



达人速

R语言

(第2版)

可以很简单

[法] Andrie de Vries [比] Joris Meys 著 李毅 译

让学习变得更简单

- 使用R语言对数据进行分析 and 操作
- 编写函数与脚本来解决重复分析
- 绘制高质量的图表
- 建立统计模型进行分析

R For Dummies
2nd Edition



中国工信出版集团



人民邮电出版社
POSTS & TELECOM PRESS

内容提要

ISBN 7-115-11000-0



达人迷

R 语言可以很简单

for
R dummies
A Wiley Brand

第 2 版



[法] Andrie de Vries
[比] Joris Meys 著

李毅 译



for
dummies
A Wiley Brand

人民邮电出版社
北 京

图书在版编目(CIP)数据

R语言可以很简单:第2版/(法)安德里·德弗里斯(Andrie de Vries),(比)乔里斯·梅斯(Joris Meys)著;李毅译.—北京:人民邮电出版社,2017.7

(达人迷)

ISBN 978-7-115-45539-0

I. ①R… II. ①安… ②乔… ③李… III. ①程序语言—程序设计 IV. ①TP312

中国版本图书馆CIP数据核字(2017)第114297号

版权声明

Andrie de Vries, Joris Meys

R For Dummies, 2nd Edition

ISBN 978 - 1 - 119 - 05580 - 8

Copyright © 2015 by John Wiley & Sons, Inc.

All rights reserved. This translation published under license.

Authorized translation from the English language edition published by John Wiley & Sons, Inc.

本书中文简体字版由 John Wiley & Sons 公司授权人民邮电出版社出版,专有版权属于人民邮电出版社。版权所有,侵权必究。

-
- ◆ 著 [法] Andrie de Vries [比] Joris Meys
译 李 毅
责任编辑 王峰松
责任印制 焦志伟
- ◆ 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>
北京市艺辉印刷有限公司印刷
- ◆ 开本: 800×1000 1/16
印张: 24
字数: 537千字 2017年7月第1版
印数: 1-2400册 2017年7月北京第1次印刷
- 著作权合同登记号 图字: 01-2016-5849号
-

定价: 69.00元

读者服务热线: (010)81055410 印装质量热线: (010)81055316
反盗版热线: (010)81055315

内容提要

R 是一个开源、跨平台的编程语言，用于统计计算和绘图，特别是其社区开发的数以千计的扩展包为 R 增加了强大的和前瞻性的功能。数据分析与挖掘已经成为大数据时代重要的技能之一，而 R 已经成为数据分析领域炙手可热的标志性语言。

本书作为业内外一致好评的 Dummies 系列书籍之一，是供 R 语言初学者学习的经典力作。本书通俗易懂地讲解了如何利用 R 语言基本知识，包括创建、运行以及调试 R 脚本，用户自定义 R 函数，用 R 绘制基本图形，R 的循环语句和逻辑控制语句等，逐步引导读者迈入 R 语言高手行列。

本书适用于数据分析人员以及对 R 语言感兴趣的读者。

作者简介

Andrie de Vries：他从 2009 年开始使用 R 语言来分析调研数据，之后开始活跃在一些开源社区，开发引人注目的软件。同时，Andrie 就职于 PentaLibra 公司，从事时尚品市场的调研和统计分析。随着 Andrie 对 R 疯狂地着迷，他加入 Revolution Analytics 公司使用 R 来服务于企业客户，帮助客户处理大数据和数据科学带来的挑战。为了陶冶生活，Andrie 正在学习瑜伽。

Joris Meys：理学硕士，比利时根特大学讲师，同时也是统计咨询师和 R 程序员。在获得生物学硕士学位后，他从事了 6 年环境研究与管理相关的工作，之后获得了统计数据分析的高级硕士学位。Joris 为他们系的项目开发了大量代码包，另外他也是 R-Forge 上某些包的维护者，还与其他合作者共同发表了若干统计专业方面的学术论文。在闲暇时刻，Joris 是当地乐队的萨克斯手。

译者简介

李毅，韩国岭南大学理学博士，现为山西财经大学统计学院副教授、硕士生导师，研究方向为应用统计，主持国家自然科学基金、国家统计局多项重点课题等，发表学术论文 20 余篇，其中被 SCI 收录 10 余篇，其电子邮箱：liyi@sxufe.edu.cn。

献词

敬爱

这本书献给我的妻子 Annemarie，谢谢她的鼓励、支持和耐心。同时还有我 9 岁的外甥女 Tanya，她数学非常棒，一直很认真地提醒我这本书的截稿日期！最后感谢我的父母，一生的鼓励。

——Andrie de Vries

献给我这一生最重要的女人——我的母亲，因为她成就了现在的我；献给 Eva，深爱着我的人；献给 Amelie，每次她的微笑感染着我；献给 Granny，因为她太酷了！

——Joris Meys

致谢

本书能够面世，完全得益于 Wiley 出版社编辑团队的大力支持。我们尤其感谢本书第一版的编辑 Elizabeth Kuball 和第二版的编辑 Katie Mohr。

感谢我们的技术编辑 Gavin Simpson，他非常仔细地审阅了本书并给出了很好的建议。

感谢 R 语言核心开发团队开发 R 语言、维护 CRAN，并通过各类邮件列表、文档和专题讲座为 R 社区贡献力量。感谢 R 语言社区，感谢大家开发了数以千计的代码包、博客文章，并回答各种疑难问题。

本书使用了若干个由 Hadley Wickham 编写的代码包，他对 ggplot 和 dplyr 等代码包的贡献至今引人注目。

在编写本书的过程中，我们收到大量 R tag 和 Stack Overflow 贡献者的帮助和支持。在这里要感谢：James (JD) Long、David Winsemius、Ben Bolker、Joshua Ulrich、Barry Rowlingson、Roman Luštrik、Joran Elias、Dirk Eddelbuettel、Richie Cotton、Colin Gillespie、Simon Urbanek、Gabor Grotendieck，还有一直努力让 Stack Overflow 成为更优秀的 R 资源社区的爱好者们。

Andrie：毫不夸张地说这本书改变了我的人生轨迹。我学习 R 归功于开源代码社区，写这本书归功于 Revolution Analytics 公司。同时我要感谢我的同事，特别是 Derek McCrae Norton、David Smith 和 Joseph Rickert。

Joris：感谢比利时根特大学数据建模、统计与生物信息系的各位教授和同事，他们在本书撰写过程中所进行了深入而细致的讨论，感谢他们提供的帮助。

前言

欢迎阅读《R 语言可以很简单》。这本书可以帮助读者快速轻松地学习统计编程语言 R。

读过这本书后，虽然不能保证读者会成为 R 语言专家，但读者应该能够掌握以下几点。

- » 利用各种强大的工具进行数据分析。
- » 使用 R 语言完成统计分析和数据处理任务。
- » 领会到向量运算（而不是循环）进行高速计算的魅力。
- » 欣赏下面代码的优美：

```
knowledge<- apply(theory, 1, sum)
```
- » 知道如何查找、下载和使用 R 语言社区里活跃的开发者贡献的代码。
- » 知道在哪里获取额外的帮助和资源，从而进阶 R 语言的编程水平。
- » 能够绘制漂亮的图形，实现数据可视化。

关于这本书

《R 语言可以很简单》主要介绍 R 统计编程语言。从 R 语言的 IDE 界面介绍和最基本的语法入手，由浅入深，逐步到更复杂的数据处理和分析。

本书用浅显易懂的实例来解释 R 语言的要点，不仅包含了大量的代码片段，还有很多完整的数据分析脚本，给读者留下很大的动手尝试发挥空间。

本书不对 R 语言的内部实现技术进行介绍，而是更关注 R 语言为什么这样操作。R 语言有很多看起来可能很奇怪的属性，因此，本书将介绍如何对 R 发出命令，以及 R 怎样处理命令。读完本书后，读者不仅能够以其想要的格式来管理数据，还会知道如何使用本书没有提及的功能（也包括提到的）。

这是一本参考书。读者不必从头读到尾，而是可以通过目录和索引快速找到想要的内容，书中还会交叉引用其他章节，以提供更多的信息。

第2版的变化

第1版书出版以来，R语言一直不断地发展和改进。为了让本书准确无误，作者更新了代码来反映最新R版本（3.2.0版本）的变化。根据读者、学生和同事的反馈，作者重新修订了部分章节，更正了一些错误，例如，在使用文本字符串时，修改了代码用法——用双引号取代单引号；将列表的基本单元称为组件，而不是元素。

本书中有全新R包“rfordummies”案例代码。详情见附录B。

R 和 R Studio

《R语言可以很简单》适用于任何操作系统，无论是Mac、Linux还是Windows，这本书都会让读者学会在自己的操作系统中使用R。

与其说R是应用程序，不如说R是编程语言。当下载R时，适用于读者的操作系统的控制台程序也会一同被下载。然而，这些程序只具备基本的功能，在不同的操作系统中会略有差异。

R Studio是跨平台应用程序，被认为是非常简洁的R语言集成开发环境（IDE）。本书不强制读者使用某种特定的R语言控制台。但是，R Studio在不同的操作系统中提供通用的操作界面，本书将使用R Studio而非某个特定操作系统的R语言控制台来演示R语言的概念和程序。

本书的一些默认规则

下面的一段代码模拟出2个六面骰子掷100万次的例子。

```
> set.seed(42)
> throws <- 1e6
> dice<- replicate(2,
+                   sample(1:6, throws, replace = TRUE)
+ )
> table(rowSums(dice))
```

	2	3	4	5	6	7	8
	28007	55443	83382	110359	138801	167130	138808
	9	10	11	12			
	110920	83389	55816	27945			

这里每一行 R 代码之前都带有一个提示符，有以下两种情况。

- » >: 提示符 “>” 不属于代码的一部分，当读者练习输入代码的时候不需要输入该符号。
- » +: 连续符 “+” 表示该行代码仍属于上一行。读者不必将一行代码分成两行输入，本书中这么写通常是考虑到书中代码排版印刷后的可读性。

R 控制台不会输出提示符或连续符开头的行。在这个例子中，所投掷的 2 个骰子点数之和为 2 到 12。例如，在投掷的 100 万次中，有 28007 次投掷结果的和为 2。

读者可以试着复制这段代码在 R 中运行，但是在确保正确地输入这段代码的同时，需要注意以下三点。

- » 不要输入提示符 “>”。
- » 不要输入连续符 “+”。
- » 除了关键字，可以在任何位置输入空格或制表符。另外，需要注意换行。

在 R 控制台输入代码时，代码前会出现提示符 “>”，如下：

```
>print("Hello world!")
```

在控制台输入这行代码，然后敲击回车键，R 会运行出下面的结果：

```
[1] "Hello world!"
```

为了简便，将上面两行输入代码和输出结果合并成单一代码框来表示，如下：

```
>print("Hello world!")  
[1] "Hello world!"
```

在本书中，R 语言的函数、参数等关键词用普通字体来表示。例如，可以使用 `plot()` 函数来绘制一张数据图。函数名称后面都会有一对小括号——例如 `plot()`。除非特别必要，一般不会对正文的函数名后面添加参数等额外信息。

本书也会介绍菜单命令，例如 `File⇒Save`，这表示打开 `File` 菜单，然后选择 `Save` 选项。

可以省略阅读的内容

如果这本书适合于读者的学习，但又时间紧迫（或者对某些技术细节不感兴趣

趣)，则读者可以放心地跳过带有“Technical Stuff”图标的内容，也可以略过侧边栏（灰色框中内容），虽然其中包含了不少有趣的信息，但是这对把握整体知识没有任何影响。

读者要求

本书对读者及其计算机有如下要求。

- » 要熟悉计算机的基本操作。读者要知道如何下载和安装软件，可以连接互联网，并且知道如何在互联网上搜索信息。
- » 可以不是一个程序员。如果读者是程序员，并且使用过其他编程语言编写代码，那么推荐关注“Technical Stuff”中的内容，这里会告诉读者 R 语言和其他常见的编程语言之间的异同点。
- » 可以不是来自统计学专业，但需要具备基本统计学知识。这本书不是一本统计学著作，但展示了如何用 R 语言来完成一些基础的统计工作。如果读者想要更深入地了解统计学知识，推荐学习 Deborah J. Rumsey 博士编写的《Statistics For Dummies, 2nd Edition》（Wiley 出版）。
- » 想要学习新的知识。读者喜欢解决问题，并且不惧怕在 R 控制台界面上进行尝试。

本书结构安排

本书由 6 部分组成，每部分内容如下所示。

第一部分：R 语言编程入门

在这部分，读者将要编写第一个脚本。使用强大的向量概念来对多个变量进行一次性计算。在 R 工作空间上工作（即如何创建、修改和删除变量），读者会学会保存工作，加载并修改之前编写的 R 脚本文件。另外，我们还会介绍 R 的一些基础知识（如如何安装程序包）。

第二部分：开始使用 R

这部分介绍 R 语言三会：读、写和算，即处理文本和数字（包括日期）。另外，读者也可以学到列表和数据框这两种重要的数据结构。

第三部分：编写R代码

R 是一种编程语言，因此需要了解如何编写和理解函数。这部分将介绍如何完成相关工作，如何使用 if 语句控制脚本的逻辑流，以及如何使用循环代码来实现重复操作。此部分还介绍了如何处理代码中产生的警告和错误提示。最后，还会介绍一些工具，帮助读者应对调试中可能遇到的问题。

第四部分：让数据说话

在这部分，首先介绍 R 语言中使用的不同类型的数据结构，如列表和数据框。读者将学会如何在 R 语言中将数据导入或者输出（例如，从文件夹或剪贴板中读取数据），并且还会掌握如何将 R 语言与其他应用程序（如微软 Excel 软件）进行交互使用。

其次，读者将会发现在 R 语言中做数据的高级变形和管理是非常容易的。此部分介绍如何对数据的子集进行选择、分类和排序，如何基于相同数据列合并不同的数据集。同时，针对数据子集应用函数来实现分离和合并数据，还介绍了一种非常有效的策略。当读者理解了这个策略后，可以反复地使用，只需要很少的几步就可以进行复杂数据的专业分析。

阅读完这部分后，读者会搞清楚如何使用 R 语言来描述、总结变量和数据，将能够做一些经典的检验（如 t 检验），并且学会如何使用随机数来模拟一些分布。

最后，介绍了一些线性模型的基本原理（如线性回归和方差分析）。此外，还展示了如何在 R 语言上利用数据拟合模型，从而预测新数据。

第五部分：绘制图形

有人说，一张图胜过千言万语。尤其是当读者想和其他人分享自己的研究成果时这一点是肯定的。在这部分中，读者会学习如何绘制基本的甚至更复杂的图形，以可视化形式查看数据。我们将从柱形图和折线图开始，介绍如何使用小平面来展示数据的不同方面。

第六部分：20条有用建议

这部分介绍了如何用 R 语言来做本可以使用微软 Excel 来做的 10 件事。例如，如何做出相同效果的透视图和查询表。另外，本书也给出了 10 条关于使用非基础 R 程序包的建议。

本书图标

当读这本书的时候，读者会在页面边缘发现一些小图片。这些图片，或者说是图标，标注了下面的类型。



TIP

当看到这个“TIP”图标的时候，一定可以找到一种更简单或者更快速的方法来替代某项操作。



REMEMBER

不需要完全记住这本书，但是“REMEMBER”图标标出的内容都是很有用的东西，是必须要记住的。通常这些标示表明会在更多的章节中遇到它们。



WARNING

当看到“WARNING”图标的时候，一定要提高警惕。它告诉读者哪些事情是千万不能做的。虽然使用 R 并不会导致一些灾难性的错误，但是需要用这个图标提醒读者可能会增添的麻烦。



TECHNICAL
STUFF

“TECHNICAL STUFF”图标表示一些技术细节，可以放心地跳过。本书尽可能使这些内容变得有趣，但是如果读者没有时间，或者只需要获取想要的知识，可以跳过这些内容，继续下面的学习。

本书之外的内容

本书还包含了以下可以在互联网下载的相关信息及对应网址：

» 备忘录：www.dummies.com/cheatsheet/r

» 额外的内容：www.dummies.com/extras/r

» 源代码：www.dummies.com/extras/r

下一步

学习 R 语言的唯一途径是：使用它！本书尽力让读者熟悉 R 的用法。但读者最好坐在电脑前亲身体验和尝试，翻开书，开始敲击键盘吧！

目录

第一部分 R 语言编程入门	1
第 1 章 R 语言简介：全景图	3
认识到使用 R 语言的优势	5
免费、开源代码	5
可以在任何环境下运行	5
R 语言支持扩展	5
拥有活跃的社区	5
和其他语言的连接	6
R 语言的独特之处	7
向量的多项计算	7
不仅仅是统计分析	8
无需编辑直接运行	8
第 2 章 探索 R	9
使用代码编辑器	10
探索 RGui	11
用 RStudio 优化	13
开始第一个 R 会话	15
向世界说你好	15
使用向量	15
存储和计算值	16
回馈用户	18
启动一个脚本	18
响应你的工作	20

导航环境	21
操纵环境中的内容	21
保存你的工作	21
检索你的工作	22
第3章 R 基础知识	23
充分利用函数的强大功能	23
向量函数	24
函数参数调用	25
创建历史记录	27
保持代码的可读性	27
遵循命名规则	28
组织代码	30
添加注释	32
R 基础功能的扩展	32
查找扩展包	32
安装扩展包	33
加载和卸载扩展包	33
第二部分 开始使用 R	35
第4章 算术入门	37
数值、无穷值与缺失值	37
基础运算的操作	38
使用数学函数	40
计算整个向量	43
无穷及其以后	43
使用向量组织数据	45
探索向量属性	45
创建向量	48
向量连接	48

重复向量	49
向量值的存取	49
理解 R 的索引	50
从向量中提取数值	50
修改向量的值	51
使用逻辑向量	52
值的比较	53
将逻辑向量作为索引	54
逻辑表达式的组合	55
逻辑向量小结	56
增强数学运算	56
使用向量的数学运算	57
参数循环	59
 第 5 章 开始读和写	 61
对文本数据使用字符向量	61
为字符向量赋值	62
创建包含多个元素的字符向量	62
获取向量的子集	63
为向量中的值命名	64
文本操作	66
字符串理论：组合和分割字符串	66
文本排序	69
查找文本中包含的内容	70
文本替换	72
使用正则表达式	73
使用因子进行分类	76
创建因子	76
转换因子	77
关注水平	79

区分数据类型	80
使用有序因子	81
第 6 章 使用 R 处理时间数据	83
处理日期	83
用不同的格式表示日期	85
添加时间	86
日期和时间的格式	88
操作日期与时间	88
加法和减法	89
日期的比较	89
提取	90
第 7 章 高维数据的处理	93
添加第二个维度	93
探索新维度	94
将向量组合成矩阵	97
使用索引	98
提取矩阵元素的值	98
降低维度	100
修改矩阵中的值	100
为矩阵行列命名	101
修改行和列的名称	102
将名称作为索引	103
矩阵的计算	103
矩阵的基本运算	103
行列求和	105
矩阵运算	105
添加更多维度	107
创建数组	107