

O'REILLY®

TURING

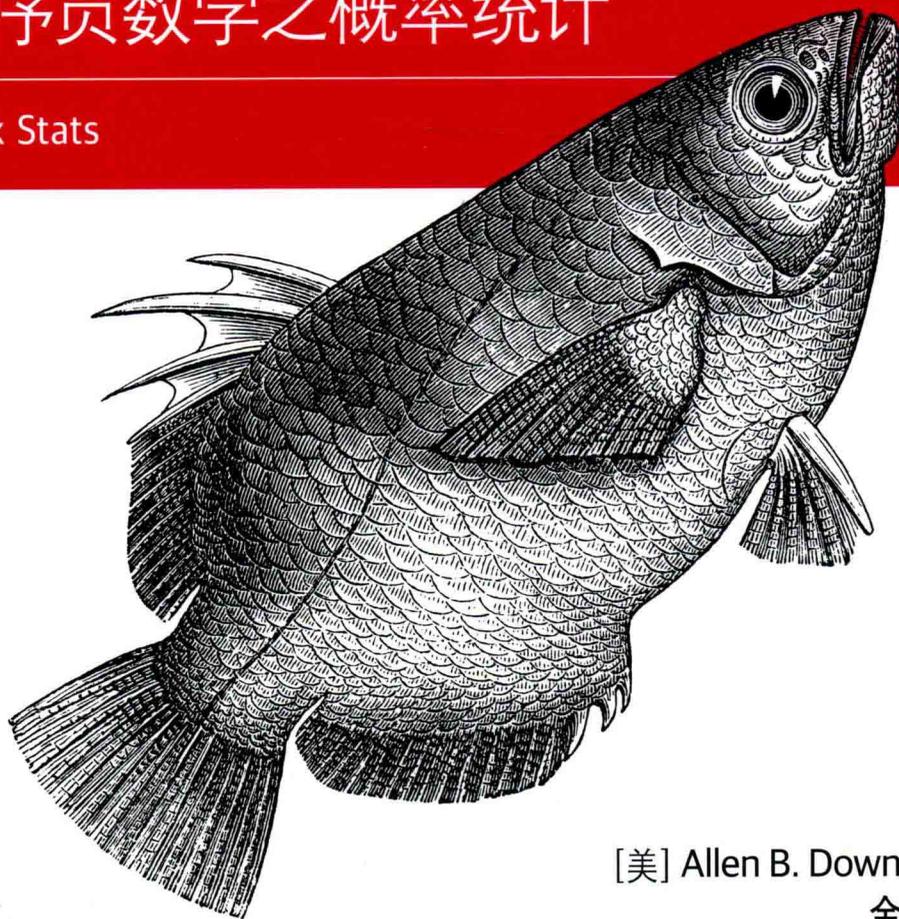
图灵程序设计丛书

第2版

统计思维

程序员数学之概率统计

Think Stats



[美] Allen B. Downey 著
金迎 译



中国工信出版集团



人民邮电出版社
POSTS & TELECOM PRESS

TURING

图灵程序设计丛书

统计思维

程序员数学之概率统计（第2版）

Think Stats
Second Edition

[美] Allen B. Downey 著
金迎 译

O'REILLY®

Beijing • Cambridge • Farnham • Köln • Sebastopol • Tokyo

O'Reilly Media, Inc. 授权人民邮电出版社出版

人民邮电出版社
北 京

图书在版编目 (C I P) 数据

统计思维：程序员数学之概率统计：第2版 / (美)
唐尼 (Downey, A. B.) 著；金迎译. -- 2版. -- 北京：
人民邮电出版社，2015.9
(图灵程序设计丛书)
ISBN 978-7-115-40108-3

I. ①统… II. ①唐… ②金… III. ①概率统计
IV. ①O211

中国版本图书馆CIP数据核字(2015)第176735号

内 容 提 要

这是一本以全新视角讲解概率统计的入门书。抛开经典的数学分析，Downey 手把手教你用编程理解统计学。具体说来，本书通过一个案例研究，介绍探索性数据分析的全过程：从收集数据、生成统计信息，到发现模式、验证假设。同时研究分布、概率规则、可视化和其他多种工具及概念。此外，第2版新增了回归、时间序列分析、生存分析和分析方法等章节。

本书既适合作为教材，又适合作为程序员学习概率统计的参考书，也适合作为非程序员了解概率统计与编程的工具书。

-
- ◆ 著 [美] Allen B. Downey
 - 译 金 迎
 - 责任编辑 岳新欣
 - 执行编辑 张 庆
 - 责任印制 杨林杰

 - ◆ 人民邮电出版社出版发行 北京市丰台区成寿寺路11号
 - 邮编 100164 电子邮件 315@ptpress.com.cn
 - 网址 <http://www.ptpress.com.cn>
 - 北京鑫正大印刷有限公司印刷

 - ◆ 开本：800×1000 1/16
 - 印张：12.75
 - 字数：302千字 2015年9月第2版
 - 印数：9001-13 000册 2015年9月北京第1次印刷
 - 著作权合同登记号 图字：01-2015-2497号
-

定价：49.00元

读者服务热线：(010)51095186转600 印装质量热线：(010)81055316

反盗版热线：(010)81055315

广告经营许可证：京崇工商广字第 0021 号

版权声明

© 2015 by Allen B. Downey.

Simplified Chinese Edition, jointly published by O'Reilly Media, Inc. and Posts & Telecom Press, 2015. Authorized translation of the English edition, 2015 O'Reilly Media, Inc., the owner of all rights to publish and sell the same.

All rights reserved including the rights of reproduction in whole or in part in any form.

英文原版由 O'Reilly Media, Inc. 出版，2014。

简体中文版由人民邮电出版社出版，2015。英文原版的翻译得到 O'Reilly Media, Inc. 的授权。此简体中文版的出版和销售得到出版权和销售权的所有者——O'Reilly Media, Inc. 的许可。

版权所有，未得书面许可，本书的任何部分和全部不得以任何形式重制。

O'Reilly Media, Inc.介绍

O'Reilly Media 通过图书、杂志、在线服务、调查研究和会议等方式传播创新知识。自 1978 年开始，O'Reilly 一直都是前沿发展的见证者和推动者。超级极客们正在开创着未来，而我们关注真正重要的技术趋势——通过放大那些“细微的信号”来刺激社会对新科技的应用。作为技术社区中活跃的参与者，O'Reilly 的发展充满了对创新的倡导、创造和发扬光大。

O'Reilly 为软件开发人员带来革命性的“动物书”；创建第一个商业网站（GNN）；组织了影响深远的开放源代码峰会，以至于开源软件运动以此命名；创立了 Make 杂志，从而成为 DIY 革命的主要先锋；公司一如既往地通过多种形式缔结信息与人的纽带。O'Reilly 的会议和峰会集聚了众多超级极客和高瞻远瞩的商业领袖，共同描绘出开创新产业的革命性思想。作为技术人士获取信息的选择，O'Reilly 现在还将先锋专家的知识传递给普通的计算机用户。无论是通过书籍出版、在线服务或者面授课程，每一项 O'Reilly 的产品都反映了公司不可动摇的理念——信息是激发创新的力量。

业界评论

“O'Reilly Radar 博客有口皆碑。”

——*Wired*

“O'Reilly 凭借一系列（真希望当初我也想到了）非凡想法建立了数百万美元的业务。”

——*Business 2.0*

“O'Reilly Conference 是聚集关键思想领袖的绝对典范。”

——*CRN*

“一本 O'Reilly 的书就代表一个有用、有前途、需要学习的主题。”

——*Irish Times*

“Tim 是位特立独行的商人，他不光放眼于最长远、最广阔视野，并且切实地按照 Yogi Berra 的建议去做了：‘如果你在路上遇到岔路口，走小路（岔路）。’回顾过去，Tim 似乎每一次都选择了小路，而且有几次都是一闪即逝的机会，尽管大路也不错。”

——*Linux Journal*

前言

本书介绍探索性数据分析的实用工具，书中章节按照我自己处理数据集时遵循的步骤进行组织。

- 导入和清洗：无论数据格式如何，我们通常都需要花费一些时间和精力进行数据的读取、清洗和变换，并进行检查，以确保在此过程中信息完好无损。
- 单变量探索：通常情况下，我会首先逐个检查变量，弄清变量的意义，分析变量值的分布，选择合适的汇总统计量。
- 成对探索：为了发现变量之间的关系，我会分析表格和散点图，计算相关性并进行线性拟合。
- 多变量分析：如果变量之间存在明显关系，我就要使用多元回归以增加控制变量，从而研究更复杂的关联关系。
- 估计和假设检验：在汇报统计结果时，有 3 个重要问题需要回答。效应规模如何？再次运行同一测量时，预期的变化性有多大？这个明显的效应是否可能是偶然产生的？
- 可视化：在数据探索中，可视化是寻找可能关系和效应的一个重要工具。如果一个明显的效应是统计显著的，那么可视化可以帮助我们有效地展示结果。

本书采用的是计算方法。相比数学方法，计算方法具有如下优点。

- 大多数概念用 Python 代码进行展示，而非数学符号。总体而言，Python 代码的可读性更好，而且这些代码是可执行的，读者可以下载、运行并进行修改。
- 每一章都附有练习，可以帮助读者扩展并巩固知识。编写程序时，你把自己对知识的理解表达为代码；调试代码时，这些理解也可以得到修正。
- 一些练习使用了实验检验统计行为。例如，你可以通过生成随机样本并计算它们的总和来探索中心极限定理（Central Limit Theorem, CLT）。练习得到的可视化结果展示了 CLT 的工作原理及适用条件。

- 一些概念很难从数学角度进行理解，却很容易通过模拟掌握。例如，通过运行随机模拟对 p 值进行近似，可以增强我们对 p 值含义的理解。
- 由于本书使用通用编程语言（Python），因此读者几乎可以从任何数据源导入数据，而不必受限于使用特定统计工具进行了清洗和格式化的数据集。

本书使用基于项目的方法。在我的课堂上，学生需要完成一个为期一个学期的项目。在项目中，学生要提出一个统计问题，寻找可以解决这个问题数据集，并将学到的各种技术应用到这个数据集。

为了展示我采用的统计分析方法，本书将介绍一个贯穿各章的案例。这个案例使用的数据来自以下两方面资源。

- 全国家庭增长调查（National Survey of Family Growth, NSFG），这一调查由美国疾病控制和预防中心（Center for Disease Control and Prevention, CDC）开展，以收集“与家庭生活、婚姻状况、妊娠情况、生育情况、避孕情况，以及两性健康相关的信息”。参见 <http://cdc.gov/nchs/nsfg.htm>。
- 行为危险因素监测系统（Behavioral Risk Factor Surveillance System, BRFSS），由国家慢性病预防和健康促进中心（National Center for Chronic Disease Prevention and Health Promotion）主持，以“跟踪美国的健康状况及风险行为”。参见 <http://cdc.gov/BRFSS/>。

其他示例使用的数据来自美国国税局（IRS）、美国人口普查（U.S. Census）及波士顿马拉松赛（Boston Marathon）。

《统计思维》的第2版包含了第1版的各章，但对其中很多内容进行了大幅修改，并新增了关于回归、时间序列分析、生存分析和分析方法的章节。本书第1版没有使用 pandas、SciPy 和 StatsModels，所以这些内容也都是新增的。

写作思路

人们在编写新教材时，通常会参考已有教材。这样做的结果就是，大部分图书都采用相似的结构顺序叙述相似的内容。

我没有这样做。实际上，在撰写本书时出于以下几点考虑，我几乎没有使用任何纸质资料。

- 我的目的是探索新方法，因此不想过多介绍已有方法。
- 既然本书的授权是免费的，那么我希望书中所有的内容都不受版权限制。
- 我的很多读者都无法到提供纸质资料的图书馆去，因此我尽量引用互联网上的免费资源。

- 一些传统媒体的支持者认为，只使用电子资料是偷懒且不可靠的做法。关于偷懒，他们可能说对了，但是我不认为电子资料不可靠，因此希望对自己的理论进行验证。

我使用最多的资源是维基百科（Wikipedia）。总的来说，我在维基百科上读到的统计资料都很不错（但是我在后续也做了一些小的改动）。本书多处引用了维基百科页面，希望你能通过提供的链接阅读这些资料。很多时候，维基百科页面是本书内容的补充。除去我认为必要的修改，书中使用的术语和符号与维基百科基本一致。另外两个我觉得有用的资源是 Wolfram Mathworld 和 Reddit 统计论坛（<http://www.reddit.com/r/statistics>）。

本书代码

本书使用的代码和数据都可从 GitHub（<https://github.com/AllenDoweny/ThinkStats2>）下载。Git 是一个版本管理系统，可以对项目文件进行跟踪。受 Git 管理的文件集称为代码库（repository）。GitHub 是一项托管服务，可以存储 Git 代码库，并提供一个便于使用的 Web 接口。

我的 GitHub 主页提供以下几种使用代码的方法。

- 你可以点击 Fork 按钮，在 GitHub 上创建该代码库的副本。如果你还没有 GitHub 账号，就需要创建一个。创建副本之后，你就在 GitHub 上拥有了自己的代码库，可以跟踪学习本书时编写的代码。之后你可以复制这个代码库，即将文件复制到自己的计算机上。
- 或者，你也可以复制我的代码库。这一操作不需要 GitHub 账号，但是你对代码所做的修改无法写回 GitHub。
- 如果你完全不想使用 Git，那么可以点击 GitHub 页面右下角的按钮，下载文件的 Zip 包。

本书所有代码都无需翻译即可在 Python 2 和 Python 3 中直接运行。

编写本书代码时，我使用的是 Continuum Analytics 的 Anaconda，这是一个免费的 Python 版本，其中带有运行本书代码所需的所有软件包（还有很多其他包）。Anaconda 很容易安装。默认情况下，Anaconda 进行用户级而非系统级安装，因此不需要管理员权限。Anaconda 同时支持 Python 2 和 Python 3，你可以从 Continuum（<http://continuum.io/downloads>）进行下载。

如果你不想使用 Anaconda，那么需要安装以下软件包。

- pandas，进行数据的表示和分析。下载地址为：<http://pandas.pydata.org/>。
- NumPy，支持基本的数字运算。下载地址为：<http://www.numpy.org/>。

- SciPy, 进行科学计算, 包括统计运算。下载地址为: <http://www.scipy.org/>。
- StatsModels, 进行回归分析和其他统计分析。下载地址为: <http://statsmodels.sourceforge.net/>。
- matplotlib, 支持可视化。下载地址为: <http://matplotlib.org/>。

虽然这些都是常用软件包, 但并不是所有的 Python 安装都包含这些包, 而且在有些环境下很难进行安装。如果你无法安装这些包, 我强烈建议你使用 Anaconda, 或者包含这些包的其他 Python 版本。

当你复制完代码库或者将 Zip 包解压后, 会得到一个名为 ThinkStats2/code 的文件夹, 其中有一个 nsfg.py 文件。运行 nsfg.py 会读取一个数据文件, 运行一些测试, 并输出一条消息, 如 “All tests passed”。如果你得到的是 import error, 可能是因为缺少某些必要的软件包。

本书的大部分练习都使用 Python 脚本, 但也有一些使用 IPython 记事本。如果你之前没有用过 IPython 记事本, 可以访问文档 <http://ipython.org/ipython-doc/stable/notebook/notebook.html> 得到帮助。

本书读者应该熟悉 Python 的核心功能, 包括面向对象的特征, 但无需具备 pandas、NumPy 和 SciPy 知识。如果你已经熟知这些模块, 可以跳过一些相关小节。

本书读者应该了解基本的数学知识, 例如对数和求和。本书中有几处会涉及微积分概念, 但你无需进行微积分运算。

如果你从未学习过统计学, 本书会是一本很好的入门教材。如果你学习过传统的统计学课程, 那么我希望本书能够修正你过去接受的一些错误观点。

Allen B. Downey 是一位计算机科学教授, 执教于美国马萨诸塞州尼德姆的富兰克林欧林工程学院。

致谢

如果你有任何建议或者更正, 请发送电子邮件至 downey@allendowney.com。如果我采纳了你的意见并对书中内容进行了修改, 会将你的名字加入致谢列表 (除非你拒绝这样做)。

请在邮件中给出存在错误的句子, 或句子的一部分, 以便我进行搜索。当然, 提供页码和章节号也可以, 但还是以句子内容为佳。谢谢!

- Lisa Downey 和 June Downey 阅读了本书初稿, 作出了很多更正, 也提出了很多建议。
- Steven Zhang 发现了数处错误。

- Andy Pethan 和 Molly Farison 帮助调试了一些解决方案，Molly 还发现了数处拼写错误。
- Andrew Heine 发现了 error 函数中的一个错误。
- Dr. Nikolas Akerblom 知道一只始祖马有多大。
- Alex Morrow 对一个代码示例进行了说明。
- Jonathan Street 在关键时刻发现了一个错误。
- Gábor Lipták 发现了本书的一处拼写错误及接力赛问题的解决方案。
- 非常感谢 Kevin Smith 和 Tim Arnold 设计了 plasTeX，让我可以将本书转为 DocBook。
- George Caplan 的建议使本书结构更加清晰。
- Julian Ceipek 发现了一处错误和很多拼写错误。
- Stijn Debrouwere、Leo Marihart III、Jonathan Hammler 和 Kent Johnson 更正了本书第 1 印次中的错误。
- Dan Kearney 发现了一处拼写错误。
- Jeff Pickhardt 发现了一个损坏的链接和一处拼写错误。
- Jörg Beyer 发现了书中的拼写错误，并对书中代码的帮助文档进行了许多修正。
- Tommie Gannert 发送了一个补丁文件，其中包括许多更正。
- Alexander Gryzlov 对一个练习中的说明提出了建议。
- Martin Veillette 报告了一个 Pearson 相关性公式中的一处错误。
- Christoph Lendenmann 提交了数个勘误。
- Haitao Ma 发现了一处拼写错误，并告诉了我。
- Michael Kearney 提出了很多极佳的建议。
- Alex Birch 提出了一些很有益的建议。
- Lindsey Vanderlyn、Griffin Tschurwald 和 Ben Small 阅读了本书的早期版本，并发现了很多错误。
- John Roth、Carol Willing 和 Carol Novitsky 进行了技术审阅，发现了很多错误，并提出了许多有益的建议。
- Rohit Deshpande 发现了一处排版错误。
- David Palmer 提出了很多建议，作出了不少更正。
- Erik Kulyk 发现了很多拼写错误。

Safari® Books Online



Safari Books Online 是应需而变的数字图书馆。它同时以图书和视频的形式出版世界顶级技术和商务作家的专业作品。

Safari Books Online 是技术专家、软件开发人员、Web 设计师、商务人士和创意人士开展调研、解决问题、学习和认证培训的首选资料。

对于组织团体、政府机构和个人，Safari Books Online 提供各种产品组合和灵活的定价策略。

成为 Safari Books Online 的会员，你即可通过一个功能完备的数据库检索系统访问 O'Reilly Media、Prentice Hall Professional、Addison-Wesley Professional、Microsoft Press、Sams、Que、Peachpit Press、Focal Press、Cisco Press、John Wiley & Sons、Syngress、Morgan Kaufmann、IBMRedbooks、Packt、Adobe Press、FT Press、Apress、Manning、New Riders、McGraw-Hill、Jones & Bartlett、Course Technology 以及其他几十家出版社的上千种图书、培训视频和正式出版之前的书稿。要了解 Safari Books Online 的更多信息，请访问我们的网站 (<http://www.safaribooksonline.com>)。

联系我们

请把对本书的评价和问题发给出版社。

美国：

O'Reilly Media, Inc.
1005 Gravenstein Highway North
Sebastopol, CA 95472

中国：

北京市西城区西直门南大街 2 号成铭大厦 C 座 807 室 (100035)
奥莱利技术咨询 (北京) 有限公司

O'Reilly 的每一本书都有专属网页，你可以在那儿找到本书的相关信息，包括勘误表、示例代码以及其他信息。本书的网站地址是：

http://bit.ly/think_stats_2e

对于本书的评论和技术性问题，请发送电子邮件到：bookquestions@oreilly.com。

要了解更多 O'Reilly 图书、培训课程、会议和新闻的信息，请访问以下网站：

<http://www.oreilly.com>

我们在 Facebook 的地址如下：<http://facebook.com/oreilly>。

请关注我们的 Twitter 动态：<http://twitter.com/oreillymedia>。

我们的 YouTube 视频地址如下：<http://www.youtube.com/oreillymedia>。

目录

前言	xi
第 1 章 探索性数据分析	1
1.1 统计学方法	2
1.2 全国家庭增长调查	2
1.3 数据导入	3
1.4 DataFrame	4
1.5 变量	6
1.6 数据变换	6
1.7 数据验证	8
1.8 解释数据	9
1.9 练习	10
1.10 术语	11
第 2 章 分布	13
2.1 表示直方图	14
2.2 绘制直方图	14
2.3 全国家庭增长调查中的变量	15
2.4 离群值	18
2.5 第一胎	18
2.6 分布概述	20
2.7 方差	21
2.8 效应量	21
2.9 报告结果	22
2.10 练习	23
2.11 术语	23

第 3 章 概率质量函数	25
3.1 概率质量函数	25
3.2 绘制 PMF	26
3.3 绘制 PMF 的其他方法	28
3.4 课堂规模悖论	29
3.5 使用 DataFrame 进行索引	31
3.6 练习	33
3.7 术语	34
第 4 章 累积分布函数	35
4.1 PMF 的局限	35
4.2 百分位数	36
4.3 CDF	37
4.4 表示 CDF	38
4.5 比较 CDF	39
4.6 基于百分位数的统计量	40
4.7 随机数	41
4.8 比较百分位秩	42
4.9 练习	43
4.10 术语	44
第 5 章 分布建模	45
5.1 指数分布	45
5.2 正态分布	48
5.3 正态概率图	49
5.4 对数正态分布	51
5.5 Pareto 分布	53
5.6 随机数生成	56
5.7 为什么使用模型	56
5.8 练习	57
5.9 术语	59
第 6 章 概率密度函数	61
6.1 PDF	61
6.2 核密度估计	63
6.3 分布框架	65
6.4 Hist 实现	65
6.5 Pmf 实现	66
6.6 Cdf 实现	67
6.7 矩	68

6.8	偏度	69
6.9	练习	72
6.10	术语	73
第7章 变量之间的关系		75
7.1	散点图	75
7.2	描述关系特征	78
7.3	相关性	79
7.4	协方差	80
7.5	Pearson 相关性	81
7.6	非线性关系	82
7.7	Spearman 秩相关	82
7.8	相关性和因果关系	83
7.9	练习	84
7.10	术语	85
第8章 估计		87
8.1	估计游戏	87
8.2	猜测方差	89
8.3	抽样分布	90
8.4	抽样偏倚	93
8.5	指数分布	93
8.6	练习	95
8.7	术语	95
第9章 假设检验		97
9.1	经典假设检验	97
9.2	假设检验	98
9.3	检验均值差	100
9.4	其他检验统计量	101
9.5	检验相关性	102
9.6	检验比例	103
9.7	卡方检验	104
9.8	再谈第一胎	105
9.9	误差	106
9.10	功效	107
9.11	复现	108
9.12	练习	109
9.13	术语	109

第 10 章 线性最小二乘法	111
10.1 最小二乘法拟合	111
10.2 实现	112
10.3 残差	113
10.4 估计	114
10.5 拟合优度	116
10.6 检验线性模型	118
10.7 加权重抽样	119
10.8 练习	121
10.9 术语	121
第 11 章 回归	123
11.1 StatsModels	124
11.2 多重回归	125
11.3 非线性关系	127
11.4 数据挖掘	128
11.5 预测	129
11.6 Logistic 回归	131
11.7 估计参数	132
11.8 实现	133
11.9 准确度	134
11.10 练习	135
11.11 术语	136
第 12 章 时间序列分析	139
12.1 导入和清洗数据	139
12.2 绘制图形	141
12.3 线性回归	143
12.4 移动平均值	144
12.5 缺失值	146
12.6 序列相关	148
12.7 自相关	149
12.8 预测	150
12.9 参考书目	154
12.10 练习	154
12.11 术语	155
第 13 章 生存分析	157
13.1 生存曲线	157
13.2 危险函数	159

13.3	估计生存曲线	160
13.4	Kaplan-Meier 估计	161
13.5	婚姻曲线	162
13.6	估计生存函数	163
13.7	置信区间	164
13.8	群组效应	166
13.9	外推	168
13.10	预期剩余生存期	169
13.11	练习	171
13.12	术语	172
第 14 章	分析方法	173
14.1	正态分布	173
14.2	抽样分布	174
14.3	表示正态分布	175
14.4	中心极限定理	176
14.5	检验 CLT	177
14.6	应用 CLT	180
14.7	相关检验	181
14.8	卡方检验	183
14.9	讨论	184
14.10	练习	184
作者介绍		186
封面介绍		186

探索性数据分析

如果能将数据与实际方法相结合，就可以在存在不确定性时解答问题并指导决策，这就是本书的主题。

举个例子。我的妻子在怀第一胎时，我听到了一个问题：第一胎是不是经常晚于预产期出生？下面所给出的案例研究就是由这个问题引出的。

如果用谷歌搜索这个问题，会看到大量的讨论。有人认为第一胎的生产日期确实经常晚于预产期，有人认为这是无稽之谈，还有人认为恰恰相反，第一胎常常会早产。

在很多此类讨论中，人们会提供数据来支持自己的观点。我发现很多论据是下面这样的。

“我有两个朋友最近都刚生了第一个孩子，她们都是超过预产期差不多两周才出现临产征兆或进行催产的。”

“我的第一个孩子是过了预产期两周才出生的，我觉得第二个孩子可能会早产两周！”

“我认为这种说法不对，因为我姐姐是头生子，而且是早产儿。我还有好些表兄妹也是这样。”

这些说法都是基于未公开的数据，通常来自个人经验，因此称为轶事证据（anecdotal evidence）。在闲聊时讲讲轶事当然无可厚非，所以我并不是要批评以上那几个人。

但是，我们可能需要更具说服力的证据以及更可靠的回答。如果按照这个标准进行衡量，轶事证据通常都靠不住，原因有如下几点。