (com base em uma amostra)
$SE_D$	Erro padrão da diferença
$SE_E$	Erro padrão da estimativa
$SE_M$	Erro padrão da média
$\sigma$	1. Letra grega, sigma minúsculo)
	2. Desvio padrão (com base na população)
$\sigma_p$	Erro padrão de uma proporção
SS	Soma dos quadrados
Stanine	Pontuação padrão de Stanine <sup>2</sup> com pontuação média = 5 e R = 1 a 9
$\Sigma$	1. Letra grega, sigma maiúsculo
	2. A soma de um conjunto de dados
t	t de Student
T	Escore T (escore padrão com $X = 50$ e $\sigma = 10,0$ )
U	Teste U de Mann-Whitney
V	Variância
X	Um único escore bruto
$\bar{X}$	A média
$X_{mid}$	O escore médio em um intervalo de escores
Z	Escore Z (escore padrão com $\bar{X} = 0$ e $\sigma = 1,0$ )
$Z_\sigma$	Ponto Alpha

---

<sup>2</sup> Stanine do Inglês standard of nine

# CAPÍTULO 1

## **MEDIDA, ESTATÍSTICA E PESQUISA**

O passo mais importante no processo de toda ciência é a medição de quantidades... Todo o sistema da vida civilizada pode ser adequadamente simbolizado por uma régua, um conjunto de pesos e um relógio.

James Maxwell

**Cinesiologia** é o estudo da arte e da ciência do movimento humano. Os pesquisadores artísticos podem estudar e avaliar a beleza qualitativa e a forma do movimento humano na dança, na ginástica ou em outras formas de movimento artístico. Os pesquisadores científicos estão interessados nas características quantitativas do corpo humano à medida que ele se move. Este livro aborda a ciência do movimento humano e como ele é medido, analisado estatisticamente e avaliado.

Os procedimentos estatísticos são os mesmos, independentemente da disciplina onde os dados foram recolhidos. O pesquisador escolhe o procedimento adequado para analisar os dados de uma determinada questão de pesquisa. Nesta quinta edição de Estatística em Cinesiologia, os autores incluem exemplos de procedimentos estatísticos de uma ampla lista de disciplinas em cinesiologia, incluindo educação física e esportes; aprendizagem motora; biomecânica; fisiologia do exercício; psicologia do esporte; saúde, estudos de lazer e recreação; treino atlético<sup>3</sup>; e fisioterapia. A partir destes exemplos, o leitor pode escolher os procedimentos apropriados e aplicá-los aos dados coletados em qualquer área relacionada.

Toda ciência é baseada em medições precisas e consistentes. Quer você se considere um cientista do exercício, um professor de educação física ou um fisioterapeuta ou não, você pode ganhar muito aprendendo técnicas de medição adequadas. Os cientistas do exercício medem vários atributos do desempenho humano em laboratórios, os professores medem o desempenho dos alunos no campo e os fisioterapeutas medem o desempenho dos pacientes na clínica.

A observação de Maxwell indica que a maioria das medições são de valores quantitativos – distância, força e tempo. Porém, contar a frequência de ocorrência de eventos também é uma medida. Essas mesmas medidas se aplicam à cinesiologia, onde comumente medimos distância (qual a altura das pessoas ou quão longe elas podem pular), força (quanto pesam ou quanto podem levantar), tempo (quão rápido eles podem correr, ou quanto tempo eles podem correr em um determinado ritmo em uma esteira) e frequência (quantas passadas são necessárias para correr 100 metros, ou

---

<sup>3</sup> Athletic training: Estes termos não são usados em Português, mas é uma especialização na área da saúde que abrange a prevenção, exame, diagnóstico, tratamento e reabilitação de lesões e condições médicas emergentes, agudas ou crônicas.

quantas vezes o coração bate em um minuto). Essas medições são às vezes chamadas de objetivas porque são feitas com instrumentos mecânicos, que exigem julgamento mínimo por parte do investigador e reduzem ao mínimo o viés do investigador.

Outras medidas são classificadas como qualitativas (ou subjetivas), porque requerem julgamento humano e são utilizadas para determinar a qualidade de um desempenho, como uma rotina de ginástica ou uma tacada de golfe, ou outros fatores, como o nível de dor do paciente.

## O que é a Medição?

Simplificando, **medição** é o processo de comparação de um valor com um padrão. Por exemplo, comparamos o nosso próprio peso (a força da gravidade nos nossos corpos) com o padrão de uma libra ou de um quilograma sempre que subimos numa balança. Quando um professor de educação física testa os alunos no salto em distância, o processo de medição está sendo aplicado. O padrão com o qual os saltos são comparados é a distância (metros). Quando o professor utiliza um instrumento (neste caso, uma fita métrica) para determinar que um aluno saltou 5,2 metros, essa informação é chamada de dado.

Os **dados** são o resultado da medição. Quando partes individuais de dados são coletados, eles geralmente ficam desorganizados. Depois que todos os pontos de dados desejados forem conhecidos, eles poderão ser organizados por um processo chamado estatística. **Estatística** é uma técnica matemática pela qual os dados são organizados, tratados e apresentados para interpretação e avaliação. Avaliação é o processo filosófico de determinar o valor dos dados.

Para serem úteis, os dados da medição devem ser reproduzíveis – isto é, uma segunda medição nas mesmas condições deve produzir o mesmo resultado que a primeira medição. A reprodutibilidade é normalmente discutida sob o título de confiabilidade. A **confiabilidade** (às vezes chamada de **consistência dos dados**) é geralmente determinado pelo método teste-reteste, onde a primeira medida é comparada com uma segunda ou terceira medida nos mesmos sujeitos nas mesmas condições. A quantificação da confiabilidade é abordada no capítulo 13.



Para serem aceitáveis, os dados também devem ser válidos. **Validade** refere-se à solidez ou adequação do teste em medir o que foi projetado para medir. A validade pode ser determinada por uma análise lógica dos procedimentos de medição ou por comparação com outro teste conhecido como válido. Na cinesiologia, frequentemente quantificamos a validade determinando até que ponto um teste está correlacionado com outro índice. As técnicas de correlação e análise de regressão são frequentemente utilizadas para esses fins. Por exemplo, a validade das medidas de dobras cutâneas para avaliação da gordura corporal pode ser quantificada pela forma como as medidas de dobras cutâneas se correlacionam com os resultados da absorciometria de raios X de dupla energia (DEXA). Os Capítulos 8 e 9 abordam procedimentos de correlação e regressão que podem ser usados para quantificar a relação entre variáveis, como é típico em estudos de validade.

**Objetividade** significa que os dados são coletados sem preconceitos por parte do investigador. A tendenciosidade pode ser detectada comparando as pontuações de um investigador com as de um especialista ou painel de especialistas. A objetividade é por vezes referida como confiabilidade entre avaliadores (Morrow et al., 2000, p. 78).

## Processo de Medição

A medição envolve quatro etapas:

1. O objeto a ser medido é identificado e definido.
2. O padrão com o qual o objeto medido será comparado é identificado e definido.
3. O objeto é comparado com o padrão.
4. É feita uma declaração quantitativa da relação do objeto com o padrão.

Por exemplo, se medíssemos a altura de uma pessoa que tem 2 metros de altura, concluiríamos que a altura da pessoa (o objeto medido) é duas vezes maior (a relação) que 1 metro (o padrão).

O padrão usado para comparação é fundamental para o processo de medição. Se o padrão não for consistente, os dados mudarão cada vez que um objeto for comparado com esse padrão. No sistema inglês de medição, o padrão original não era consistente. Há cerca de 600 anos, na Inglaterra, o padrão para medir distâncias era o

comprimento do pé do rei. Quando o rei morreu e outro com pé menor ou maior tomou seu lugar, o padrão mudou e o comprimento de todos os objetos do reino tiveram de se determinados novamente.

O sistema inglês de medição de distância foi originalmente baseado em padrões anatômicos como pé, cúbito (distância do cotovelo até a ponta dos dedos - normalmente cerca de 1,5 pés), jarda (uma passada típica de uma pessoa) e mão (a extensão da mão da ponta do dedo mínimo até a ponta do polegar). A força baseava-se em libras (7.000 grãos de trigo equivaliam a 1 libra), e cada libra era dividida em 16 onças. Nos anos em que a chuva foi adequada os grãos de trigo eram grandes, mas nos anos de seca os grãos eram menores. Portanto, o padrão mudou de ano para ano.

Eventualmente estas medidas foram padronizadas, mas o sistema inglês é difícil de usar porque não tem um denominador numérico comum para todas as unidades de medida. Dezesseis onças equivalem a uma libra, mas 2.000 libras equivalem a uma tonelada; 2 xícaras equivalem a um pint e 2 pints equivalem a um quarto, mas são necessários 4 quartos para perfazer um galão. Doze polegadas equivalem a um pé, 3 pés equivalem a uma jarda e 5.280 pés constituem uma milha. Não é de admirar que as crianças tenham dificuldade em aprender este sistema.

O sistema métrico, que é mais consistente e mais fácil de compreender, foi introduzido pela primeira vez em França em 1799. É agora utilizado em quase todos os lugares, exceto nos Estados Unidos e em alguns outros países. Neste sistema, as unidades de medida de distância, força e volume são baseadas em múltiplos de 10. O sistema métrico usa os seguintes termos:

<b>Prefixo</b>	<b>Valor</b>
milli	1/1,000
centi	1/100
deci	1/10
zero	0
deca	10
hecto	100
kilo	1,000
mega	1,000,000
giga	1,000,000,000

Esses termos facilitam a conversão de unidades de medida. Por exemplo, um quilômetro equivale a 1.000 metros e um centímetro equivale a 1/100 de metro. A mesma terminologia é usada para força, volume e distância. O sistema métrico é baseado em valores geofísicos constantes. Um metro foi anteriormente definido como 1/10.000.000 da distância do equador a um polo na Terra, mas agora é definido como o comprimento que a luz viaja no vácuo durante 1/299.793.458 de segundo. Um grama é a força da gravidade em 1 centímetro cúbico de água a 4 °C (sua densidade máxima).

Felizmente, tanto o sistema inglês quanto o métrico usam as mesmas unidades de medida de tempo: segundos, minutos, horas e assim por diante. Embora as medições não sejam baseadas em múltiplos de 10 (há 60 segundos a 1 minuto), as relações são as mesmas em ambos os sistemas e são comuns em todo o mundo.

O sistema métrico é claramente superior ao sistema inglês. Além disso, o sistema métrico é o sistema utilizado para medições científicas e publicações de pesquisas.

## **Variáveis e Constantes**

Quando medimos o desempenho humano, medimos variáveis. Uma **variável** é uma característica de uma pessoa, lugar ou objeto que pode assumir mais de um valor. Por exemplo, uma característica que varia de uma pessoa é o tempo que ela leva para correr uma milha.

Outros exemplos de variáveis em cinesiologia são peso, altura, número de lances livres de basquete feitos em 10 tentativas, consumo de oxigênio e frequência cardíaca durante um teste de esteira, ângulos na articulação do joelho durante várias fases do ciclo de marcha, pontuações nos músculos manuais testes e colocação em um torneio de escada.

Observe que pessoas diferentes pontuam de forma diferente na mesma variável, e uma única pessoa pode ter desempenho diferente quando medida na mesma variável mais de uma vez. Os dados variam entre pessoas e também dentro das pessoas. Como as variáveis mudam, devemos monitorá-las ou medi-las com frequência se precisarmos saber o status atual da variável.

Uma característica que pode assumir apenas um valor é chamada de **constante**. Uma constante nunca muda. Portanto, uma vez medido com precisão, não precisamos

medi-lo novamente. O número de jogadores de um time oficial de beisebol é uma constante. Devem ser nove, nem mais nem menos. As distâncias em eventos de pista são constantes. Em uma corrida de 100 metros, a distância é sempre de 100 metros. As distâncias de base a base em um campo de beisebol e do monte do arremessador ao *home plate* (quarta base) são constantes.

Muitas características anatômicas são constantes. Geralmente uma pessoa tem apenas uma cabeça, um coração, dois pulmões e dois rins. É claro que doenças ou acidentes podem alterar o corpo e, assim, alterar algumas destas características, mas normalmente a anatomia do corpo humano é constante.

Provavelmente a constante mais conhecida em matemática é pi. Pi é o número de vezes que o diâmetro de um círculo pode ser colocado em torno de sua circunferência, e é sempre 3,14159...

## **Tipos de Variáveis**

As variáveis podem ser classificadas como contínuas ou discretas. Uma variável contínua é aquela que teoricamente pode assumir qualquer valor. Distância, força e tempo são variáveis contínuas. Dependendo da precisão do instrumento de medição, a distância pode ser medida em distâncias tão curtas como um milionésimo de centímetro ou até um ano-luz. O tempo pode ser medido em milissegundos, dias ou séculos.

O valor de uma **variável discreta** é limitado a certos números, geralmente números inteiros. Ao contar pessoas, usamos sempre números inteiros porque é impossível ter uma fração de uma pessoa. O número de batimentos cardíacos num minuto e o número de cestos marcados num jogo de basquetebol também são exemplos de variáveis discretas. Não se pode contar metade de um batimento cardíaco ou marcar parte de uma cesta. Muitas variáveis clínicas são variáveis discretas. Ao fazer um diagnóstico, uma pessoa é classificada como tendo a doença (por exemplo, ruptura do ligamento cruzado anterior) ou não.

## **Classificação dos Dados**

Os dados coletados sobre as variáveis podem ser agrupados em quatro categorias ou escalas: nominal, ordinal, intervalar e razão. Nas **escalas nominais**, os sujeitos são

agrupados em categorias mutuamente exclusivas, sem diferenciação qualitativa entre as categorias. Os assuntos são simplesmente classificados em uma das categorias e depois contados. Os dados agrupados desta forma são por vezes chamados de dados de frequência porque a escala indica a frequência, ou o número de vezes que um evento acontece, para cada categoria. Por exemplo, um pesquisador pode estar interessado na lateralidade entre jogadores de softball. Numa amostra de jogadores, o pesquisador pode determinar que existem 128 arremessadores destros e 26 arremessadores canhotos. Os valores 128 e 26 representam as frequências das duas categorias.

Algumas escalas nominais possuem apenas duas categorias, como diagnóstico clínico (por exemplo, concussão ou não concussão) ou sim e não. Outras, como a escala de etnia, têm mais de duas divisões. As **escalas nominais** não atribuem diferenças de valor qualitativo às categorias da variável. No entanto, os números são atribuídos às categorias. O tamanho do número não indica uma quantidade, mas é usado para indicar atribuição de categoria em um arquivo de dados. Por exemplo, podemos atribuir o número 0 aos homens e 1 às mulheres. Aqui, a escolha do número é completamente arbitrária.

Uma **escala ordinal**, às vezes chamada de escala de ordem de classificação, dá uma ordem quantitativa às variáveis, mas não indica o quanto uma pontuação é melhor do que outra. Em uma aula de educação física, a colocação em um torneio de escada é um exemplo de escala ordinal. A pessoa no topo da escada teve um desempenho melhor do que a pessoa classificada em segundo lugar, mas nenhuma indicação é dada de quão melhor. As duas primeiras pessoas podem ter competências muito próximas e ambas podem ser consideravelmente mais qualificadas do que a pessoa que ocupa o terceiro lugar, mas a escala ordinal não fornece essa informação. Representa apenas a ordem dos jogadores, não suas habilidades absolutas. As diferenças entre as posições numa escala ordinal podem ser desiguais. Se 10 pessoas forem colocadas em ordem de baixa para alta e numeradas de 1 (mais baixa) a 10 (mais alta), os valores de 1 a 10 representariam dados ordinais. Dez é mais alto que 9 e 9 é mais alto que 8, mas os dados não revelam quanto mais alto. Os médicos costumam usar escalas ordinais de 0 a 10 para quantificar a dor. Da mesma forma, na fisiologia do exercício, a escala de Borg de 6 a 20 é uma escala ordinal usada para quantificar a avaliação do esforço percebido durante o exercício.

Uma **escala intervalar** tem unidades iguais, ou intervalos, de medida - isto é, existe a mesma distância entre cada divisão da escala - mas não tem ponto zero absoluto. Como zero não representa ausência de valor, não é apropriado dizer que um ponto na escala é duas, três vezes ou metade do tamanho de outro ponto.

A escala Fahrenheit para medir temperatura é um exemplo de escala de intervalo:  $60^\circ$  é  $10^\circ$  mais quente que  $50^\circ$  e  $10^\circ$  mais frio que  $70^\circ$  (os intervalos entre os pontos de dados são iguais), mas  $100^\circ$  não é duas vezes mais quente que  $50^\circ$ . Isso ocorre porque  $0^\circ$  não indica ausência completa de calor.

A escala de medição mais completa é a **escala de proporção**. Esta escala é baseada na ordem, possui distância igual entre os pontos da escala e utiliza zero para representar a ausência de valor. Todas as unidades são equidistantes umas das outras e comparações proporcionais ou de proporção são apropriadas. Todas as medições de distância, força ou tempo são baseadas em escalas de proporção. Vinte quilogramas é o dobro da massa de 10 quilogramas, e 100 metros equivalem ao dobro de 50 metros. Uma pontuação negativa não é possível em uma escala de proporção. Uma pessoa não pode correr uma corrida em segundos negativos, pesar menos de 0 quilogramas ou marcar pontos negativos no basquete. Na cinesiologia, dados do tipo proporção são frequentemente usados.

Os dados medidos em **escalas nominais** e **ordinais** são frequentemente analisados utilizando procedimentos estatísticos não paramétricos porque não atendem a certos pressupostos da estatística paramétrica. Os dados medidos em escalas de intervalo e proporção são normalmente analisados usando procedimentos estatísticos paramétricos e são os mais comuns em cinesiologia. Esses conceitos são discutidos mais detalhadamente no capítulo 16.

## **Delineamento de Pesquisa e Análise Estatística**

O desenho da pesquisa e a análise estatística baseiam-se em princípios de medição. Eles estão tão interligados que é difícil discutir um sem referir o outro. Este livro apresenta técnicas estatísticas projetadas para auxiliar na avaliação de dados. A forma como os dados são coletados, quais instrumentos são utilizados e como as variáveis são controladas fazem parte do desenho da pesquisa.

**Pesquisa** é uma técnica especial para resolver problemas. Identificar o problema é uma parte crítica da pesquisa. Um problema geralmente começa com perguntas como “Eu me pergunto se...”, “Eu me pergunto por que...” ou “Eu me pergunto o que...” Se não encontrarmos a resposta para a pergunta, então teremos um problema a ser pesquisado. Primeiro, podemos perguntar a um especialista na área sobre a questão. Se o especialista souber a resposta, nosso problema estará resolvido (supondo que o especialista não esteja errado!).

Se o especialista não souber, poderemos visitar a biblioteca. Se encontrarmos a resposta na biblioteca, nosso problema estará resolvido. Mas quando não conseguimos encontrar a resposta procurando na biblioteca ou conversando com outras pessoas, então a única maneira de resolver o problema é realizar pesquisas.

Muitas pessoas pensam em um experimento quando ouvem a palavra pesquisa, mas a pesquisa não se limita a explorar problemas de design científico e experimental. O problema pode ser resolvido por pesquisa histórica, pesquisa descritiva ou pesquisa experimental.

**A pesquisa histórica** é uma pesquisa em registros do passado para determinar o que aconteceu e por quê. É uma tentativa de resolver os problemas atuais aprendendo com o passado. Este livro não aborda a pesquisa histórica; no entanto, muitos textos disponíveis sobre desenho de pesquisa discutem a pesquisa histórica.

**A pesquisa observacional** (ou pesquisa descritiva) envolve a descrição de eventos ou condições que o pesquisador não manipula ativamente. Neste tipo de estudo, os pesquisadores frequentemente examinam as correlações nos dados. Uma ferramenta comum de pesquisa observacional é a pesquisa. O pesquisador identifica os eventos ou condições a serem descritos e busca informações de pessoas ou outras fontes fazendo perguntas, muitas vezes por meio de um questionário. Técnicas estatísticas são usadas para organizar, tratar e apresentar os dados da pesquisa observacional para avaliação e interpretação. Por exemplo, digamos que um pesquisador esteja interessado em saber se o exercício regular reduz a pressão arterial sistólica em repouso em pessoas que têm hipertensão (pressão alta). O pesquisador pode medir a pressão arterial sistólica de todos os participantes do estudo e, em

seguida, fazer com que preencham um questionário perguntando quanto exercício eles normalmente realizam em uma semana. Então, técnicas como correlação e regressão (ver capítulos 8 e 9) podem ser usadas para quantificar o grau de relação entre a pressão arterial sistólica e o exercício auto relatado. Aqui o pesquisador não manipula o exercício realizado pelos sujeitos. Se houver uma relação entre a pressão arterial sistólica em repouso e o exercício auto relatado, estaríamos inclinados a pensar que o exercício influencia a pressão arterial. No entanto, pode haver outros fatores que impulsionam o relacionamento. Por exemplo, as pessoas que se exercitam muito também podem adotar outros comportamentos saudáveis, como ter uma dieta saudável, e evitar comportamentos prejudiciais à saúde, como fumar. Por razões como esta, considera-se geralmente que os estudos observacionais fornecem evidências mais fracas do que a investigação experimental.

**A pesquisa experimental** é o processo de pesquisa que envolve a manipulação e controle de eventos ou variáveis para resolver um problema.

A pesquisa experimental coloca os pesquisadores na posição mais forte para fazer inferências de causa e efeito a partir dos dados. Para ilustrar, considere o mesmo interesse geral de pesquisa descrito no parágrafo anterior (isto é, exercício e pressão arterial sistólica em repouso). Em um estudo experimental, um pesquisador poderia alocar aleatoriamente os participantes em um grupo de exercícios e um grupo de controle. O grupo de exercício realizaria um programa de exercícios específico (por exemplo, 30 minutos de ciclismo ergométrico cinco vezes por semana) durante um determinado período de tempo (por exemplo, 12 semanas), enquanto o grupo de controle não se exercitaria. Antes e depois do período de 12 semanas, todos os participantes teriam sua pressão arterial sistólica medida. Para minimizar o viés, o técnico que mede a pressão arterial pode não ter conhecimento da atribuição de grupo de cada indivíduo durante o teste. Neste exemplo, com atribuição aleatória aos grupos (e tamanho de amostra adequado), esperaríamos que houvesse diferenças mínimas entre os grupos na pressão arterial de repouso no início do estudo. Sob estas condições, as diferenças entre os grupos na pressão arterial de repouso no final do estudo seriam razoavelmente interpretadas como tendo ocorrido devido aos efeitos do programa de exercícios.



Para começar sua pesquisa, você precisa de um plano. O desenho da pesquisa é o plano que define a maneira como os dados serão coletados e analisados. Muitas vezes, o plano exige que os subproblemas sejam resolvidos primeiro ou que seja realizado um trabalho piloto (coleta preliminar de dados) para determinar a viabilidade do desenho da investigação. Um erro comum dos investigadores iniciantes é saltar para a coleta de dados antes de fazer o planejamento adequado e o trabalho piloto.

Se o problema não tiver sido resolvido após a identificação do problema e a busca na biblioteca ter sido concluída, estamos prontos para fazer uma hipótese. Uma hipótese é uma suposição fundamentada ou uma suposição lógica baseada em pesquisas anteriores ou fatos conhecidos e que pode ser testada pelo projeto experimental. A hipótese deve ser formulada de tal forma que a análise estatística possa ser realizada nos dados para determinar a probabilidade (chance<sup>4</sup>) de obtenção dos resultados fornecidos se a hipótese for verdadeira.

## Teste de Hipótese

A abordagem tradicional para análise estatística de dados é realizar um teste estatístico de hipótese nula (TEHN). Deve-se notar que esta abordagem tem sido criticada ao longo dos anos, e os desafios a ela são abordados nos capítulos subsequentes.

Na abordagem TEHN, a hipótese que motiva a pesquisa é chamada de **hipótese de pesquisa**, ou **hipótese alternativa**, e é simbolizada por  $H_1$ .  $H_1$  geralmente prevê relações ou diferenças entre grupos de sujeitos. Afinal, se não acreditássemos que existiam relações ou diferenças, então provavelmente não realizaríamos a experiência. No entanto,  $H_1$  não é a hipótese normalmente testada pela análise estatística.

A hipótese geralmente testada estatisticamente é chamada de hipótese nula, ou  $H_0$ . A hipótese nula não prevê relação ou diferença alguma entre os grupos. Se  $H_0$  for verdadeira, então  $H_1$  será falsa e vice-versa. São proposições mutuamente exclusivas. Essencialmente, a hipótese nula afirma que qualquer relação ou diferença que possa ser observada por medição é o resultado de ocorrências aleatórias.

A análise estatística relata a probabilidade de que os resultados ocorreriam conforme os observamos se a hipótese nula fosse verdadeira. Por exemplo, se a

---

<sup>4</sup> a probabilidade de que um fato o evento seja assim ou aconteça em vez de outro

hipótese nula for verdadeira, as estatísticas podem indicar que a probabilidade ( $p$ ) de que os resultados obtidos possam ocorrer por acaso é inferior a uma em 100 ( $p = 0,01$ ). Se a probabilidade for pequena, rejeitamos a hipótese nula e aceitamos a hipótese alternativa, ou de pesquisa ( $H_1$ ). Se a probabilidade for grande, aceitamos a hipótese nula.

A hipótese nula é normalmente usada para avaliar resultados porque os pesquisadores geralmente não têm certeza de quais serão os resultados quando conduzirem um experimento. Se soubéssemos os resultados antes de começarmos, não precisaríamos fazer o experimento. Mas os investigadores começam uma experiência com uma ideia em mente, e essa ideia é representada pela hipótese de investigação. Normalmente, a hipótese de pesquisa estimula o experimento, mas é a hipótese nula que é testada estatisticamente.

Rejeitamos  $H_0$  e aceitamos  $H_1$  quando diferenças ou relações entre variáveis são estabelecidas além de qualquer dúvida razoável ou em um nível de confiança aceitável. Antes de coletarmos dados, devemos estabelecer um nível de confiança. Por exemplo, podemos decidir rejeitar a hipótese nula se as probabilidades contra ela forem melhores que 95 para 5. Dito de outra forma,  $p$  (a probabilidade de que poderíamos ter obtido os dados que obtivemos se o nulo fosse verdadeiro) é menor que ou igual a 0,05 ( $p \leq 0,05$ ). O Capítulo 7 aborda esses processos com mais detalhes.

## **Variáveis Independentes e Dependentes**

Num experimento, a **variável independente** refere-se à variável que é manipulada ou controlada pelo pesquisador. Isso às vezes é chamado de tratamento. Um pesquisador de nutrição esportiva pode randomizar os indivíduos para receber um suplemento de creatina ou um placebo. Aqui poderíamos chamar esta variável independente de “condição de suplemento” e dizer que ela tem dois níveis (creatina vs. placebo). Da mesma forma, um pesquisador pode estar interessado em examinar o efeito da duração do alongamento na amplitude de movimento da região lombar e dos isquiotibiais. Os indivíduos poderiam ser randomizados para um dos três grupos que realizam alongamento dos isquiotibiais por 15, 30 ou 60 segundos. A **variável independente** pode ser chamada de “duração do alongamento” e, neste exemplo, possui três níveis.

Uma **variável dependente** depende dos efeitos de uma ou mais variáveis. Num estudo experimental, a variável dependente é aquela que é medida. Nessas condições, o pesquisador examina o efeito da variável independente sobre a variável dependente. No estudo da creatina, a variável dependente pode ser a potência máxima de um teste de potência anaeróbica de Wingate. O pesquisador poderá então testar a hipótese da pesquisa de que a suplementação de creatina causa um aumento na potência anaeróbica. Se o estudo for bem desenhado e controlado, e se os indivíduos suplementados com creatina pontuarem mais alto (em média) do que os indivíduos que receberam placebo, então a hipótese é apoiada. Para o exemplo de alongamento no parágrafo anterior, a variável dependente pode ser a flexibilidade da região lombar e dos isquiotibiais, medida pelo teste de sentar e alcançar.

Os termos variável independente e dependente também são utilizados no contexto de estudos observacionais. Imagine que um pesquisador de educação física pergunte aos atletas com que frequência eles praticam e depois lhes aplique um teste de habilidade motora. Poderíamos suspeitar que a habilidade depende da prática; portanto, a habilidade seria a variável dependente e a prática seria a variável independente. Normalmente, quanto mais se pratica, melhor é o desempenho. Se fosse construído um gráfico do tempo de prática (no eixo X) e da habilidade (no eixo Y), o gráfico da relação progrediria do canto inferior esquerdo para o canto superior direito (ver figura 1.1). À medida que o tempo de prática aumenta no eixo X, a habilidade também aumenta no eixo Y. A variável independente é comumente plotada no eixo X e a variável dependente é plotada no eixo Y, e frequentemente nos referimos à variável independente como a variável X e à variável dependente como a variável Y. Observe que o pesquisador não manipulou o tempo de prática. Em vez disso, a quantidade de tempo de prática foi estimada com base no autorrelato dos sujeitos. Portanto, este estudo é observacional e não experimental.

É comum referir-se à variável independente como variável preditora e chamar a variável dependente, que está sendo estudada, de variável critério. Se medíssemos o efeito de uma dieta no ganho ou perda de peso, a dieta seria a variável independente, ou preditora, e o peso seria a variável dependente, ou critério. O ganho ou perda de peso depende dos efeitos da dieta. Estudamos o efeito da variável preditora na variável critério.

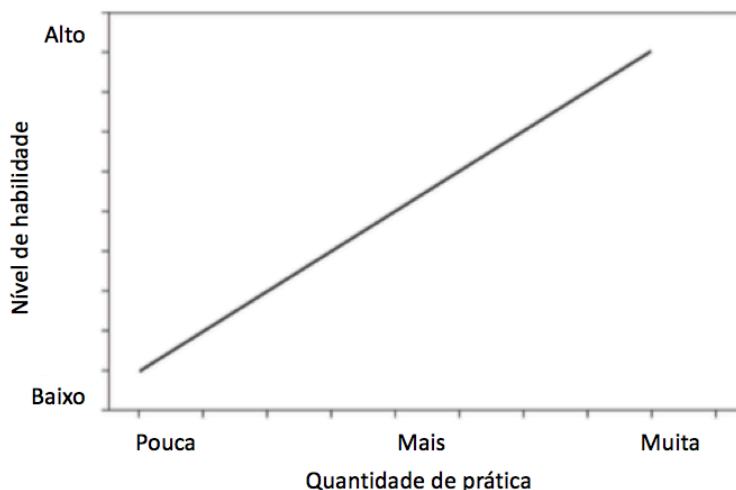


Figura 1.1 Relação entre habilidade e prática.

## Validade Interna e Externa

Anteriormente, observamos que validade é a medida em que um teste mede o que pretende medir. Também utilizamos o termo validade no contexto da qualidade de um estudo de investigação, na medida em que a investigação conduzida por desenho experimental deve demonstrar validade interna e externa. A **validade interna** refere-se ao desenho do estudo em si; é uma medida de controle dentro do experimento para verificar se os resultados são devidos ao tratamento aplicado. Às vezes, quando as pessoas fazem testes de habilidades motoras, elas melhoram seu desempenho simplesmente fazendo o teste duas vezes. Se for realizado um projeto de pré-teste-tratamento-pós-teste, os sujeitos podem apresentar melhorias no pós-teste porque aprenderam técnicas específicas de realização do teste durante o pré-teste. Se essas melhorias forem atribuídas ao tratamento, quando na verdade são devidas à prática do pré-teste, um erro foi cometido.

Para saber se as alterações se devem ao tratamento ou à prática do teste, os pesquisadores poderiam utilizar um **grupo de controle**. O grupo controle também faria o pré e o pós-teste, mas não receberia o tratamento; os sujeitos no grupo controle podem ou não apresentar melhora pós-teste. A análise das diferenças pós-teste entre o grupo experimental e o grupo de controle nos ajuda a determinar quanta melhoria se deve (a) ao tratamento e (b) ao efeito de aprendizagem do pré-teste. Um projeto deste tipo sem grupo de controle pode ser criticado por ter fraca validade interna.

Outros fatores que não são controlados no experimento também podem reduzir a validade interna. Às vezes, esses fatores são chamados de **variáveis intervenientes ou variáveis estranhas**; eles intervêm para afetar a variável dependente, mas são estranhos ao desenho da pesquisa. Por exemplo, se o pós-teste for realizado logo após o tratamento, a fadiga poderá afetar os resultados. Se a fadiga não for uma das variáveis em estudo e se não for devidamente controlada, os resultados podem não refletir o verdadeiro efeito do tratamento. Da mesma forma, um estudo dos efeitos de uma dieta pobre em gorduras na composição corporal que não controle a variável exercício pode chegar a conclusões errôneas. Para preservar a validade interna, todas as variáveis intervenientes em potencial devem ser controladas ou equacionadas entre os grupos do experimento.

Dois outros fatores que podem reduzir a validade interna são o **erro do instrumento e o erro do investigador**. Erro do instrumento refere-se a dados incorretos devido a um instrumento defeituoso. Se usarmos um cronômetro impreciso para medir o tempo, os dados estarão errados. Instrumentos complicados, como analisadores de oxigênio, respirômetros, plataformas de força e dinamômetros, precisam ser calibrados continuamente para garantir que estejam medindo corretamente a variável.

O erro do investigador ocorre quando o investigador introduz tendenciosidade no registro dos dados. Essa **tendenciosidade** pode ser intencional ou não. É claro que esperamos que ninguém falsifique dados intencionalmente, mas sabe-se que isso acontece. Geralmente, porém, o preconceito não é intencional.

Para medições de distância, força, tempo ou frequência, o erro do investigador é geralmente mínimo. É bastante fácil ler um instrumento, especialmente aquele com leitura digital. Mas ao julgar um desempenho qualificado, o investigador, ou juiz, pode produzir pontuações tendenciosas. Outros erros ocorrem quando o investigador não tem habilidade na técnica de coleta de dados, como medir dobras cutâneas para análise da composição corporal ou medir o ângulo articular com um goniômetro portátil. A quantidade de erro que um investigador introduz pode ser determinada comparando os dados do investigador com os recolhidos sobre os mesmos assuntos por um perito ou painel de peritos.

**Validade externa** refere-se à capacidade de generalizar os resultados do experimento para a população da qual as amostras foram provenientes. Se uma amostra

não for **aleatória**, ela pode não representar a população da qual foi extraída. Também é possível que outros fatores (variáveis intervenientes) que foram controlados no experimento possam não ser controlados na população. O próprio fato de a experiência ter sido rigorosamente controlada pode tornar difícil generalizar os resultados para uma situação real em que estas variáveis são deixadas livres para influenciar o desempenho.

Ao conduzir pesquisas, precisamos demonstrar que projetamos o experimento adequadamente e controlamos todas as variáveis apropriadas para garantir a validade interna. Também precisamos mostrar que os resultados podem ser aplicados ao mundo real. O processo de generalização de uma amostra para uma população é chamado de inferência estatística e é uma das ferramentas básicas do estatístico.

## **Inferência Estatística**

Grande parte do trabalho realizado por um estatístico envolve fazer previsões sobre um grande grupo (geralmente um grupo de pessoas, mas pode ser um grupo de animais, pedras, peixes, estrelas ou quase qualquer objeto) com base em dados coletados de uma pequena porção do grupo. Uma **população** é qualquer grupo de pessoas, lugares ou objetos que possuem pelo menos uma característica comum. Estas características são especificadas pela definição da população. Todas as meninas da sétima série de uma determinada escola formariam uma população. Homens com idades entre 31 e 40 anos que não praticam exercícios regulares são outra população. Em suma, uma população pode ser qualquer grupo, desde que os critérios de inclusão no grupo sejam definidos de forma a que fique claro quem se qualifica como membro.

Normalmente, a população de interesse é bastante grande, tão grande que seria praticamente impossível ou financeiramente irracional medir todos os membros. Se for impossível ou impraticável medir todos os membros de uma população, então medimos uma porção, ou fração, da população, que é chamada de **amostra**. Assumimos que os sujeitos da amostra representam ou têm as mesmas características da população. Assim, os dados coletados sobre a amostra pode ser generalizada para estimar as características da população.

Quanto maior a amostra, mais precisamente ela representará a população. Se quisermos saber o índice de massa corporal (IMC) médio de todas as mulheres num

estado, é mais provável que obtenhamos uma imagem precisa da população medindo 1.000 indivíduos do que medindo apenas 10 indivíduos. O erro na previsão está inversamente relacionado ao tamanho da amostra. Se todo o resto for igual, quanto maior a amostra, menor o erro, e quanto menor a amostra, maior o erro.

Em uma **amostra aleatória**, cada membro da população tem oportunidades iguais de ser selecionado para a amostra. Qualquer inferência feita sobre a população com base numa amostra não aleatória tem valor duvidoso. Na verdade, todas as fórmulas e cálculos usados para fazer inferências sobre populações baseiam-se na suposição de amostragem aleatória. Erros graves na estimativa da população podem ser cometidos se a amostra não for aleatória.

Por exemplo, suponha que precisássemos estimar a percentagem média de gordura corporal de todos os homens numa universidade. Uma amostra aleatória exigiria que todos os estudantes do sexo masculino tivessem chances iguais de serem selecionados. Se selecionarmos apenas os homens que entram no ginásio entre as 13h00 e as 15h00. Às 15h00 e às 17h00, a amostra provavelmente representará uma parcela maior de atletas do que a população, porque muitos atletas entram no ginásio neste horário para se prepararem para o treino. Os atletas tendem a ter baixa gordura corporal, portanto, tal amostra provavelmente subestimaria a percentagem média de gordura corporal de toda a população e seria considerada tendenciosa.

Possivelmente não existe nenhum lugar no campus onde todos tenham chances iguais de serem escolhidos em um determinado momento. Se a amostra for colhida durante o dia, serão excluídos os alunos noturnos. Se for realizado na terça-feira, serão excluídos os alunos que não estiverem no campus na terça-feira. Se for tirada perto do edifício de engenharia, é provável que seja escolhido um número desproporcional de cursos de engenharia. Provavelmente, o único lugar onde uma verdadeira amostra aleatória pode ser coletada em uma universidade é nos arquivos do prédio da administração. Usando um computador para selecionar números de identificação aleatórios de uma lista de todos os alunos poderia garantir que cada aluno tivesse chances iguais de ser representado na amostra.

Quando a seleção aleatória em uma grande população é desejada e subcategorias da população são de interesse, uma **amostra estratificada** pode ser obtida. Para fazer isso, selecionamos uma determinada parte da amostra de cada

subgrupo da população. No exemplo anterior, podemos querer garantir a inclusão de alunos do sexo masculino de cada área de especialização, alguns de turmas diurnas, alguns de turmas noturnas, alguns de cada turma acadêmica (calouros, alunos do segundo ano, juniores, veteranos, alunos de pós-graduação) e alguns de cada grupo étnico. A proporção de alunos de cada subgrupo da amostra deve ser igual à proporção desse subgrupo em toda a população. As estatísticas podem então ser compiladas para toda a amostra ou para qualquer subgrupo.

Uma amostra não pode representar com precisão uma população, a menos que seja extraída sem **tendenciosidade ou viés**. **Viés** significa que fatores atuam na amostra para torná-la não representativa da população. Esses fatores às vezes são muito sutis e podemos nem estar cientes deles. Mas se a amostra for totalmente aleatória e suficientemente grande, mesmo os fatores desconhecidos que possam enviesar os resultados serão eliminados ou distribuídos dentro da amostra da mesma forma que são distribuídos na população.

## **Parâmetros e Estatísticas**

A única maneira de conhecer as características exatas de uma população é medir todos os seus membros. Um **parâmetro** é uma característica de toda a população. Uma **estatística** é uma característica de uma amostra usada para estimar o valor do parâmetro populacional.

Qualquer estimativa de um parâmetro populacional baseada em estatísticas amostrais contém algum erro. A quantidade de erro nunca é conhecida com exatidão, mas pode ser estimada com base no tamanho e na variabilidade da amostra. Por exemplo, se medirmos todos os homens numa universidade e determinarmos que a percentagem média de gordura corporal na população é de 21%, este valor é chamado de parâmetro. Se então pegarmos uma amostra e descobrir que o percentual de gordura na amostra é de 18%, esse valor é chamado de estatística. A diferença de 3% entre o parâmetro e a estatística é resultado de **erro amostral**. O Capítulo 7 explica como estimar a quantidade de erro em uma amostra.



## Probabilidade e Teste de Hipótese

A estatística tem sido chamada de ciência de fazer suposições fundamentadas. A menos que toda a população seja medida, a única afirmação que pode ser feita sobre uma população com base numa amostra é uma estimativa fundamentada acompanhada de uma declaração de probabilidade. As estatísticas permitem-nos fazer uma afirmação e depois citar as probabilidades de ela estar correta. Por exemplo, se quiséssemos saber a altura das mulheres de 15 anos numa cidade, poderíamos afirmar que, com base numa amostra aleatória de 200 mulheres, a altura média da população é estimada em 158 centímetros com um fator de erro de  $\pm 5$  centímetros e que as chances de essa estimativa estar correta são de 95 para 5. Em termos estatísticos, isso é chamado de **nível de confiança de 95% ou probabilidade de erro de 5%**. Este fator de erro é geralmente representado como  $p < 0,05$  (p quase nunca é exato, por isso costumamos dizer “a probabilidade de erro é inferior a 5%”).

Outra abordagem pode ser formular hipóteses (adivinhar ou prever) qual será provavelmente a altura média da população e depois utilizar uma amostra e uma declaração de probabilidade para testar a hipótese. Suponhamos que levantemos a hipótese de que a altura média da população de mulheres de 15 anos de idade numa cidade é de 160 centímetros. Usando os dados da amostra de 200 pessoas descritas anteriormente, inferimos que existe uma chance de 95% de que a altura média da população seja de 158 centímetros com um fator de erro de  $\pm 5$  centímetros (o capítulo 7 descreve como prever parâmetros populacionais usando inferências estatísticas). Isto significa que as probabilidades são de 95 para 5 de que a verdadeira altura média da população feminina esteja entre 153 e 163 centímetros. Nestas condições, aceitamos como verdadeira a hipótese de que a altura é de 160 centímetros porque está dentro dos limites dos valores estimados a partir da amostra. No entanto, uma hipótese de que a média ou média a altura é de 165 centímetros seria rejeitada porque esse valor não está dentro dos limites do valor populacional estimado.

A técnica de formular hipóteses e depois testá-las por meio de experimentação fornece respostas a questões que não podem ser respondidas diretamente de nenhuma outra forma. É aqui que reside o valor real da estatística inferencial: a capacidade de

fazer uma afirmação com base em pesquisas e estimar a probabilidade de que a afirmação esteja correta.

## **Teorias e Hipóteses**

Uma teoria é uma crença a respeito de um conceito ou de uma série de conceitos relacionados. As teorias não são necessariamente verdadeiras ou falsas. Eles são apenas produtivos ou improdutivos na produção de hipóteses. Teorias frutíferas produzem muitas hipóteses que podem ser testadas pelo processo científico de experimentação. Uma hipótese é declarada mais especificamente do que uma teoria e pode ser testada em um experimento. Quando o experimento estiver concluído, as chances de a hipótese estar correta ou incorreta podem ser declaradas. Determinamos essas probabilidades usando procedimentos estatísticos.

Quando uma teoria produz muitas hipóteses, muitas ou todas consideradas corretas (por estudos originais e confirmatórios), a teoria é aceita como verdadeira. Geralmente esse processo passa por vários estágios, e a teoria é revisada à medida que o processo avança. O processo pode levar anos, décadas ou até séculos. Finalmente, a teoria é aceita como a interpretação mais correta dos dados observados. Quando muitas ou a maioria das hipóteses produzidas por uma determinada teoria são rejeitadas ou não podem ser confirmadas por outros cientistas imparciais, a teoria é revista ou abandonada.

Um exemplo desse processo no campo do comportamento motor é encontrado no conceito de prática mental, ou visualização. Durante muitos anos, cientistas e atletas acreditaram, mas não conseguiram provar, que a aprendizagem das capacidades motoras era melhor conseguida através de uma combinação de processos mentais e físicos. Os atletas pareciam saber intuitivamente que poderiam melhorar o desempenho visualizando-se executando a habilidade. Esta teoria produziu muitas hipóteses, que foram testadas. Uma hipótese popular era que se uma pessoa apenas pensasse numa habilidade física, sem nunca a ter executado fisicamente, o seu desempenho nessa habilidade melhoraria.

Alguns estudos em meados do século XX produziram algumas pistas de que isto pode de fato ser verdade. Um dos primeiros pesquisadores nesta área (Twinning, 1949)

publicou um estudo que demonstrou diferenças significativas no desempenho físico entre indivíduos na condição controle<sup>5</sup> e indivíduos que se visualizaram realizando uma nova habilidade. Logo outros estudos com hipóteses semelhantes, mas modificadas, foram adicionados à base de conhecimento.

Na década de 1960, foram publicados muitos estudos (Egstrom, 1964; Jones, 1965; Oxendine, 1969; Richardson, 1967; Vincent, 1968) baseados na teoria da visualização, a maioria dos quais confirmou a conclusão de que os grupos de visualização têm um desempenho significativamente melhor do que os grupos na condição controle, mas não tão bem quanto grupos de prática física. A teoria, ou crença geral, produziu hipóteses testáveis que foram apoiadas por muitos experimentos. Hoje, a teoria de que a visualização melhora o desempenho de uma habilidade física é bem aceita.

## **Uso Indevido da Estatística**

As propagandas tendem a citar estatísticas livremente. Dizem-nos que uma determinada pasta de dentes é melhor que outra, que “com o nosso aparelho mágico, pode perder 4,5 quilos por semana com apenas 1 minuto de exercício por dia” ou que “8 em cada 10 médicos recomendam o nosso produto”. Estes são exemplos de estatísticas que podem ou não ser verdadeiras. Tais declarações enganosas geralmente resultam de uma definição inadequada de termos, da falta de uma amostra aleatória ou de uma amostra muito pequena; ou uma afirmação pode não ter nenhuma análise estatística para apoio ou ser apenas uma suposição sem instrução.

Uma instituição educacional afirmou que 33% dos alunos se casam com seus professores. Embora isto fosse verdade naquele momento para aquela escola (apenas três mulheres estavam matriculadas na escola e uma casou com um professor), é um exemplo de generalização imprópria a partir de uma pequena amostra. Isso leva o leitor a uma conclusão incorreta.

Às vezes, a palavra média é enganosa. Por exemplo, é possível mostrar que mais de metade da população tem um rendimento anual inferior à média. Se 9 pessoas ganham US\$ 10.000 por ano e 1 ganha US\$ 100.000, então 9 em cada 10 ganham menos do que a renda média de US\$ 19.000. Talvez uma melhor descrição da renda da

---

<sup>5</sup> Condição controle é quando as pessoas não receberam tratamento experimental.

população fosse a renda típica (percentil 50). Pontuações extremas, às vezes chamadas de outliers<sup>6</sup>, têm um efeito desproporcional nas estatísticas. Isso é um tanto análogo à piada sobre o homem com a cabeça no forno e os pés no freezer que comentou: “Em média, me sinto bem”.

Estatística é o processo de fazer suposições fundamentadas. Um estatístico tenta explicar ou controlar os efeitos aleatórios que podem estar operando e fazer uma declaração de probabilidade sobre os efeitos reais restantes. As estatísticas não comprovam uma afirmação. Na melhor das hipóteses, fornecem-nos informações suficientes para estimar a probabilidade de a afirmação ser verdadeira.

Precisamos ter cuidado ao produzir ou utilizar estatísticas. Devemos relatar apenas resultados bem documentados, válidos, confiáveis e objetivos. Devemos ter cuidado com afirmações incomuns ou únicas, especialmente se a fonte das estatísticas for suscetível de beneficiar financeiramente quando acreditarmos nas afirmações.

## **Resumo**

Este capítulo introduziu os conceitos de medição, estatística e pesquisa, discutindo os fundamentos da teoria da medição e o processo de como as coisas são medidas. Este capítulo também discutiu as inter-relações entre princípios de medição, estatísticas e desenho de pesquisa. O desenho da pesquisa e a análise estatística estão sempre inter-relacionados. A pesquisa não pode ser conduzida sem análise estatística, e a análise estatística adequada depende da qualidade do desenho da pesquisa.

Foram introduzidos o processo de teste estatístico de hipóteses e o uso adequado da pesquisa e da hipótese nula.

A inferência estatística é uma ferramenta essencial usada pelo estatístico para estimar parâmetros populacionais a partir de estatísticas amostrais.

---

<sup>6</sup> Outlier é conhecido em Português como um ponto fora da curva, ou um dado que difere significativamente das outras observações naquela distribuição. A discrepância pode ser devida a uma variabilidade na medição, pode ser o resultado de um erro experimental, ou apenas um resultado atípico, porém correto decorrente de alguma medida.

## **Recurso de Atividades na Web**

O recurso da web oferece uma variedade de atividades interativas para ajudá-lo a aprender e compreender as informações apresentadas no texto. Você encontrará mini-palestras e atividades importantes e será capaz de resolver exemplos de problemas. Visite a página deste capítulo ou use este código para acessar as miniaulas do capítulo 1.



## CAPÍTULO 2

### ORGANIZANDO E APRESENTANDO OS DADOS

Cientistas Nas Olimpíadas de 2004 em Atenas, na Grécia, registraram dados sobre o desempenho de todos os atletas em todos os eventos. Os dados não eram todos do mesmo tipo. Houve (1) pontuações dos juízes, como as da ginástica e dos saltos ornamentais; (2) tempos em minutos e segundos, como em corridas de atletismo, natação e remo; (3) distâncias em metros, como nas provas de lançamento e salto; (4) forças em quilogramas, como as do levantamento de peso; e (5) contagem, como pontos no basquete, corridas no softball ou gols no futebol. Muitos cientistas em cada um dos locais registraram dados.

Após as Olimpíadas, os cientistas colocaram os resultados em um único banco de dados para que pudessem comparar os dados entre todos os atletas e entre todas as nações. Quando os cientistas terminaram de inserir os dados, descobriram que tinham um banco de dados enorme, complicado e difícil de ler. Tinha centenas de linhas de dados (cada linha representando uma atleta e sua nação) e múltiplas pontuações para cada atleta ou equipe. Os dados estavam todos lá, mas estavam desorganizados. Como os dados podem ser organizados e exibidos para que possam ser feitas comparações apropriadas?

## Organizando os Dados

No capítulo 1, a estatística foi definida como uma técnica matemática pela qual os dados são organizados, tratados e apresentados para interpretação e avaliação. Os computadores são dispositivos maravilhosos que podem organizar, analisar e exibir dados muito melhor do que os humanos. Os computadores melhoram o cérebro humano porque podem lembrar grandes quantidades de dados e computar com mais rapidez. Você deve usar um computador sempre que possível. No entanto, os computadores são apenas uma extensão do cérebro humano. Eles não terão um bom desempenho a menos que alguém insira os dados corretamente e compreenda o resultado. Antes que um computador tenha valor para você, você deve saber o que deseja que ele faça e o que esperar do resultado. Este capítulo demonstra técnicas para organizar e exibir dados brutos em um formato legível e útil. Explica como exibir os dados em tabelas e como criar gráficos para que os dados possam ser interpretados mais facilmente. Depois de compreender os métodos envolvidos, você deve usar um computador para acelerar o processo.

Os dados coletados pelos cientistas contêm muitas informações de valor potencial. Antes de podermos derivar informações de dados brutos, devemos organizar os dados em um formato lógico, legível e utilizável, denominado tabela de distribuição. Três tipos de tabelas de distribuição são discutidos neste capítulo: **a distribuição por ordem de classificação, a distribuição de frequência simples e a distribuição de frequência agrupada.**

**TABELA 2.1 Distribuição de ordem de classificação do escores de puxadas**

X
18
17
16
15
14
13
12
10
9
9
8
8
5
2
N = 15
Máx = 18
Mín = 2
$A = 18 - 2 = 16$

### **Distribuição por Ordem de Classificação**

Uma **distribuição por ordem de classificação** é uma listagem ordenada dos dados em uma única coluna. Apresenta uma visão rápida da distribuição ou variabilidade do grupo. Identifica facilmente as pontuações extremas, as mais altas e as mais baixas. Uma distribuição por ordem de classificação é usada quando o número de dados (N) é relativamente pequeno (ou seja,  $\leq 20$ ). Se a listagem ordenada dos dados couber em uma página, então a distribuição da ordem de classificação é apropriada.

A **amplitude** (A) é a distância em valor numérico do escore mais alto (Máx) ao mais baixo (Mín). É calculado subtraindo a pontuação mais baixa da pontuação mais alta:

$A = \text{Máx} - \text{Mín}$	(2.01)
-------------------------------	--------



O intervalo não é facilmente determinado até que os dados brutos sejam ordenados. A seguir está um subconjunto de dados retirados da caderneta de um professor de educação física. Os dados representam o número de puxadas na barra realizadas por 15 meninos da oitava série.

Dados brutos:	12, 10, 9, 8, 2, 5, 18, 15, 14, 17, 13, 12, 8, 9, 16.
---------------	---

Esses dados são difíceis de interpretar porque não estão organizados. Quando os dados são colocados numa distribuição ordenada, do mais alto para o mais baixo (ver tabela 2.1), são mais fáceis de interpretar. O símbolo  $X$  representa uma variável, neste caso puxadas, e  $N$  (o número de escores) = 15.

Quando os escores das puxadas são organizadas em uma distribuição por ordem de classificação, é fácil ver que existe uma grande diferença na capacidade de realizar puxadas. A dispersão do grupo, ou intervalo, é considerável – de 2 a 18 puxadas.

## **Distribuição por Frequência Simples**

Quando o número de casos em estudo é maior do que cabe em uma página, é inconveniente listá-los separadamente porque a lista seria muito longa. Conjuntos de dados maiores podem ser organizados em uma distribuição de **frequência simples**, uma listagem ordenada da variável em estudo ( $X$ ), com uma coluna de frequência ( $f$ ) que indica o número de casos em cada valor dado de  $X$ . (Este padrão é referido como uma distribuição de frequência simples porque também existe uma distribuição mais complicada chamada distribuição de frequência agrupada, que consideraremos a seguir).

Suponha que um estudante com especialização em cinesiologia queira analisar as pontuações de puxadas na barra de todos os 212 alunos masculinos do curso de cinesiologia da universidade ( $N = 212$ ). Para evitar uma lista longa, o aluno poderia organizar as pontuações na distribuição de frequência simples apresentada na tabela 2.2.

A coluna da esquerda na tabela 2.2, denominada  $X$ , representa a variável (escores de puxadas), e a coluna da direita, denominada  $f$ , representa o número de

sujeitos que receberam um determinado escore. O número de sujeitos medidos (N) é representado pela soma da coluna de frequência (212). Use este tipo de distribuição de frequência simples quando  $N > 20$  e  $A \leq 20$ . Isso permitirá que você ajuste todos os dados em uma folha de papel.

**TABELA 2.2** Distribuição de frequência simples – Escores de puxadas na barra

<b>X</b>	<b>f</b>
20	2
19	0
18	3
17	6
16	8
15	10
14	17
13	21
12	25
11	24
10	26
9	19
8	16
7	12
6	10
5	4
4	3
3	2
2	1
1	2
0	1
	212
	N = 212
	Máx = 20
	Mín = 0
A = 20 – 0 = 20	

### **Distribuição por Frequência Agrupada**

É bastante fácil organizar os dados numa distribuição de frequência simples se o intervalo de escores for apenas 20, mas os investigadores trabalham frequentemente com variáveis que produzem um intervalo de mais de 20 escores. Quando os professores

de educação física analisaram a capacidade aeróbica de seus alunos estimada pelos escores na corrida de uma milha (N = 206), descobriram que o escore mais baixo, ou tempo mais rápido, foi de 302 segundos e o escore mais alta, ou tempo mais lento, foi de 595 segundos — um intervalo de 293 segundos (595 – 302 = 293). Com tal intervalo, é impraticável listar todas os escores em uma linha. Os professores precisavam de um método de agrupamento de dados que reduzisse o comprimento da lista de dados brutos.

Uma **distribuição de frequência agrupada** é uma listagem ordenada de, em uma coluna, uma variável (X) em grupos de escores e, em uma segunda coluna [a coluna de frequência (f)], o número de pessoas que tiveram desempenho em cada grupo de escores. Quando  $N > 20$  e  $A > 20$ , deve ser utilizada uma distribuição de frequência agrupada.

Ao configurar uma distribuição de frequência agrupada, devemos primeiro decidir quantos grupos devem ser formados. Por conveniência, adotaremos 15 como número ideal de grupos. Quinze foram escolhidos porque representam um número razoável de grupos para listar em uma página de papel, mas a decisão é arbitrária.

Quando o número de grupos se torna tão pequeno quanto 10, o número de pontuações em cada grupo pode tornar-se demasiado grande. Isto tende a obscurecer os dados porque muitos casos estão agrupados. Da mesma forma, quando há mais de 20 grupos, os grupos ficam tão dispersos que alguns grupos podem não ter casos e a lista torna-se longa e complicada. Por estas razões, é melhor manter o número de grupos em cerca de 15, mas o número pode variar entre 10 e 20.

No exemplo anterior dos tempos de corrida de milhas, grupos de 20 escores cada (por exemplo, 300–319) produzem 15 grupos (ver tabela 2.3).

A fórmula para o tamanho do **intervalo** (o tamanho de um grupo de escores em uma determinada variável;  $i$ ) é

$i = \text{amplitude} / 15$	(2.02)
-----------------------------	--------

Para os dados de milhas percorridas,  $i = 293/15 = 19,53$ , que arredondamos para 20. Agrupar os escores é muito mais fácil se pudermos colocar os escores em grupos que tenham números inteiros para seus pontos inicial e final. Mas dependendo do intervalo,

o tamanho do intervalo pode ser um valor inteiro ou decimal. Para simplificar o processo de agrupamento, geralmente arredondamos o tamanho do intervalo para o número inteiro ímpar mais próximo. Um tamanho de intervalo ímpar sempre resulta em um grupo com um número inteiro como ponto médio.

A única exceção à regra de arredondamento ímpar é quando o tamanho do intervalo é igual ou próximo de 10 ou 20 (como é o caso do nosso exemplo). Como estamos mais familiarizados com 10 do que com qualquer outro número, 10 constitui um tamanho de intervalo conveniente. Mesmo que o ponto médio não seja um número inteiro, os valores de tamanho de intervalo próximos a 10 ou 20 são geralmente arredondados para 10 ou 20 por conveniência na criação de grupos e na contabilização de dados brutos nos grupos. A decisão de arredondar para um número inteiro ímpar, ou para 10 ou 20 quando o tamanho do intervalo estiver próximo desses números, é outra decisão arbitrária. Estas escolhas baseiam-se na natureza dos dados e na necessidade de simplicidade na contagem dos escores em grupos.

**TABELA 2.3 Distribuição de frequência agrupada: Tempos em segundos para corrida de 1 milha**

<b>X</b>	<b>f</b>
580-589	3
560-579	9
540-559	13
520-539	15
500-519	17
480-499	21
460-479	19
440-459	19
420-439	18
380-399	15
360-379	12
340-359	9
320-339	5
300-319	2
	N = 206

Depois que o tamanho do intervalo for determinado, criamos os grupos. Quando o tamanho do intervalo for um múltiplo de 5 (ou 0,5 se os dados forem registrados em

décimos), o grupo mais baixo deverá incluir a pontuação mais baixa dos dados, mas o limite inferior do grupo mais baixo deverá ser um múltiplo de 5. Quando o tamanho do intervalo não for um múltiplo de 5, o limite inferior do grupo mais baixo deve ser igual à pontuação mais baixa nos dados. Como a determinação do tamanho do intervalo é uma decisão arbitrária, o procedimento de arredondamento pode ser modificado para criar grupos com os quais seja fácil trabalhar.

Como  $i = 20$ , queremos 20 pontuações por grupo, e o primeiro grupo deve começar com um múltiplo de 5. A pontuação mais baixa é 302, portanto o primeiro grupo incluirá todas as pontuações entre 300 e 319 (ver tabela 2.3). Observe que o limite superior do primeiro grupo é 319, não 320. O grupo começa em 300, e o 20º score acima de 300 é 319. De maneira semelhante, são criados os demais grupos, com 20 pontuações em cada grupo. O processo de criação de grupo continua na escala de dados até que seja criado um grupo (580–599) que inclua a pontuação mais alta (595).

Depois que os grupos forem criados, registre os scores que se enquadram em cada grupo. A frequência de cada grupo é determinada pela soma das marcas de contagem. Normalmente a contagem é feita em papel de rascunho; o resultado final mostra apenas os grupos e a frequência, conforme mostra a tabela 2.3. O agrupamento dos scores facilita a interpretação visual dos dados. Na tabela 2.3, a maioria dos valores está nos grupos intermediários e a média é de cerca de 450 segundos. Como as tabelas de frequência de grupo são usadas quando  $N$  é grande, um computador pode ser de grande ajuda ao lidar com grandes bancos de dados que exigem tabelas de distribuição de frequência. É comum encontrar software para computador que permitirá ao usuário inserir dados e organizá-los de várias maneiras.

Algumas informações são perdidas durante o agrupamento. Por exemplo, uma vez agrupados os scores, é impossível dizer exatamente qual score uma determinada pessoa recebeu. Sabemos que 25 sujeitos tiveram scores entre 440 e 459 segundos, mas não sabemos como os scores estão distribuídos dentro do grupo. Todos os 25 sujeitos tiveram scores de 450? Alguém marcou 440, 445 ou 455? Se assumirmos que os scores num grupo estão igualmente distribuídas dentro desse grupo, então o score que melhor representa todo o grupo é o score que fica no ponto médio do grupo. Usar números inteiros para os pontos médios facilita o trabalho com os dados.

O processo descrito para agrupar dados funciona bem para dados discretos nos quais valores decimais não estão envolvidos. No entanto, surge um problema quando usamos dados contínuos e medimos as pontuações em frações de números inteiros. Considere a distribuição de frequência agrupada que representa o tempo em segundos para nadar 100 metros mostrada na tabela 2.4.

**TABELA 2.4** Distribuição de frequência agrupada: Tempos em segundo para prova de 100 metros na natação

<b>X</b>	<b>Y</b>
<b>115-119</b>	<b>1</b>
<b>110-114</b>	<b>2</b>
<b>105-109</b>	<b>3</b>
<b>100-104</b>	<b>7</b>
<b>95-99</b>	<b>10</b>
<b>90-94</b>	<b>15</b>
<b>85-89</b>	<b>17</b>
<b>80-84</b>	<b>11</b>
<b>75-79</b>	<b>5</b>
<b>70-74</b>	<b>4</b>
<b>65-69</b>	<b>2</b>
<b>60-64</b>	<b>2</b>
	<b>N = 79</b>

Os tempos de natação são geralmente medidos em décimos, ou mesmo centésimos, de segundo. A distribuição de frequência agrupada é configurada por números inteiros, mas os dados brutos incluem decimais. Um aluno que nadou a distância em 86,4 segundos seria obviamente incluído no grupo de 85 a 89, mas em qual grupo colocaríamos o aluno que marcou 84,7 segundos? Como as pontuações de tempo podem ser registradas com qualquer grau de precisão, devemos tomar algumas

providências para acomodar essas pontuações intermediárias. Conseguimos isso estabelecendo os limites reais dos grupos.

Os **limites aparentes** de cada grupo são os valores inteiros listados para cada grupo na distribuição de frequência agrupada. Existe uma lacuna de um ponto entre o limite final aparente de um grupo e o início do próximo. Os **limites reais** de cada grupo são os valores de pontuação superior e inferior assumidos em cada grupo, criados no grau de precisão exigido pelos dados; os limites reais definem os verdadeiros limites superior e inferior do grupo. Para estabelecer os limites reais, a distância entre os limites aparentes é dividida igualmente; os valores na metade superior pertencem ao grupo acima e os valores na metade inferior pertencem ao grupo abaixo.

O limite real inferior do grupo 80 a 84 é 79,5, e o limite real superior é 84,49999.... Normalmente, o limite real superior é realizado com uma casa decimal a mais do que os dados exigem (ou seja, se os dados forem em décimos, defina o limite em centésimos).

Assim, para estabelecer os limites reais dos grupos de natação de 100 metros, elevamos em 0,49 o escore mais alto do grupo e baixamos em 0,5 o escore mais baixo do grupo. Feito isso, é fácil determinar que o nadador cujo tempo foi de 84,7 segundos deve ser incluído no grupo de 85 a 89 porque o limite real inferior desse grupo é 84,5. Os limites reais geralmente não são listados na distribuição de frequência agrupada, portanto, precisamos manter esses valores em mente quando classificamos os dados em grupos de acordo com os limites reais, e não os aparentes.

## **Exibindo os Dados**

Os dados podem ser exibidos de diversas maneiras. As seções a seguir detalham as diversas opções de exibição.

### **Tabelas e Planilhas**

As tabelas apresentam dados em formato de linha e coluna. Na terminologia da informática, uma tabela às vezes é chamada de planilha. As planilhas são úteis para organizar e exibir dados.

As planilhas são especialmente úteis ao apresentar dados multivariados (dados com mais de uma variável medida em cada assunto). Tradicionalmente, as planilhas apresentam dados com os assuntos listados em uma coluna verticalmente à esquerda e as variáveis listadas horizontalmente na linha superior. Nesse arranjo, você pode ver todos os escores de um determinado assunto examinando as linhas, ou todas os escores de uma determinada variável examinando as colunas. A Tabela 2.5 é um exemplo de planilha representando cinco sujeitos em três variáveis: altura, peso e índice de massa corporal (IMC).

**TABELA 2.5 Exemplo de Planilha**


Número do Sujeito	Estatura (pol.)	Peso (lb)	Índice de Massa Corporal
1	60	150	25
2	70	165	21
3	62	160	25
4	65	130	19
5	67	200	27

O Microsoft Excel é um exemplo de software de planilha. O Excel pode facilmente somar colunas ou linhas, calcular estatísticas descritivas e realizar outros tipos de testes estatísticos em dados uni ou multivariados. Ele também pode criar novas variáveis manipulando variáveis existentes. Por exemplo, a coluna do IMC na tabela 2.5 foi criada utilizando uma fórmula para calcular o IMC a partir da altura e do peso.

## **Gráficos**

Os gráficos são outra forma de apresentar informações sobre os dados. Os gráficos são representações visuais de dados que nos fornecem informações sobre os dados que podem não ser facilmente observados em uma planilha ou tabela. Um gráfico é uma representação figurativa ou visual de dados. Os gráficos são úteis para comparar dois ou mais conjuntos de dados ou para mostrar tendências. Todos os gráficos devem incluir pelo menos três características: (1) um título, (2) um rótulo no eixo X (a abcissa) e (3) um rótulo no eixo Y (a ordenada). Outras notas explicativas e informações podem ser incluídas no gráfico, tais como valores numéricos nos eixos X e Y (ver figura 2.1).





**Figura 2.1** Histograma dos 100 metros na natação

Para gráficos que transmitem frequências de escores, é prática geral colocar a frequência na ordenada (vertical ou eixo Y) e os escores na abscissa (horizontal ou eixo X), mas esta prática não é obrigatória. A reversão desse processo giraria o gráfico 90°, mas os dados não seriam alterados. No eixo X, os escores se movem da esquerda para a direita à medida que os valores numéricos se movem do menor para o maior. Mas lembre-se, bons escores nem sempre são escores altos – por exemplo, corredores mais rápidos têm escores de tempo mais baixos. No eixo Y, as frequências movem-se de baixo para cima à medida que os valores numéricos se movem de baixo para cima. A seguir estão exemplos de vários tipos de gráficos.

### ***Histograma***

Provavelmente o gráfico mais comum é o **histograma ou gráfico de barras**. Geralmente é construído a partir de uma distribuição de **frequência agrupada**, mas também pode originar-se de uma distribuição de **frequência simples**. As barras no eixo X representam os grupos, e a altura de cada barra é determinada pela frequência desse grupo conforme plotado no eixo Y. Os dados da tabela 2.4 (tempos de natação de 100 metros) são mostrados na figura 2.1 em um histograma. Os limites aparentes de cada grupo são plotados no eixo X.

Outro gráfico que pode ser construído a partir de dados de distribuição de frequência, denominado **polígono de frequência**, é um gráfico de linhas das pontuações plotadas em relação à frequência. Geralmente é formado a partir de dados simples de

distribuição de frequência, plotando as pontuações ordenadas no eixo X em relação à frequência no eixo Y. Um histograma pode ser convertido em um polígono de frequência traçando os pontos médios das barras. Um polígono de frequência dos dados da tabela 2.2 sobre pontuações puxadas na barra é mostrado na figura 2.2.




Figure 2.2 Polígono de frequência para escores de puxadas na barra

### *Gráfico de Frequência Cumulativa*

Um terceiro gráfico frequentemente usado por estatísticos é chamado de gráfico de **frequência cumulativa ou curva de frequência cumulativa**. É um gráfico de linhas de escores ordenados no eixo X plotados em relação ao número de indivíduos que obtiveram escore igual ou abaixo de um determinado escore no eixo Y. Um fisiologista do exercício, estudando os efeitos dos exercícios contrarresistência, mediu a força da parte superior do corpo em um grupo de indivíduos e contou o número de mergulhos<sup>7</sup> na barra que os indivíduos poderiam realizar nas barras paralelas. O cientista organizou os dados resultantes numa distribuição de frequência agrupada e construiu uma tabela de frequência agrupada que incluía uma coluna de frequência cumulativa (ver tabela 2.6).

---

<sup>7</sup> Mergulho na barra (arm dips) é um exercício de extensão e flexão do cotovelo que visa fortalecer principalmente a musculatura do tríceps

A coluna de frequência cumulativa nos informa o status de cada sujeito em comparação com o grupo total. É calculado determinando o número de sujeitos cujo escore é igual ou inferior à de cada grupo. Para conseguir isso, adicionamos a frequência de um determinado grupo às frequências de todos os grupos abaixo dele. Para determinar a frequência cumulativa do grupo de 10 a 12, somamos  $6 + 10 + 15 + 18 = 49$ .

O gráfico de frequência cumulativa é traçado com escores no eixo X e frequência cumulativa no eixo Y. Como os dados da tabela 2.6 são discretos, o limite superior aparente de cada grupo é traçado porque esse valor representa todos os indivíduos que pontuaram nesse grupo ou abaixo dele. Para dados contínuos, os limites reais superiores seriam traçados para representar a pontuação máxima que poderia ser obtida por qualquer pessoa nesse grupo ou nos grupos abaixo. A Figura 2.3 é um exemplo de gráfico de frequência cumulativa para os dados do teste de imersão em barras paralelas da tabela 2.6.

**TABELA 2.6** Força de membros superior medidas pelo teste de mergulho na barra paralela

X	f	f Acumulada
34-36	2	130
31-33	4	128
28-30	5	124
25-27	7	119
22-24	9	112
19-21	15	103
16-18	19	88
13-15	20	69
10-12	18	49
7-9	15	31
4-6	10	16

1-3	6	6
	N = 130	




Figura 2.3 Frequência cumulativa de mergulhos nas barras paralelas.

### *Gráfico de Plotagem de Pontos*

Uma tendência recente é criar gráficos que exibam, se possível, os dados brutos (Drummond e Vowler, 2011). Uma maneira de transmitir graficamente os escores brutos é criar um **gráfico de pontos**. Em um gráfico de pontos, cada ponto representa a pontuação de uma variável dependente para cada sujeito. Os indivíduos com os mesmos escores são posicionados ao longo de uma linha horizontal no nível apropriado no eixo Y. A Figura 2.4 representa gráficos dos escores de edema do tornozelo; este exemplo será analisado estatisticamente no capítulo 10.

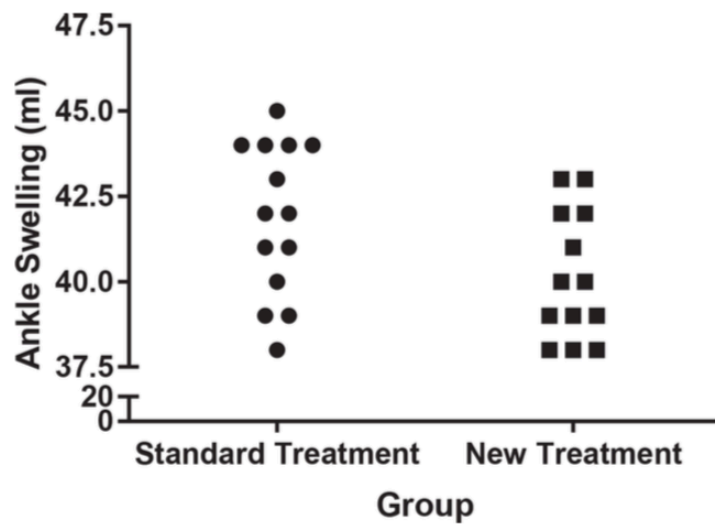


Figura 2.4 Gráfico de pontos de escore de edema muscular

## Curvas

Uma curva é a linha que resulta quando os escores (X) são plotados em relação à frequência (Y) em um gráfico. A forma da curva depende da distribuição dos dados. Uma curva apresenta uma imagem visual que nos permite ver tendências nos dados que não podemos observar facilmente quando olhamos para uma tabela. As curvas a seguir são comumente usadas em estatísticas.

### Curva normal


A curva mais conhecida na estatística é a **curva normal**. Esta curva de formato único, descrita pela primeira vez pelo matemático Karl Gauss (1777-1855), é às vezes chamada de **curva gaussiana ou curva em forma de sino**.

A natureza geralmente se comporta de acordo com a regra. Karl Friedrich Gauss descobriu esse fato e formulou a sua descoberta numa expressão matemática de distribuição normal ... e esta curva tornou-se desde então a condição *sine qua non* do estatístico. (Leedy, 1980, p. 25)

Uma curva normal é caracterizada pela distribuição simétrica de dados em torno do centro da curva de uma maneira especial. A média<sup>8</sup>, a mediana (percentil 50) e a moda (escore com maior frequência) estão todas localizadas no meio da curva. A frequência dos escores diminui de maneira previsível à medida que os escores se desviam cada vez mais do centro da curva.

Todas as curvas normais são bilateralmente simétricas e geralmente têm o formato de um sino, mas nem todas as curvas simétricas são normais. Quando os dados são identificados como normais, as características especiais da curva normal podem ser utilizadas para fazer afirmações sobre a distribuição dos escores. Muitas das variáveis medidas em cinesiologia são normalmente distribuídas, portanto os pesquisadores de cinesiologia precisam entender a curva normal e como ela é usada. O Capítulo 6 discute detalhadamente as características especiais da curva normal.

Uma curva normal típica é apresentada na figura 2.5. Observe que as duas extremidades, ou caudas, da curva são simétricas e representam as pontuações nos extremos inferior e superior da escala. Quando as pontuações se aproximam dos valores extremos na escala de dados, a frequência diminui. Isto é demonstrado pelos dados representados na tabela 2.4. A maioria dos sujeitos pontua na faixa intermediária.



**Figura 2.5** Curva normal.

Usamos extensivamente a distribuição normal na estatística, o que sugere que a distribuição aparece muito na natureza. É claro que poderíamos estar usando a

---

<sup>8</sup> Média é o somatório de todos os escores de uma distribuição de dados dividido pelo o número total de escores desta distribuição

distribuição normal quando não deveríamos; isto é, talvez curvas que pensamos serem Gaussianas realmente não o sejam. No entanto, a uniformidade da distribuição normal na estatística baseia-se no **teorema do limite central**. O teorema do limite central pode ser definido de várias maneiras. No entanto, explicado de forma simples, uma soma de números aleatórios torna-se normalmente distribuída à medida que mais e mais números aleatórios são somados (Smith, 1997). Para ver como isso funciona, imagine que um gerador de números aleatórios cuspiu 20 números e você calculou e salvou o valor médio desses 20 números. Então você repetiu esse processo indefinidamente, então você tinha muitos dessas médias em uma panela. Se você fizesse uma distribuição de frequência dessas médias, seria quase normal (Gaussiana). A onipresença da distribuição normal decorre da ideia de que a aleatoriedade leva a distribuições Gaussianas. O teorema do limite central é uma base fundamental de muitos dos nossos usos da estatística.

### ***Curvas Mesocúrtica, Leptocúrtica e Platicúrtica***

Quando a maioria dos escores fica na faixa média e a frequência dos escores diminui simetricamente em direção às caudas, ocorre a familiar curva em forma de sino. Isso é conhecido como **curva mesocúrtica**<sup>9</sup>. No entanto, as caudas de uma distribuição podem ser mais espessas ou mais finas do que numa distribuição normal. O termo platicúrtica refere-se a curvas com caudas mais finas do que em uma distribuição normal, e leptocúrtica refere-se a curvas com caudas mais pesadas do que em uma distribuição normal. No capítulo 6, será descrito o cálculo do que é chamado de curtose, e esse cálculo nos ajuda a interpretar as curvas em relação às suas características mesocúrticas, platicúrticas ou leptocúrticas.

### ***Curvas Bimodais***

A **moda** é o escore com maior frequência. Na curva normal, uma única moda está sempre no meio, mas algumas distribuições de dados têm duas ou mais modas e, portanto, são chamadas de **bimodais**, ou **multimodal**. Se uma moda for superior à outra, as modas serão chamadas de modas maior e menor. Quando essas distribuições de

---

<sup>9</sup> Mesokurtic: meso = meio e kurtic = curva

dados são plotadas, elas apresentam duas ou mais saliências que representam o agrupamento de escores. As curvas bimodais não são curvas normais. Uma curva bimodal é mostrada na figura 2.6.

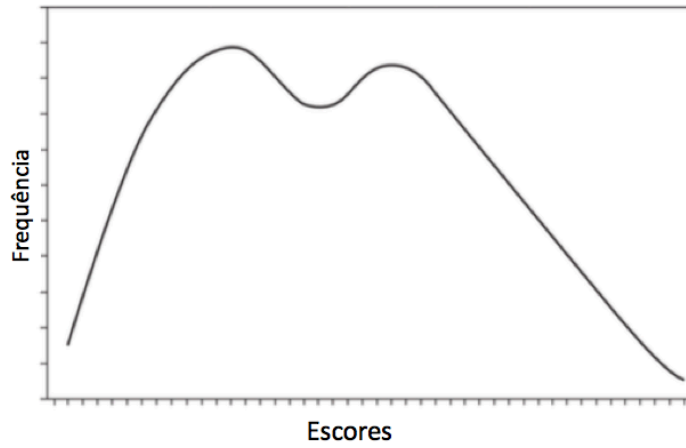


Figura 2.6 Curva bimodal

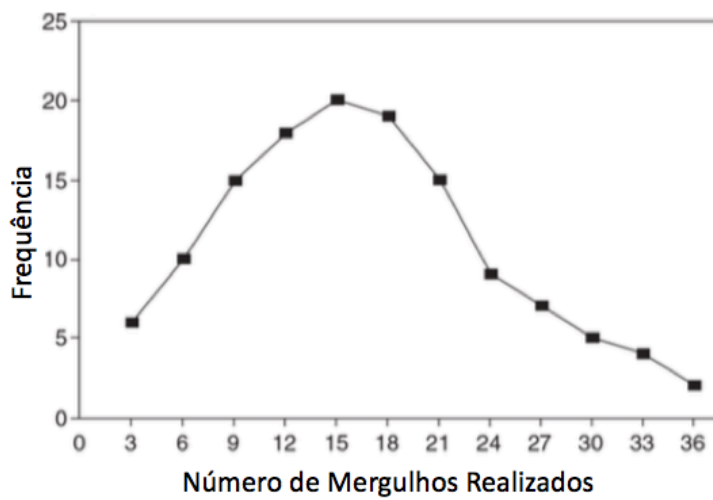


Figura 2.7 Curva positivamente assimétrica de mergulhos na barra paralela



## Curvas Assimétricas

Às vezes, os dados resultam em uma curva que não é normal; isto é, as caudas da curva não são simétricas. Quando um número desproporcional de sujeitos pontua em uma extremidade da escala, a curva fica distorcida. Os dados da tabela 2.6 para mergulho nas barras paralelas mostram que um número maior de sujeitos obteve escores na parte inferior da escala do que no topo. Alguns indivíduos mais fortes aumentaram a média realizando 30 ou mais mergulhos. Quando os dados da tabela 2.6 são plotados, como na figura 2.7, a protuberância ou moda da curva é empurrada para a esquerda e a cauda à direita é mais longa que a cauda à esquerda. A curva tem uma **assimetria positiva** porque a cauda longa aponta em uma direção positiva na abscissa.

Se a maioria dos sujeitos tiver uma pontuação alta num teste e apenas alguns se saírem mal, então a moda é para a direita e a cauda esquerda é mais longa que a cauda direita, como mostra a figura 2.8. Isso é chamado de **assimetria negativa** porque a cauda longa aponta na direção negativa da abscissa. O Capítulo 6 apresenta um método para calcular a quantidade de assimetria em um conjunto de dados. É bastante comum ver distribuições distorcidas quando os dados apresentam efeitos de teto ou de chão. Um **efeito teto** ocorre quando há um limite de quão altas os escores podem ser e os escores tendem a se agrupar em torno desse limite. Da mesma forma, um **efeito chão** pode ocorrer quando há um limite de quão baixos os escores podem chegar e os escores tendem a se agrupar em torno desse limite. Por exemplo, as notas em um curso de pós-graduação em estatística não podem ser superiores a 100% (supondo que não haja crédito extra), e esperaríamos que a maioria dos alunos obtivesse notas acima de 80% em um exame típico, mas (espera-se) apenas um pequeno número de alunos teria pontuação abaixo de 70%. Aqui podemos antecipar efeitos de teto, já que as pontuações tendem a se agrupar acima de 80% e produzir uma assimetria negativa nos dados.




Figura 2.8 Curva com assimetria negativa

### ***Outras Formas***

Outras formas de curva são possíveis, mas a maioria delas é relativamente rara. As **curvas retangulares** ocorrem quando a frequência de cada uma das pontuações no meio do conjunto de dados é a mesma. Uma curva em **forma de U** é o resultado de uma alta frequência de valores nos extremos da escala e uma baixa frequência no meio.

Uma **curva J** resulta quando a frequência é alta em um extremo da escala, diminui rapidamente e depois se achata e reduz para quase zero no outro extremo da escala. Esta curva é diferente de uma linha reta, em que a frequência diminui uniformemente de um extremo ao outro da escala. As curvas J podem ter direção positiva ou negativa, dependendo da orientação da cauda inferior da curva. Se a cauda apontar para a extremidade positiva do eixo X, a curva é positiva. As curvas J também podem ser invertidas.

### **Resumo**

O objetivo de organizar e exibir dados é produzir ordem e parcimônia a partir dos dados brutos. Depois de compreender os princípios explicados neste capítulo, você deverá usar um computador para organizar e exibir seus dados. Organizar e exibir dados é o primeiro passo em uma análise estatística. A organização dos dados exige que os apresentemos como uma distribuição de escores. Uma distribuição de ordem de classificação pode ser usada quando o tamanho da amostra é  $\leq 20$ . Quando o intervalo

é limitado a 20 valores ou menos, mas o número de escores é grande ( $N > 20$ ), uma distribuição de frequência simples é usada. Quando tanto o intervalo como o número de escores são grandes, os dados devem ser organizados numa distribuição de frequência agrupada.

Um gráfico apresenta uma imagem visual dos dados e revela tendências que podem não ser óbvias em uma tabela. A curva dos dados representados graficamente é especialmente significativa porque mostra como os dados são distribuídos. Muitas das variáveis medidas em cinesiologia são normalmente distribuídas. A curva normal possui características especiais que nos permitem fazer afirmações sobre a distribuição dos escores. O Capítulo 6 discute a curva normal com mais detalhes.

### **Atividades de recursos da web**

O recurso da web oferece uma variedade de atividades interativas para ajudá-lo a aprender e compreender as informações apresentadas no texto. Você encontrará mini palestras e atividades importantes e será capaz de resolver exemplos de problemas. Visite a página deste capítulo ou use este código para acessar as miniaulas do capítulo 2.



## CAPÍTULO 3

### PERCENTIS

*Quando os locutores de basquete relatam o desempenho de vários jogadores ou times, eles geralmente usam porcentagens em vez de dados brutos. Vemos as porcentagens de arremessos de certos jogadores comparadas em lances livres, arremessos de dois pontos e arremessos de três pontos. As porcentagens são utilizadas porque são comumente compreendidas e permitem comparações imediatas de dois ou mais jogadores.*

*Os dados brutos tornariam difícil dizer quem é o melhor arremessador de lance livre: o jogador A, que acertou 46 de 62 tentativas, ou o jogador B, que acertou 56 de 78. Mas quando os dados são convertidos em porcentagens (74% para o jogador A, 72% para o jogador B), comparações entre jogadores podem ser feitas facilmente. A mesma lógica matemática pode ser empregada convertendo dados brutos nos chamados percentis.*

Os percentis são uma das ferramentas estatísticas mais comuns em uso atualmente. Educadores e cientistas consideram os percentis úteis na interpretação de dados para o público leigo. Este capítulo apresenta métodos de cálculo manual de percentis. Embora os pesquisadores usem computadores para fazer cálculos em dados mais complicados ou em bancos de dados com grande número de pontuações, é melhor aprender os métodos usando dados simples e papel e lápis.

**Cent** é a raiz latina para cem. A palavra por cento significa por cem. Quando usamos porcentagens, estamos comparando um escore bruto com uma escala conceitual de 100 pontos. As porcentagens fornecem uma referência rápida para qualquer escore bruto em relação ao restante dos escores. Um percentil representa a fração (em centésimos) dos escores ordenados que são iguais ou inferiores a um determinado escore bruto. Nas estatísticas, um percentil é definido como um ponto ou posição em uma escala contínua de 100 divisões teóricas, de modo que uma certa fração da população de escores brutos fique nesse ponto ou abaixo dele.

Um escore no percentil 75 é igual ou ultrapassa três quartos dos outros escores no conjunto de dados brutos. O percentil 33 é igual ou melhor que cerca de um terço dos escores, mas é superado por dois terços dos escores. Um escore em percentil de um aluno em um teste indica como o escore do aluno se compara a um escore perfeito de 100%.

Percentis são escores padrão. Um **escore padrão** é um escore derivado de dados brutos e que possui uma base conhecida para comparação. Em porcentagens, o centro é 50% e o intervalo é de 0 a 100%. Um homem de meia idade pode consumir 40 mililitros de oxigênio por quilograma de peso corporal por minuto. Esta é um

escore bruto. Sem mais informações, o escore é difícil de avaliar. Mas se compararmos este valor com outros valores na população de todos os homens da mesma idade e calcularmos um escore percentual de 65, então sabemos que o consumo de oxigênio do homem é igual ou melhor do que o de 65% das pessoas nessa população. Os escores brutos são valores medidos. Escores padrão, que são derivados dos escores brutos, fornecem mais informações do que os escores brutos.

As escores padrão nos permitem (1) avaliar os escores brutas e (2) comparar dois conjuntos de dados baseados em diferentes unidades de medida. Qual é a melhor escore, 150 pés no arremesso de softball ou 30 abdominais em um minuto? Com apenas esta informação é impossível dizer. Devemos perguntar: qual foi o alcance? Qual foi a média?

Mas quando comparamos um escore percentil de 57 no arremesso de softball com um escore percentil de 35 no teste de abdominais, a resposta é clara. Não apenas os valores relativos dos escores são aparentes, mas também conhecemos o escore intermediário (50) e o intervalo (0–100). O aluno que recebeu essas notas é melhor no arremesso de softball do que nos abdominais quando comparado com os demais alunos da turma.

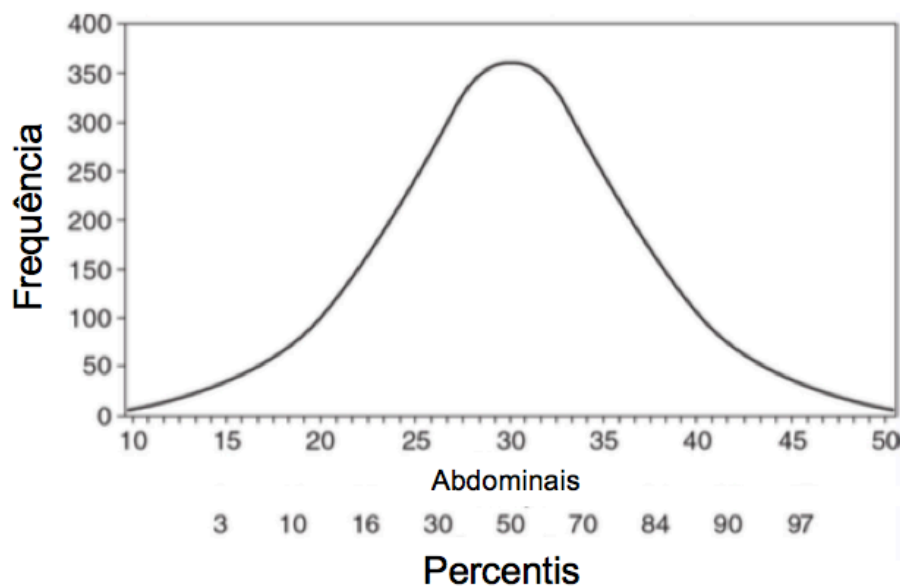
A conversão de escores brutos em escores padrão, das quais os percentis são apenas um exemplo, é uma técnica comum em estatística. É mais útil na avaliação de dados. (O Capítulo 6 discute outras pontuações padrão.)

Os percentis podem apresentar um problema de interpretação quando consideramos os extremos da escala para conjuntos de dados com grande número de pontuações. O problema resulta da imposição de uma escala percentil em dados de intervalo ou razão.

Por exemplo, a figura 3.1 mostra um gráfico do número de abdominais realizados em 1 minuto por 1.000 meninos da sétima série. Tanto o número de abdominais (escores brutos) quanto as divisões percentuais foram plotadas. Observe que um escore de 30 abdominais é igual ao percentil 50.

Se um menino fizer 30 abdominais no primeiro teste e aumentar seu escore bruto para 35 na segunda tentativa, seu escore percentual aumentaria de 50 para cerca de 75, ou 25 pontos percentuais. No entanto, se ele já estivesse no limite superior da escala e fizesse a mesma melhoria de 5 abdominais de 45 para 50, o seu percentil aumentaria apenas cerca de três pontos, de 97 para perto de 100. Este fenômeno é um exemplo de efeito teto.

Professores e treinadores devem levar isso em conta quando avaliam a melhoria. É muito mais fácil reduzir o tempo necessário para correr a corrida de 100 metros rasos de 12,0 segundos para 11,5 segundos do que reduzi-lo de 10,5 segundos para 10,0 segundos. Uma melhoria de 0,5 segundos por um corredor no nível mais alto de desempenho (ou seja, pontuações de tempo mais baixas) representa mais esforço e realização do que a mesma melhoria de tempo num corredor no meio da escala.



**Figure 3.1 Abdominais por minuto (N = 1.000).**

As curvas de aprendizado normalmente começam lentas, aceleram no meio e estabilizam à medida que nos aproximamos do desempenho de alto nível. O efeito teto é demonstrado pelo platô na curva. É mais difícil melhorar no topo da curva de aprendizagem do que no início ou no meio. Esta dificuldade de interpretação não deve impedir-nos de utilizar percentis, mas devemos reconhecer o efeito limite quando consideramos pontuações que representam níveis elevados de desempenho, especialmente se a melhoria for a base da avaliação.

### **Divisões Comuns do Percentis**

Todas as medições contêm algum erro. Quando o erro é relativamente grande, o escore verdadeiro do sujeito é apenas aproximado. Nestes casos, seria inapropriado relatar uma classificação em percentil exata porque o escore bruto é apenas uma estimativa do escore verdadeiro. Relatar uma série de escores ou



uma série de percentis dentro dos quais provavelmente se encontra o escore verdadeiro do sujeito é uma prática comum.

Os dois intervalos mais comuns de escores percentis são o intervalo quartil e o intervalo decil. Ocasionalmente, os escores são reportados em quintis. Na faixa quartil, a escala percentil é dividida em quatro partes iguais, ou quartis. O primeiro quartil vai de zero ao percentil 25 (Q1). O segundo quartil varia do Q1 ao percentil 50 (Q2). O terceiro quartil estende-se do Q2 ao percentil 75 (Q3). O quarto, ou mais alto, quartil vai do Q3 ao percentil 100 (Q4). Na faixa do quintil são feitas cinco divisões da escala percentil.

Os decis seguem o mesmo formato, exceto que a escala é dividida em 10 partes, cada uma com alcance de 10 pontos. O 1º decil varia de 0 a D1, o 2º decil de D1 a D2, e assim por diante; o 10º decil estende-se de D9 a D10 (o 100º percentil). A Figura 3.2 mostra as divisões quartil e decil da escala percentil.

Às vezes, os escores dos testes são relatados em classificações de quartil ou decil. Se um aluno estiver classificado no 3º quartil, o escore desse aluno ficará em algum lugar entre o 50º e o 75º percentis. Da mesma forma, uma classificação decil de 4 significa que o escore está entre o 30º e o 40º percentis. Este tipo de relatório é utilizado se o professor ou cientista tiver conhecimento de erros nos testes ou se o teste for tal que apenas uma estimativa do escore verdadeiro possa ser obtido. Baterias de testes que relatam escores em vários aspectos da habilidade de um aluno, de modo a formar um perfil, ou imagem total, dos talentos do aluno, são comumente relatadas em classificações de quartil ou decil.

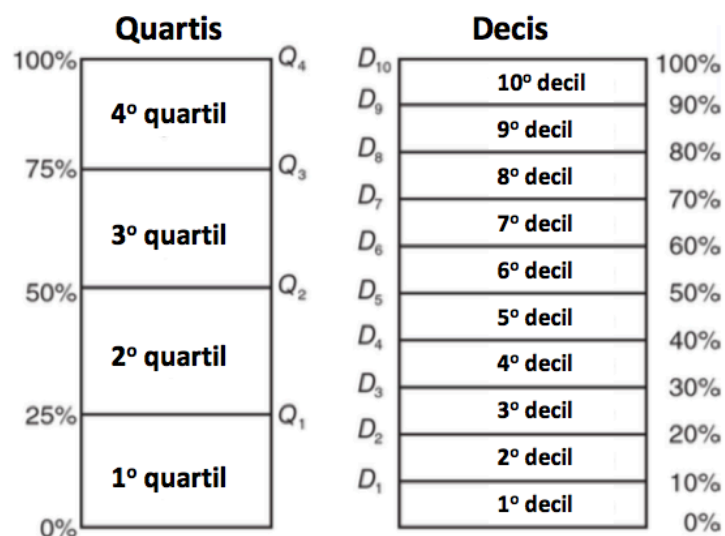


Figura 3.2 Relações entre percentis, quartis e decis

### Cálculos Usando Percentis

A conversão de escores brutos em percentis ou a determinação do escore bruto que representa um determinado percentil pode ser realizada usando dados ranqueados por ordem. Também precisamos ser capazes de aplicar esses processos a dados que foram organizados em distribuições de frequência simples e agrupadas. Nesta seção, discutiremos primeiro como executar esses processos com distribuições de ordem de classificação. Em seguida aplicamos os conceitos a distribuições de frequência simples e agrupadas.

### Distribuição Ranqueadas por Ordem

Um técnico de basquete fez com que 15 jogadores de um time do ensino médio completassem um teste de lance livre. Cada jogador deu 10 arremessos da linha de lance livre e o placar foi registrado. A Tabela 3.1 apresenta os dados em uma distribuição ordenada. Com

escores como estes num grupo tão pequeno, escores em percentis podem não ser significativos. O exemplo é apresentado aqui para demonstrar o conceito básico do cálculo do percentil.

**TABELA 3.1 Distribuição por Ordem de Ranque: Arremessos Livres de Basquete Convertidos em 10 Tentativas**

X
10
9
9
7
7
7
6
5
5
5
4
4
3
3
1

N = 15

*Determinando o Percentil a Partir de um Escore*

Qual é a classificação percentual para um escore bruto de 6 cestas? Lembre-se, um percentil é um escore em uma escala contínua de 100 divisões teóricas, de modo que uma certa fração da população de escores brutos esteja nesse escore ou abaixo dele. Para calcular

o percentil para um escore de 6 cestas, precisamos determinar qual fração dos escores fica igual ou inferior a 6 cestas.

Os percentis não se baseiam no valor de escores individuais, mas na ordem dos escores. Na tabela 3.1, o valor do escore mais baixo poderia ser alterado para 2 sem afetar as divisões percentuais porque ainda estaria na mesma ordem no grupo. A pergunta que devemos fazer é esta: quantos escores ficam iguais ou inferiores a 6 na lista ordenada de escores?

Contando a partir do escore de 6 para baixo, notamos que nove escores ficam iguais ou abaixo de 6. Há 15 escores, então a pessoa que marcou 6 cestas está a  $9/15$  do caminho da parte inferior da escala até o topo. Esta fração é primeiro convertida em decimal ( $9/15 = 0,60$ ) e, em seguida, o decimal é multiplicado por 100 para convertê-lo em porcentagem ( $0,60 \times 100 = 60\%$ ). Assim, uma pontuação de 6 neste teste que cai a 60% da parte inferior da escala para o topo e é classificada como o 60º percentil.

Qualquer escore único poderia ser convertido de maneira semelhante, mas vários escores foram obtidos por mais de uma pessoa. Por exemplo, três pessoas receberam, cada uma, um escore de 5. (Qual o ranque de percentil) ou (Qual é a sua classificação percentual?) Usando o método descrito anteriormente, poderíamos calcular que o primeiro escore de 5, o sexto escore de baixo para cima, representa o percentil 40 ( $6/15 = 0,40$ ;  $0,40 \times 100 = 40\%$ ). Mas o escore máximo de 5 está a oito escores da base e representa aproximadamente o percentil 53 ( $8/15 \times 100 = 53,3\%$ ).

Concluimos então que as pessoas que fizeram cinco cestas cada uma pontuaram entre o 40º e o 53º percentil? Não. Como definimos o percentil como uma fração igual ou inferior a um determinado escore concluimos que todos são iguais ou inferiores a

uma pontuação de 5. Como todos tiveram desempenhos iguais, todos deveriam receber o mesmo percentil, como uma fração dos escores em ou abaixo de um determinado escore. Portanto, todos os três têm um escore percentual de 53,3.

Para grandes conjuntos de dados, calcular valores percentuais individuais para cada escore bruto em uma distribuição é complicado e propenso a erros. No entanto, um software estatístico permite o cálculo de percentis a partir de grandes conjuntos de dados com rapidez e precisão.

#### *Determinando o Escore a Partir do Percentil*

O cálculo mais comum ao trabalhar com percentis é calcular o percentil a partir do escore bruto, mas às vezes é necessário o cálculo oposto. Se um treinador determinar que o percentil 60 é o ponto de corte em um teste para seleção de atletas para um time universitário, o técnico precisa saber qual escore bruto é representado pelo percentil 60.

Frequentemente, as notas ou divisões de turmas são feitas com base em percentis. Uma turma pode ser dividida em terços, com o terço superior recebendo um cronograma de prática, o terço intermediário outro e o terço inferior ainda outro. Para determinar quais alunos devem ser incluídos em cada grupo, devemos estabelecer os escores brutos equivalentes aos valores percentuais. A técnica para determinar o escore bruto que corresponde a um determinado valor percentual é o oposto daquele para encontrar o percentil a partir de um escore bruto.

Por exemplo, o técnico de basquete que coletou os dados de lances livres (ver tabela 3.1) pode levar os dois terços melhores do time para jogos fora de casa. Se o técnico usar o resultado do lance

livre como critério para determinar quem fará parte do elenco itinerante, quantas cestas um jogador deve fazer para se classificar?

O treinador deve perguntar: “Qual escore define o terço inferior da equipe?” Todos os jogadores com escore acima desse ponto estão entre os dois terços melhores e se classificam para o time itinerante. Este é um problema simples com 15 jogadores porque é fácil determinar que os 10 melhores jogadores representam os dois terços superiores da equipe. Mas ao pensar no processo com dados simples, aprendemos os conceitos que podem ser aplicados a dados mais difíceis.

O percentil equivalente a  $1/3$  é encontrado convertendo a fração para decimal ( $1/3 = 0,333$ ) e multiplicando esse equivalente decimal pelo número total de sujeitos do grupo ( $0,333 \times 15 = 5$ ). Este valor (5) é o número de escores de baixo para cima, não o valor bruto da pontuação de 5 cestas feitas.

Para determinar o escore bruto que é equivalente a um determinado percentil (P), converta o percentil em decimal, multiplique o decimal equivalente pelo número de escores no grupo (N) e conte esse número de escores de baixo para cima. Contando cinco escores de baixo para cima, descobrimos que um escore de 4 lances livres representa um escore percentual de 33,3. Qualquer jogador que tenha feito quatro ou menos lances livres é incluído no terço inferior do grupo, e qualquer jogador que marque mais de quatro lances livres está incluído nos dois terços superiores do grupo. Portanto, cinco lances livres é o critério para compor o elenco itinerante.

Com valores pequenos de N e dados discretos, pode ser necessário encontrar a pontuação mais próxima de um determinado percentil se nenhum dos escores brutos cair exatamente nesse

ponto. Se o produto de  $P \times N$  não for um número inteiro, arredonde para o número inteiro mais próximo para determinar a contagem de baixo para cima. Na tabela 3.1, o percentil 50 está a 7,5 escores do final ( $0,50 \times 15 = 7,5$ ), mas não há meio escores. Então, arredondamos 7,5 para 8 e contamos 8 escores de baixo para cima. O oitavo escore acima é 5. Portanto, 5 é o escore mais próximo do 50º percentil.

### **Distribuição de Frequência Simples**

Quando mais escores estão disponíveis, mas o intervalo ainda é pequeno ( $N \geq 20$  e  $R \leq 20$ ), os escores são geralmente agrupados em uma distribuição de frequência simples. Suponha que o técnico de basquete do exemplo anterior aplicasse o teste de lance livre a 60 alunos em uma aula de educação física. Os dados são apresentados numa distribuição de frequência simples na tabela 3.2.

**TABELA 3.2 Distribuição de Frequência Simples: Arremesso Livres de Basquete Completados em 10 tentativas**

x	f	Cum.f
10	2	60
9	6	58
8	9	52
7	12	43
6	15	31
5	8	16
4	4	8
3	2	4
2	1	2
1	1	1

### **Determinando o Percentil a Partir do Escore**

Qual é a classificação percentual de um aluno que fez sete cestas? Para responder a esta pergunta, precisamos calcular a fração de escores iguais ou inferiores a 7. Fazemos isso adicionando os números na coluna de frequência (f) de escores (X) de 7 até o final.

Se vários cálculos percentuais forem realizados, é útil criar uma coluna de frequência cumulativa. A coluna de frequência cumulativa na tabela 3.2 indica que 43 pessoas fizeram sete ou menos cestas. Sessenta pessoas fizeram o teste, então 43 dos 60 alunos acertaram sete ou menos cestas. Convertido em decimais,  $43/60 = 0,716$  e  $0,716 \times 100 = 71,6$ . Portanto, uma pessoa que marcou sete cestas é igual ou melhor que cerca de 72% daqueles que fizeram o teste.

### **Determinando o Score a Partir do Percentil**

Na tabela 3.2, qual escore equivale ao percentil 75? O conceito de determinar o escore equivalente a um determinado percentil a partir de uma distribuição de frequência simples é o mesmo que pela distribuição de ordem de classificação. Primeiro estabelecemos o número de lances livres igual ou inferior ao qual 75% do grupo marcou. Este valor é determinado da seguinte forma:  $0,75 \times 60 = 45$  alunos.

A coluna de frequência cumulativa indica que 43 alunos pontuaram sete ou menos e 52 alunos pontuaram oito ou menos. Os nove alunos que marcaram oito cestas cada representam o 44º ao 52º aluno na distribuição ordenada. Portanto, o 45º aluno é um desses nove. Não podemos separar os nove alunos, pois todos



tiveram o mesmo escore, portanto o percentil 75 é determinado como oito cestas. Como nove alunos empataram em oito cestas, os três quartos inferiores do grupo são aproximadamente aqueles que marcaram oito ou menos, e os quartos superiores do grupo são aproximadamente aqueles que marcaram nove ou mais.

Se o produto do percentil (P) em valor decimal vezes N não for um número inteiro, arredondaremos o produto para o número inteiro mais próximo e encontraremos esse valor na coluna de frequência cumulativa. Por exemplo, se o 14º percentil for desejado ( $0,14 \times 60 = 8,4$ ), encontraríamos onde 8 cai na coluna de frequência cumulativa e então leríamos 4 como o número de cestas mais próximas do 14º percentil.

### **Distribuição de Frequência Agrupada**

Os dados acumulados de um teste em que há uma grande amplitude<sup>10</sup> de escores ( $R > 20$ ) e muitas pessoas participaram ( $N > 20$ ) podem ser apresentados em uma distribuição de frequência agrupada. Como exemplo, consideramos os resultados de um teste de lançamento de softball para distância aplicado a 115 alunos. A Tabela 3.3 apresenta os dados brutos em uma distribuição de frequência agrupada.

---

<sup>10</sup> Uma amplitude de 20 é considerada pequena. Entretanto é uma avaliação subjetiva. Trinta também poder considerada pequena, assim como 10.

**TABELA 3.3 Distribuição de Frequência Agrupada: Distância do Arremesso de Softball, em pés**

x	f	f acumulada
220–229	2	115
210–219	5	113
200–209	7	108
190–199	7	101
180–189	9	94
170–179	12	85
160–169	10	73
150–159	15	63
140–149	7	48
130–139	9	41
120–129	10	32
110–119	7	22
100–109	6	15
90–99	5	9
80–89	4	4

N = 115

### **Determinando o Percentil a Partir do Escore**

Qual é a classificação percentual de um aluno que arremessou a bola de softball a 146 pés? Este problema é abordado da mesma maneira que o problema simples de distribuição de frequência, exceto que, como os dados estão agrupados, não sabemos onde está um determinado escore dentro de um intervalo.

A Tabela 3.3 indica que sete pessoas lançaram a bola entre 140 e 149 pés. Não sabemos quantas das sete pessoas atiraram

mais de 146 pés e quantas atiraram menos, por isso devemos assumir que todas as sete pessoas estão igualmente distribuídas entre os limites reais do intervalo (139,50–149,49). Limites reais são usados para que percentis para dados discretos e contínuos possam ser calculados.

Este problema agora é facilmente resolvido aplicando a seguinte equação:

$$P = \frac{\left(\frac{X-L}{i}\right)f+C}{N}, \quad (3.01)$$

onde **P** é o percentil, **X** é o escore bruto, **L** é o limite real inferior do intervalo em que o escore bruto cai, **i** é o tamanho do intervalo, **f** é a frequência do intervalo em que o escore bruto cai, **C** é a frequência cumulativa do intervalo imediatamente abaixo daquele em que cai o escore bruto, e **N** é o número total de casos.

Quando a equação 3.01 é aplicada à pontuação bruta de 146, são obtidos os seguintes resultados:

$$P = \frac{\left(\frac{146-139.5}{10}\right)7+41}{115} = .396 \text{ or } 39.6\%.$$

Portanto, um arremesso de 146 pés é aproximadamente igual ao 40º percentil.

#### *Determinando o Escore a Partir do Percentil*

Utilizando os dados da tabela 3.3, o professor pode desejar determinar o escore do meio, ou percentil 50. Quão longe um aluno

teria que lançar a bola de softbol<sup>11</sup> para ser considerado como estando na metade superior da turma? Para resolver este problema, devemos primeiro multiplicar  $P \times N$  para determinar o intervalo em que cai a pontuação. Com 115 alunos na turma, a pontuação que representa o percentil 50 cai exatamente na metade da coluna de frequência acumulada ( $0,50 \times 115 = 57,5$ ). Isso coloca a pontuação intermediária em algum lugar no intervalo de 150 a 159.

A Equação 3.01 pode ser resolvida algebricamente para  $X$ , para obter a seguinte equação:

$$(3.02) \quad X = \left( \frac{PN - C}{f} \right) i + L.$$

A notação simbólica é a mesma da equação 3.01. O problema discutido anteriormente agora é facilmente resolvido:

$$X = \left( \frac{(.5 \times 115) - 48}{15} \right) 10 + 149.5 = 155.83 \text{ feet}$$

O 50º percentil é aproximado a um arremesso de 156 pés.

---

<sup>11</sup> O softbol, do inglês softball, é uma modalidade esportiva muito semelhante ao beisebol. O softbol é uma modalidade olímpica, porém nas olimpíadas e disputada apenas pelas mulheres.

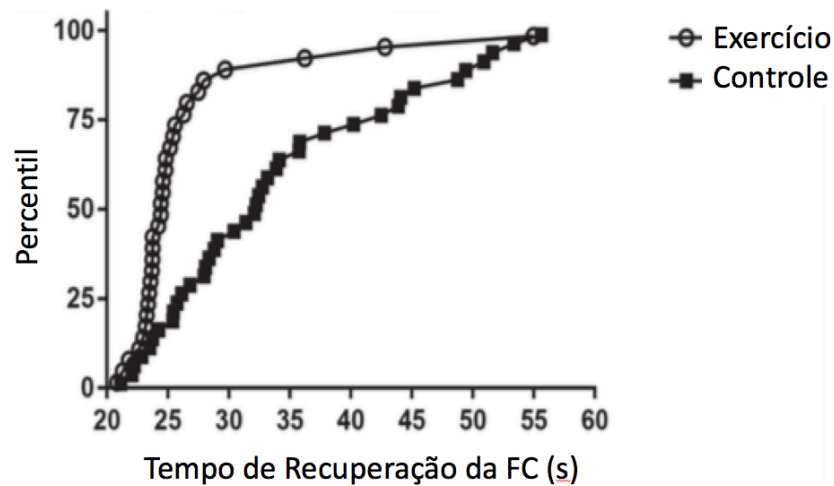


Figura 3.3 Gráfico de percentis para dois grupos amostrais.

*Exibindo Percentis Graficamente de percentis*

Muitas vezes é útil exibir dados em percentis em formato gráfico, especialmente ao comparar grupos diferentes. A Figura 3.3 mostra um gráfico de percentis a partir de dados fabricados de um estudo imaginário comparando dois grupos, praticantes regulares de exercícios versus controles, sobre o tempo necessário para que a frequência cardíaca retorne à linha de base após uma sessão de exercício padrão. Em um gráfico de percentil, um escore observado é plotada em relação ao valor do percentil desse escore. Na figura 3.3, cada ponto nas curvas reflete o escore de um participante na recuperação da frequência cardíaca (eixo X) e o respectivo valor percentil para esse valor de recuperação da frequência cardíaca. Observe que no grupo de exercício, o percentil 50 ocorre em um tempo de recuperação da frequência cardíaca de cerca de 25 segundos, mas para os controles o percentil 50 ocorre em torno de 32 segundos. O gráfico de percentis mostra bem que as formas das

distribuições para os grupos de exercício e controle diferem, e isso é visível quando se traçam gráficos das curvas de percentis.

### **Resumo**

A conversão de escores brutos em escores padrão é uma técnica comum em estatística. Os escores padrão nos permitem avaliar os escores brutos e comparar dois conjuntos de dados baseados em diferentes unidades de medida. Por causa disso, os escores padrão fornecem informações sobre dados que não estão disponíveis nos escores brutos apenas. Os escores padrão mais comuns, escores percentuais, são frequentemente usados em cinesiologia. Os escores percentuais podem ser determinados a partir de dados ordenados em ranque (ou classificados em ordem), dados de frequência simples e dados agrupados. Os percentis também podem ser facilmente convertidos em escores brutos.

### **Recurso de Atividades na Web**

O recurso da web oferece uma variedade de atividades interativas para ajudá-lo a aprender e compreender as informações apresentadas no texto. Você encontrará mini palestras e atividades importantes e será capaz de resolver exemplos de problemas. Visite a página deste capítulo ou use este código para acessar as miniaulas do capítulo 3.



## CAPÍTULO 4

# MEDIDAS DE TENDÊNCIA CENTRAL

Nas Olimpíadas, o público normalmente está interessado apenas nos escores dos atletas que ficaram em primeiro, segundo e terceiro lugar em cada evento. No entanto, os cientistas que estudam o desempenho atlético querem (1) saber o valor relativo dos escores dos atletas que não estão entre os três primeiros, (2) descobrir tendências nos dados ao longo dos anos e (3) comparar o desempenho moderno com o antigo. Esses cientistas precisam saber o escore médio (média), a mediana (percentil 50, ou pontuação mais típica) e a moda (pontuação mais comum) para todos os atletas em todos os eventos. Quando estas três medidas de tendência central são conhecidas, é mais fácil interpretar o valor de um único escore comparando-o com a média, mediana ou moda.

**Medidas de tendência central** são valores que descrevem as características intermediárias ou centrais de um conjunto de dados. Alguns termos que podem ser usados para descrever o centro de um grupo de pontuações são a **pontuação mais comum (moda)**, a **pontuação típica (mediana)** e a **pontuação média (média)**. Estas medidas fornecem informações importantes que nos permitem calcular a relação de um determinado escore com os escores médios de um conjunto de dados.

### Moda

A **moda** é o escore que ocorre com mais frequência. Não existe fórmula para calculá-lo; é encontrado por inspeção ou por um programa de computador. Em uma lista de escores por ordem de classificação, a moda pode ser determinada examinando a lista de todas os escores para determinar qual é o mais frequente. Em uma distribuição de frequência simples ou agrupada, o escore com maior valor na coluna de **frequência** é a moda.

Numa distribuição de frequência simples, a moda é o escore com maior frequência, mas numa distribuição de frequência agrupada, a moda é considerada o ponto médio do grupo com maior frequência. É claro que uma distribuição pode ter mais de uma moda. Se dois ou mais escores ou grupos têm a mesma frequência, então a variável é considerada **bi ou multimodal**.

A facilidade com que pode ser determinado é uma vantagem da moda. Fornece uma estimativa rápida do centro do grupo e, quando a distribuição é normal ou quase normal, esta estimativa é uma descrição justa da tendência central dos dados.

A moda também tem algumas desvantagens:



- É instável; isso pode mudar dependendo dos métodos usados para agrupamento.
- É uma estatística terminal; isto é, não fornece informações que possam ser usadas para cálculos adicionais.
- Desconsidera completamente os escores extremos – não reflete quantos existem, os seus valores ou a que distância estão do centro do grupo.

### **Mediana**

A **mediana** é o escore associado ao percentil 50. Pode ser determinado utilizando os métodos de cálculo de percentis apresentados no capítulo 3. Neste capítulo, discutimos a importância da mediana como medida de tendência central.

A mediana é o escore intermediária, pois ocorre no meio da lista de escores; ele divide o conjunto de dados pela metade. A mediana também é o escore típico porque é o escore único que melhor representa a maioria dos outros valores.

Em uma distribuição por ordem de classificação, quando  $N$  é ímpar, a mediana é o escore intermediário no intervalo. Quando  $N$  é par, a mediana fica entre dois escores.

Considere estes dois exemplos:

<b>A</b>		<b>B</b>
9		19
8		18
6	← mediana	17
4		← mediana
1		16
		13
		12

No exemplo A, a mediana é 6, o escore intermediário. No exemplo B, nenhum escore representa o meio exato. Quando N é par e a mediana fica entre dois escores, o escore mais alto é geralmente designado como mediana. No entanto, os programas de computador calcularão frequentemente a média dos dois escores médios como mediana. No exemplo B, escolher o escore mais alto resultaria em uma mediana de 17, e calcular a média dos dois escores intermediários resultaria em uma mediana de 16,5.

O cálculo da mediana não leva em consideração o valor de qualquer das notas. Baseia-se apenas no número de escores e na sua ordem de classificação. Por esta razão, a mediana é usada apropriadamente em dados ordinais e em dados altamente distorcidos.

Um escore extremo que seja radicalmente diferente dos outros escores no conjunto de dados não afeta a mediana. Considere o seguinte exemplo. Nove pessoas realizam 40 abdominais cada e uma faz 100. A mediana do grupo é 40, mas a média é 46. A mediana ainda seria 40, mesmo que a pontuação mais alta fosse 200. É fácil ver por que a mediana é chamada de típica do grupo. A mediana é

mais representativa da maioria dos escores do que a média quando existem escores radicalmente extremos.

O fato de a mediana não ser afetada pelo tamanho dos escores extremos é uma vantagem e uma desvantagem. Como a mediana não considera o tamanho dos escores, mas apenas quantos existem, negligencia algumas informações importantes fornecidas pelos dados – nomeadamente, o valor dos escores extremos.

### **Média**

A média é o nome estatístico da média aritmética. É representado por um ponto em escala contínua e pode ser expresso como um valor inteiro ou decimal. A média é a medida de tendência central mais comumente usada. Seu cálculo considera tanto o número de pontuações quanto seus valores.

Devido a esta característica, a média é a mais sensível de todas as medidas centrais. Pequenas alterações em qualquer uma das pontuações do grupo podem não afetar a moda ou a mediana, mas sempre alteram a média. A principal vantagem da média é que ela considera todas as informações sobre os dados e fornece uma base para muitos cálculos adicionais que produzirão ainda mais informações.

Estas características tornam-na a medida de tendência central mais apropriada para dados de razão e intervalo. Muitos argumentam que não é adequado calcular a média em dados ordinais porque as distâncias entre os escores não são conhecidos em dados ordinais. A mediana seria mais adequada neste caso. O cálculo da média requer mais informações do que as fornecidas pelos dados ordinais, enquanto a mediana considera exatamente o tipo de informação

fornecida pelos dados ordinais – ordem das pontuações, mas não a distância relativa entre as pontuações.

A sensibilidade da média também pode ser uma desvantagem. Quando uma ou mais pontuações, chamadas de **outliers**<sup>12</sup>, são consideravelmente mais altas ou mais baixas que as outras pontuações, a média é puxada para esse extremo. O exemplo anterior do número médio de abdominais por 10 sujeitos ilustra esse fenômeno.

**A precisão da média não deve exceder a precisão dos dados em mais de uma casa decimal.** Por exemplo, se a distância for medida em metros, é apropriado calcular a média até o décimo de metro ou decímetro mais próximo, mas não até o milésimo de metro ou milímetro mais próximo. A convenção permite que a precisão da média seja um algarismo significativo além da precisão dos dados.

### Calculando a média

A média é calculada simplesmente somando todas as pontuações e dividindo a soma pelo número de pontuações (N). Na estatística, a soma das pontuações é representada pelo sigma grego maiúsculo ( $\Sigma$ ). Este símbolo é lido como “a soma de”. Por exemplo, se uma variável for rotulada como X, então  $\Sigma X$  deve ser lido como “a soma de X”.

Para denotar a média de uma variável, colocamos uma linha sobre o símbolo da variável. Na equação 4.01, X é o símbolo da variável, então a média de X é representada por  $\bar{x}$ , muitas vezes lida

---

<sup>12</sup> Outlier (termo em inglês) pode ser entendido como um valor aberrante, ou valor atípico, é uma observação que apresenta um grande afastamento das demais da série observada. Também referido como um ponto fora da curva.

como  $\bar{X}$ . Se  $Y$  representa a variável,  $\bar{Y}$ , ou  $Y$ -barra, representa a média de  $Y$ .

A fórmula para a média da variável  $X$  é

$$\bar{X} = \frac{\sum X}{N}. \quad (4.01)$$

**\xba**

### **De uma distribuição por ordem de classificação**

Calcular a média de um pequeno conjunto de escores é fácil: some todas os escores e divida a soma pelo número de escores. A Tabela 4.1 mostra um exemplo de tempos de corrida (fabricados) de 200 metros (em segundos).

O valor que a calculadora retorna para  $194,4/7$  é  $27,77142857$  segundos. Mas os dados são significativos apenas até o décimo mais próximo, então o valor médio é calculado até o centésimo mais próximo. Arredondar a média para um algarismo significativo além dos dados mostra que a média está mais próxima de  $27,8$  segundos do que de  $27,7$  segundos, então podemos dizer que  $\bar{x} = \sim 27,77$  segundos (a média de  $X$  é de aproximadamente  $27,77$  segundos).

Embora um pesquisador deva conhecer as técnicas para calcular a média manualmente, o processo é muitas vezes tedioso e demorado. Os computadores executam essas funções com muito mais rapidez e precisão. Os computadores também podem lembrar grandes quantidades de informações, portanto não é necessário que um computador agrupe os dados. Como os computadores são comumente usados para calcular a média, este capítulo não demonstrará os métodos de cálculo manual para distribuições de frequência simples e agrupadas. Quando se sabe fazer cálculos

manualmente com números simples para pequenos valores de N e entende o significado das respostas, o computador pode adicionar velocidade, precisão e conveniência.

**TABELA 4.1 Amostra de tempos de corrida de 200 metros**

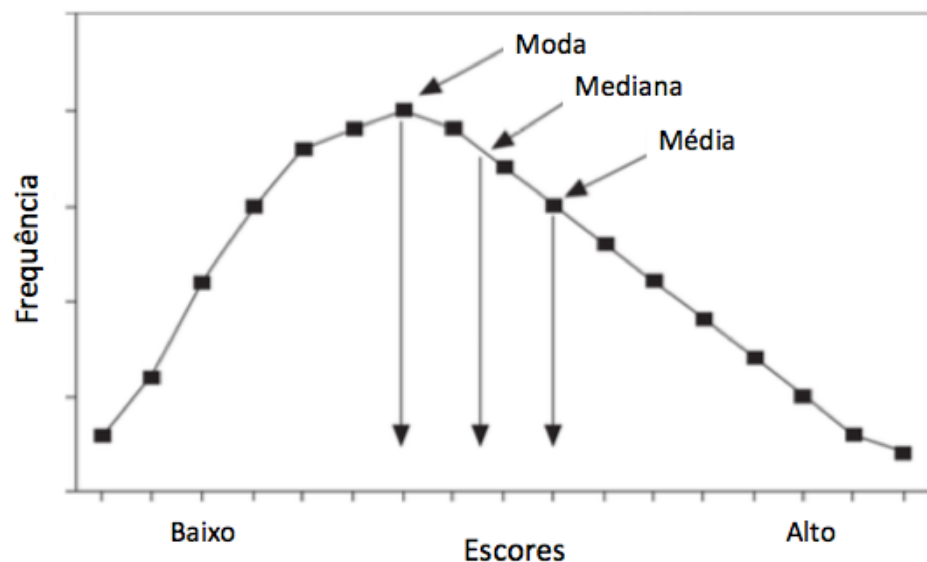
X (s)
33,9
31,2
29,6
27,0
24,7
25,0
23,0
$\Sigma_x = 194,4$
$\bar{X} = \frac{\Sigma X}{N} = 194,4/7 = 27,77$

Quando os dados são normalmente distribuídos, todas as três medidas de tendência central caem no mesmo valor ou próximo dele. Entretanto, quando os dados são assimétricos, estas medidas já não são idênticas. A Figura 4.1 demonstra as relações entre as três medidas numa distribuição positivamente assimétrica.

Observe que os escores mais altos estão mais distantes da moda do que os escores mais baixos. Esta característica de curvas positivamente assimétricas desloca a mediana e a média para a direita da moda. Numa curva positivamente assimétrica, as três medidas de tendência central são lidas da esquerda para a direita na seguinte ordem: moda, mediana, média. Numa curva negativamente assimétrica a ordem é invertida: média, mediana, moda.

Ao decidir qual das três medidas usar, considere o seguinte:

- Utilize a moda se for necessária apenas uma estimativa aproximada da tendência central e os dados forem normais ou quase normais.
- Utilize a mediana se (1) os dados estiverem numa escala ordinal, (2) for necessária a pontuação média do grupo, (3) for necessário o escore mais típico ou (4) a curva estiver muito assimétrica por escores extremos.
- Use a média se (1) a curva estiver próxima do normal e os dados forem do tipo intervalar ou razão, (2) todas as informações disponíveis dos dados devem ser consideradas (ou seja, a ordem dos escores, bem como seus valores relativos), ou (3) cálculos adicionais, como desvios padrão ou escores padrão, devem ser feitos.



Figur4 4.1 Relações das medidas de tendência central numa curva assimétrica positivamente.

## Logarithmic Transformations and the Geometric

### Mean

Os dados em estudos de cinesiologia podem ser assimétricos. Sob certas condições, é um procedimento comum transformar os dados (ou seja, aplicar uma operação matemática a cada um dos escores brutos). Por exemplo, se os dados forem positivamente assimétricos (ver figura 2.7), os investigadores podem optar por transformar os dados utilizando uma transformação logarítmica (log). Se os dados exibirem o que é chamado de distribuição logarítmica normal, os dados transformados exibirão uma distribuição normal (ver capítulo 6). Nos Estados Unidos da América, a transformação logarítmica na base 10 é comumente usada, enquanto em outros países a transformação logarítmica natural (base e) pode ser mais comum. Os dados transformados podem então ser usados em cálculos estatísticos adicionais, como os discutidos a partir do capítulo 7. Por enquanto, observe que podemos calcular a média aritmética das pontuações transformadas. A Tabela 4.2 mostra os dados transformados na base 10 e no log natural (ln) da tabela 4.1, bem como a soma e a média dos valores. Para minimizar o efeito de erros de arredondamento, realizamos a transformação logarítmica dos valores com três casas decimais.

Os escores transformados em log e suas médias são mais difíceis de interpretar do que os escores não transformados, uma vez que nos não transformados os escores não estão mais em unidades da medida original, neste caso, segundos. No entanto, podemos



pegar o antilogaritmo (antilog)<sup>13</sup> da média dos escores transformados em log para obter um valor médio de volta às unidades originais. Para os dados transformados em log de base 10, o antilog da média de 1,440 é de cerca de 27,5 segundos. Para os dados transformados em logaritmo natural, o antilog de 3,316 é de cerca de 27,5 segundos. Observe que ambos os valores equivalem a 27,5 segundos. Esta é uma propriedade matemática e não uma coincidência; portanto, a escolha da base 10 ou da transformação logarítmica natural é arbitrária.

**TABELA 4.2** Dados de Log na base 10 e Log Natural Log da Tabela 4.1

<b>X (s)</b>	<b>Log<sub>10</sub> x</b>	<b>Log<sub>e</sub> x (ln x)</b>
33,9	1,530	3,523
31,2	1,494	3,440
29,6	1,471	3,388
27,0	1,431	3,296
24,7	1,393	3,207
25,0	1,398	3,219
23,0	1,362	3,135
$\Sigma_X = 194,4$	$\Sigma_X = 10,079$	$\Sigma_X = 23,208$
$\bar{x} = 27,8$	$\bar{x} = 1,440$	$\bar{x} = 3,316$

O antilog da média dos escores transformados em log é equivalente ao que é chamado de média geométrica. A média geométrica também pode ser calculada diretamente como a enésima raiz do produto de n escores (onde n = o número de escores).

<sup>13</sup> O antilog é o inverso do log. É possível utilizar o antilog para calcular os valores originais de dados que foram anteriormente transformados com um log.

A fórmula para a média geométrica é

$$\sqrt[n]{\prod X_i}$$

(4.02)

onde o símbolo  $\prod$  é uma operação matemática para multiplicar todos os números da lista. Ou seja, para calcular diretamente a média geométrica, calcule o produto de todas os escores e, em seguida, eleve esse produto à potência  $1/n$ . Para ilustrar, para os dados da tabela 4.2, o produto dos sete escores =  $33,9 \times 31,2 \times 29,6 \times 27,0 \times 24,7 \times 25,0 \times 23,0 = 12.005.342.799,84$ . É evidente que estes cálculos podem resultar rapidamente em números muito grandes e devem ser feitos utilizando um computador. O próximo passo é levar o produto à potência  $1/n$ , que neste caso é  $12.005.342.799,84^{1/7}$  ou  $\sim 27,5$  segundos. Compare isto com o antilogaritmo das médias transformadas na tabela 4.2.

### Resumo

Medidas de tendência central são valores que descrevem as características centrais de um conjunto de dados. É essencial conhecer a tendência central de um conjunto de escores para avaliar qualquer um dos escores brutos do conjunto. As três medidas típicas de tendência central são a moda, a mediana e a média. O moda fornece uma estimativa rápida da tendência central para todos os tipos de dados. A mediana pode ser usada em dados ordinais ou quando os dados estão muito distorcidos (assimétrico). A média é a medida de tendência central preferida para dados nas escalas intervalar ou razão que são distribuídos normalmente ou quase normalmente. Quando os dados são distribuídos normalmente, todas

as três medidas de tendência central caem no mesmo valor ou próximo dele. Quando os dados são assimétricos, muitas vezes são transformados. Se os dados forem log normais, uma transformação logarítmica é comumente empregada. O antilogaritmo da média dos escores transformados em log é a média geométrica.

#### **Atividades de recursos da web**

O recurso da web oferece uma variedade de atividades interativas para ajudá-lo a aprender e compreender as informações apresentadas no texto. Você encontrará mini palestras e atividades importantes e será capaz de resolver exemplos de problemas. Visite a página deste capítulo ou use este código para acessar as miniaulas do capítulo 4.

