HZ BOOKS
华章IT
CRC Press
Taylor & Francis Group

数据科学与工程技术丛书

高级R语言编程指南

[美] 哈德利·威克汉姆（Hadley Wickham）著
李洪成 段力辉 何占军 译

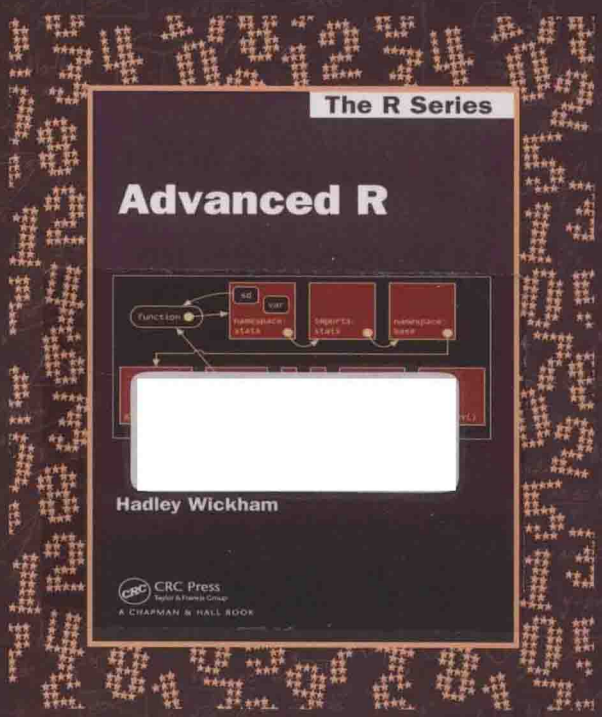

ADVANCED R

机械工业出版社
China Machine Press

数据科学与工程技术丛书

ADVANCED R

高级R语言编程指南

[美] 哈德利·威克汉姆（Hadley Wickham） 著

李洪成 段力辉 何占军 译

机械工业出版社
China Machine Press

图书在版编目（CIP）数据

高级 R 语言编程指南 /（美）哈德利 · 威克汉姆（Hadley Wickham）著；李洪成，段力辉，何占军译 . —北京：机械工业出版社，2016.6
（数据科学与工程技术丛书）
书名原文：Advanced R

ISBN 978-7-111-54067-0

I. 高… II. ① 哈… ② 李… ③ 段… ④ 何… III. 程序语言－程序设计 IV. TP312

中国版本图书馆 CIP 数据核字（2016）第 130804 号

本书版权登记号：图字：01-2015-3694

本书从 R 语言的基础知识入手，深入而详细地介绍了 R 语言及其编程技术。本书共分 4 部分：R 语言基础、函数式编程、R 语言计算和 R 性能分析。第一部分详细介绍 R 的基础知识，包括数据结构、子集选取、常用函数与数据结构、编程风格指南、函数、面向对象编程、环境、程序调试和防御性编程等。第二部分介绍函数式编程、泛函、函数运算符等。第三部分介绍非标准求值、表达式、领域特定语言（HTML 和 LaTex）等。第四部分介绍 R 的性能、代码调优、内存管理、高性能计算和 C 语言编程接口等。

本书适合 R 的初学者和具有一定编程经验的 R 用户，他们都能从书中找到对自己有用的内容。

出版发行：机械工业出版社（北京市西城区百万庄大街 22 号　邮政编码：100037）
责任编辑：盛思源　　责任校对：殷　虹
印　　刷：三河市宏图印务有限公司　　版　　次：2016 年 6 月第 1 版第 1 次印刷
开　　本：185mm × 260mm　1/16　　印　　张：19.5
书　　号：ISBN 978-7-111-54067-0　　定　　价：79.00 元

凡购本书，如有缺页、倒页、脱页，由本社发行部调换
客服热线：（010）88378991　88361066　　投稿热线：（010）88379604
购书热线：（010）68326294　88379649　68995259　　读者信箱：hzjsj@hzbook.com

推 荐 序

根据调查，R 语言现在是高级分析、统计学、数据可视化和预测模型开发领域最流行的工具。在 Statistics.com 在线课程中，R 语言方面的课程都有大量的需求，这些课程包括本书作者 Hadley Wickham 开发的 ggplot2、数据挖掘、统计模型、地图、空间分析和贝叶斯统计等。R 语言流行的一个原因是，巨大的 R 社区贡献了数千个适用于各种应用的 R 添加包。

R 在统计学家和数据挖掘人员中的流行，奠定了它在编程语言中的独特地位。最初，用户应用 R 进行统计模型拟合、数据可视化或者其他的统计任务。对这些用户而言，R 是一个功能强大的、免费的、基于命令行的统计软件。至少，一开始他们可能不需要开发高效的、长度太大的复杂代码。这些用户随着应用 R 的范围变广、应用加深，把 R 作为一门编程语言来进行最佳实践的需求就变得迫切了。

本书是进一步学习 R 语言和进行标准编程实践一个很好的指南，它与应用 R 进行数据分析密切相关。该书系统地讲解了数据结构、子集选取、函数、泛函和面向对象编程。那些被 R 的速度慢而困扰的用户可能喜欢本书有关内存应用、代码优化和高性能计算部分的内容。

越多的 R 用户遵从本书开始几章列出的原则，在 R 社区中就会看到更多的高水平的 R 代码。

美国统计教育学院，Statistics.com 在线课程网站总裁和创始人 Peter Bruce

According to some surveys, R is now the most popular tool for advanced analytics, statistics, visualization and predictive model development. At Statistics.com, courses in R are in high demand, including the ggplot2 course that Hadley Wickham developed, as well as courses in data mining, statistical modeling, mapping, spatial analysis, Bayesian statistics, and more. One reason for this is the huge global R community, which has contributed thousands of R packages for all kinds of purposes.

R's popularity among statisticians and data miners has given it a unique position among programming languages. Most of its users originally came to R with a goal of fitting a statistical

model, producing a visualization, or performing some other statistical task. For these users, R is essentially a powerful, free command-line statistical software program. They probably did not need to create code that was lengthy, complex, or especially fast, at least at first. With time, though, as the general use of R broadened and deepened, the need to treat R as a programming language, and observe "best practices," grew.

This book provides a guide for these users who need to step back and learn the nitty-gritty of standard programming practices, as it they pertain to the use of R for data analysis. It provides a systematic treatment of data structures, notation, subsetting, functions, and functional and object-oriented programming. Those frustrated with R's slowness will like the sections on memory use, code optimization and high performance computing. The more R-users who follow the principles outlined in the coming chapters, the better the overall level of code we will see in the R community.

Peter Bruce

President and Founder

The Institute for Statistics Education at Statistics.com

译 者 序

随着大数据的概念变得越来越流行，对数据的探索、分析和预测将成为大数据分析领域的基本技能之一。作为探索和分析数据的基本工具，数据分析软件包是必不可少的。R软件作为功能强大且开源的数据分析工具，在数据分析领域获得了越来越多用户的青睐。目前，市场上出版了大量的与R语言有关的书籍，这些书籍基本可以分为两类：一类是通过R语言介绍某个主题或者课程；另一类是R软件或者R语言入门性质的介绍。目前尚没有一本深入而详细地介绍R语言与编程的书籍。本书恰好填补了这方面的空白。

本书从R语言的基础知识入手，深入介绍R函数式编程、R语言的面向对象特性、程序调试、代码优化和性能调优。同时，本书也介绍了R语言如何与HTML和LaTex语言相结合的技术，介绍了高性能计算以及C语言编程接口。

本书作者Hadley Wickham是R语言专家，他具有10年以上应用R语言的实践经验，他编写了许多高质量的R添加包，例如ggplot2、plyr、reshape2等，这些都是在R社区广泛使用的添加包。通过本书的学习，一方面可以更深入地了解R语言编程的核心知识，另一方面也可以在某种程度上了解这样一位众所周知的R语言专家所编写的R添加包。

本书共分4部分：R语言基础、函数式编程、R语言计算和R性能分析。第一部分详细介绍R的基础知识，包括数据结构、子集选取、常用函数与数据结构、编程风格指南、函数、面向对象编程、环境、程序调试和防御性编程；第二部分介绍函数式编程、泛函、函数运算符；第三部分介绍非标准求值、表达式、领域特定语言（HTML和LaTex）；第四部分介绍R的性能、代码调优、内存管理、高性能计算和C语言编程接口。

本书是学习R语言难得的手册。不管是初学者还是具有一定编程经验的R用户，都可以从本书获益。初学者可以先从第一部分入手，然后根据需要逐步学习后面的部分。熟练的R用户可以从自己感兴趣的内容入手。

本书的翻译得到了国家自然科学基金（项目编号71461005）和广西高校数据分析与计算重点实验室的资助。在本书的翻译过程中，得到了明永玲编辑的大力支持和帮助。本书责任编辑盛思源老师具有丰富的经验，为本书的出版付出了大量的劳动。这里对她们的支持和帮助表示衷心的感谢。本书的翻译工作主要由李洪成、段力辉共同完成，何占军和吴立明协助翻译了本书的部分内容。

由于时间和水平所限，难免会有不当之处，希望同行和读者多加指正。

目　录

第四部分　性能

第 1 章
简　介

本书可以帮助你避免犯我曾经犯过的错误，带你走出我曾经无法跳出的死胡同，并会教给你使用一些有用的工具、技术以及习惯，从而帮助你解决编程中遇到的多种问题。在这个过程中，我希望让你知道虽然 R 语言有很多令人沮丧的奇怪之处，但是 R 从本质上来说是一款十分适合数据分析和统计的优雅而美丽的语言。

如果你刚刚接触 R，你可能会问这门奇怪的语言有什么值得学习的呢。对于我来说，R 语言最好的特性有下面几条：

- R 是免费、开源、跨平台的。所以如果使用 R 进行数据分析，每个人都可以很容易地复制它（重现分析过程）。
- 大量可以用于统计建模、机器学习、可视化、数据导入与操作的添加包（package）可以供 R 使用。可能别人都已经做好了你正在尝试构建的任何模型或者图形。即使不能完全照搬，你也会从他们的工作中学到很多经验从而对你的工作起到帮助作用。
- 最前沿的工具。统计学和机器学习领域的研究者在发表他们的研究论文时，经常会同时发布一个相应的 R 添加包。这就意味着你可以马上获得最新的统计技术并可以迅速实施。
- 对数据分析根深蒂固的支持。它包括很多特性，比如缺失值、数据框和子集选取。
- R 语言的爱好者组成了一个非常棒的社区。你可以非常容易地在 R- 帮助邮件列表（https://stat.ethz.ch/mailman/listinfo/r-help），stackoverflow（http://stackoverflow.com/questions/tagged/r），或者在其他一些针对特殊项目的邮件列表如 R-SIG-mixed-models（https://st at.ethz.ch.cnl/mailman/listinfo/r-sig-mixed-models） 或 ggplot2（https://groups.google.com/forum/#!forum/ggplot2）中得到专家的帮助。你也可以通过 Twitter（https://twitter.com/search?q=%23rstats）、LinkedIn（http://www.linkedin.com/groups/R-Project-Statistical-Computing-77616），或者用户组（http://blog.revolutionanalytics.com/local-r-groups.html）与其他 R 学员进行联系。
- 交流结果的强大工具。R 添加包可以非常容易地将结果输出成 html 或 pdf 报告（http://yihui.name/knitr/），或者创建一个交互式网站（http://www.rstudio.com/shiny）。
- 强大的函数式编程基础。函数式编程的思想非常适合应对很多数据分析的挑战。R 提供了一个强大而又灵活的工具包，让你可以写出简洁的描述性代码。

- 一个为交互式数据分析和统计编程量身定做的IDE（交互式开发环境）（http://www.rstudio.com/ide/）。
- 强大的元编程（metaprogramming）工具。R不仅仅是一门编程语言，还是一个数据分析的交互环境。它的元编程功能可以让你写出超级简洁明了的函数并为设计领域特定语言（domain-specific language）提供了出色的环境。
- 可以与高性能编程语言（如C、Fortran和C++）连接。

当然R也不是完美的。R最大的挑战就是大多数用户都不是程序员。这就意味着：

- 你看到的很多R代码都是在急于解决某个紧迫问题的情况下编写的。因此这些代码并不是非常简洁、高效或者易于理解。大多数用户不会修改他们的代码来克服这些缺点。
- 与其他编程语言相比，R社区更注重结果而非过程。软件工程最佳实践的知识不够完整。例如，使用源代码控制或自动化测试的R程序员还不够多。
- 元编程是一把双刃剑。有太多的R函数通过使用一些技巧来减少代码的输入量，由此造成的结果就是使代码变得很难理解，有些还会以意想不到的方式失败。
- 不同作者贡献的各种R添加包之间经常会出现矛盾，甚至与R的基础包发生冲突。每次使用R时，你都要面对它20多年的进化史。由于需要记住很多特例，所以R语言的学习会比较困难。
- R并不是速度很快的编程语言，尤其是写得很差的R代码运行起来会非常慢。R还非常耗费内存。

从个人角度来看，我觉得这些挑战也为有经验的程序员创造了一个极大的机会，让他们可以对R和R社区产生深远而又有益的影响。R用户确实应该写出高质量的代码，尤其是在进行可重复研究时，但是他们现在还不具有这样的能力。我希望本书不仅可以帮助更多的R用户成为R程序员，还非常鼓励正在使用其他语言的程序员对R语言做出贡献。

1.1 本书的目标读者

本书是针对两个互补的群体：

- 想深入学习R并学习解决各种问题的新策略的中级R程序员。
- 正在学习R，并想知道R为什么这样工作的其他语言的程序员。

要从本书获得最大收益，你需要编写大量的R语言或者其他语言的代码。你可能不了解函数的所有细节，尽管你目前可能为如何高效地应用它们而努力，但是你应该熟悉R中的函数是如何工作的，你应该熟悉apply系列函数（如`apply()`和`lapply()`）。

1.2 通过本书你可以学到什么

我认为本书描述的这些技能是一个高级R程序员应该掌握的：能够写出可以在各种环境中使用的高质量代码。

读完本书之后，你将：

- 熟悉R的基础。你将理解复杂的数据类型和对它们进行运算的最佳方法。对函数如何工作有更深入的理解，还将认识并使用R的4个对象系统。
- 理解什么是函数式编程，以及为什么函数式编程是数据分析的有用工具。你将能快

速地学习如何使用现有工具，以及如何在需要的时候创建自己的函数。

- 欣赏元编程这把双刃剑。你将能在遵守原则的前提下使用非标准运算（non-standard evaluation）来创建函数，从而减少代码的输入量并创建优雅的代码来表达重要的运算。你将理解元编程的危险并知道为什么使用它时要小心。
- 对于R中什么样的操作会很慢且耗费内存能够产生很好的直觉。你将知道如何使用分析来找到阻碍性能提高的瓶颈，还会学到足够多的C++知识，让你可以将很慢的R函数转换成非常快的C++程序。
- 自如地阅读并理解大多数R代码。你将认识一些R的常用语（即使你自己不使用它们），并能够对其他人的代码做出评判。

1.3 元技术

有两种元技术对改善R程序员的技术非常有帮助：阅读源代码和采用科学的思维方式。

阅读源代码之所以重要是因为它可以帮助你写出更好的代码。开始培养这种技能的一种好方法就是查看你经常使用的函数和添加包的源代码。你会发现其中有很多值得效仿的地方，这样你就会知道什么可以使你的代码更好。你也会看到一些你不喜欢的东西，或许因为它的优点不够明显或者它让你感到不舒服。这样的代码也不是没有意义，它可以让你对好代码和坏代码有更具体的认识。

学习R时具有科学的思维方式是极有帮助的。如果你不知道有些事情是如何运行的，那就提出一个假设，设计一些实验，做实验并记录结果。这种训练是非常有用的，即使你不能解决这个问题并需要别人的帮助，但在寻求帮助时你可以告诉他们你已经尝试过哪些方法。另外，当你得到新的答案后，你也已经在思想上做好了准备来更新你的世界观。当我向别人描述问题时（构建一个可再现示例（http://stackoverflow.com/questions/5963269）的艺术），我都会指出自己的解决方案。

1.4 推荐阅读

R仍然是一门相对比较年轻的语言，可以帮助你理解它的资源还在不断地完善之中。在理解R的整个过程中，我发现使用其他编程语言的资源是非常有帮助的。R同时具有函数式编程和面向对象（OO）编程的特点。学会如何使用R来实现这些概念可以帮助你利用起你自己关于其他编程语言的知识，并让你发现（R）哪里还需要改进。

我发现Harold Abelson和Gerald Jay Sussman的《The Structure and Interpretation of Computer Programs》（http://mitpress.mit.edu/sicp/full-text/book/book.html）（SICP）一书对于理解R的对象系统为什么那样运行是非常有帮助的。这是一本简明但又深奥的书。读完本书之后，我第一次感觉到我可以设计出自己的面向对象系统。在本书中我第一次认识了R面向对象系统中常用的泛型函数（generic function）风格。它帮助我理解了R的优缺点。SICP同样讲述了很多函数式编程的知识，以及如何构建简单的函数，当把这些简单函数结合在一起时它又会变得非常强大。

要理解R相对于其他编程语言的优缺点，我发现Peter van Roy和Sef Haridi的《Concepts, Techniques and Models of Computer Programming》（http://amzn.com/0262220695?tag=devtools-20）非常有用。它让我知道了为什么R的copy-on-modify语义使得对代码的理解变

得如此简单，虽然现在实现起来还不是非常有效，但这个问题是可以解决的。

5 如果你想成为一个更好的程序员，没有哪本书比 Andrew Hunt 和 David Thomas 的《The Pragmatic Programmer》（http://amzn.com/020161622X?tag=devtools-20）更好了。这本书并不针对特定的语言，它对如何使你成为更好的程序员提供了很多建议。

1.5 获取帮助

目前当你遇到困难并且不知道如何解决它时，你有两个渠道可以获得帮助：stackoverflow（http://stackoverflow.com）和 R-help 邮件列表。在这两个地方你能得到有益的帮助，但是每个社区都有自己的文化和期望。通常情况下你最好先花一段时间潜水，在了解了该社区的文化和期望之后再提出你的第一个问题。

一些建议：

- 当你遇到问题时首先要确保你使用的是 R 的最新版本和添加包，很可能这些问题已经在最新版本中被修复了。
- 花一段时间构建一个可再现示例（http://stackoverflow.com/questions/5963269）。这通常是一个非常有用的过程，在再现问题的过程中你经常会找到问题的原因。
- 在求助前首先搜索一下相关问题。如果有人已经问过同样的问题并得到了回答，使用现有答案会更快速方便。

1.6 致谢

我要感谢 R-help 以及 stackoverflow（http://stackoverflow.com/questions/tagged/r）上不
6 知疲倦的贡献者。有太多人需要感谢了，尤其要感谢 Luke Tierney、John Chambers、Dirk Eddelbuettel、JJ Allaire 和 Brian Ripley 花费了大量的时间和精力为我纠正无数的错误。

本书是以开源方式编写的（https://github.com/hadley/adv-r），Twitter（https://twitter.com/hadleywickham）上的朋友对本书的章节给出了很多建议。这是社区的智慧结晶：很多人阅读了书稿，修改了错别字，对修改提出了建议，对本书的内容做出了贡献。没有这些人的帮助，本书不可能像现在这样给力，非常感谢他们的帮助。尤其要感谢 Peter Li，他从头到尾阅读了本书并修订了很多错误。其他非常给力的贡献者有：Aaron Schumacher、@crtahlin、Lingbing Feng、@juancentro 和 @johnbaums。

以字母顺序感谢所有的贡献者：Aaron Schumacher、Aaron Wolen、@aaronwolen、@absolutelyNoWarranty、Adam Hunt、@agrabovsky、@ajdm、@alexbbrown、@alko989、@allegretto、@AmeliaMN、@andrewla、Andy Teucher、Anthony Damico、Anton Antonov、@aranlunzer、@arilamstein、@avilella、@baptiste、@blindjesse、@blmoore、@bnjmn、Brandon Hurr、@BrianDiggs、@Bryce、C. Jason Liang、@Carson、@cdrv、Ching Boon、@chiphogg、Christopher Brown、@christophergandrud、Clay Ford、@cornelius1729、@cplouffe、Craig Citro、@crossfitAL、@crowding、CrtAhlin、@crtahlin、@cscheid、@csgillespie、@cusanovich、@cwarden、@cwickham、Daniel Lee、@darrkj、@Dasonk、David Hajage、David LeBauer、@dchudz、dennis feehan、@dfeehan、Dirk Eddelbuettel、@dkahle、@dlebauer、@dlschweizer、@dmontaner、@dougmitarotonda、@dpatschke、@duncandonutz、@EdFineOKL、@EDiLD、@eipi10、@elegrand、@EmilRehnberg、

Eric C. Anderson、@etb、@fabian-s、Facundo Muñoz、@flammy0530、@fpepin、Frank @Farach、@freezby、@fyears、Garrett Grolemund、@garrettgman、@gavinsimpson、@gggtest、GökçenEraslan、Gregg Whitworth、@gregorp、@gsee、@gsk3、@gthb、@hassaad85、@i、Iain Dillingham、@ijlyttle、Ilan Man、@imanuelcostigan、@initdch、Jason Asher、Jason Knight、@jasondavies、@jastingo、@jcborras、Jeff Allen、@jeharmse、@jentjr、@JestonBlu、@JimInNashville、@jinlong25、JJ Allaire、Jochen Van de Velde、Johann Hibschman、John Blischak、John Verzani、@johnbaums、@johnjosephhorton、Joris Muller、Joseph Casillas、@juancentro、@kdauria、@kenahoo、@kent37、Kevin Markham、Kevin Ushey、@kforner、Kirill Müller、Kun Ren、Laurent Gatto、@Lawrence-Liu、@ldfmrails、@lgatto、@liangcj、Lingbing Feng、@lynaghk、Maarten Kruijver、Mamoun Benghezal、@mannyishere、Matt Pettis、@mattbaggott、Matthew Grogan、@mattmalin、Michael Kane、@michaelbach、@mjsduncan、@Mullefa、@myqlarson、Nacho Caballero、Nick Carchedi、@nstjhp、@ogennadi、Oliver Keyes、@otepoti、Parker Abercrombie、@patperu、Patrick Miller、@pdb61、@pengyu、Peter F Schulam、Peter Lindbrook、Peter Meilstrup、@philchalmers、@picasa、@piccolbo、@pierreroudier、@pooryorick、R. Mark Sharp、Ramnath Vaidyanathan、@ramnathv、@Rappster、Ricardo Pietrobon、Richard Cotton、@richardreeve、@rmflight、@rmsharp、Robert M Flight、@RobertZK、@robiRagan、Romain François、@rrunner、@rubenfcasal、@sailingwave、@sarunasmerkliopas、@sbgraves237、Scott Ritchie、@scottko、@scottl、Sean Anderson、Sean Carmody、Sean Wilkinson、@sebastian-c、Sebastien Vigneau、@shabbychef、Shannon Rush、Simon O'Hanlon、Simon Potter、@SplashDance、@ste-fan、Stefan Widgren、@stephens999、Steven Pav、@strongh、@stuttungur、@surmann、@swnydick、@taekyunk、Tal Galili、@talgalili、@tdenes、@Thomas、@thomasherbig、@thomaszumbrunn、Tim Cole、@tjmahr、Tom Buckley、Tom Crockett、@ttriche、@twjacobs、@tyhenkaline、@tylerritchie、@ulrichatz、@varun729、@victorkryukov、@vijaybarve、@vzemlys、@wchi144、@wibeasley、@WilCrofter、William Doane、Winston Chang、@wmc3、@wordnerd、Yoni Ben-Meshulam、@zackham、@zerokarmaleft、Zhongpeng Lin。

1.7 约定

在本书中 `f()` 代表函数，`g` 代表变量和函数参数，`h/` 代表路径。

大的代码块包含输入和输出。输出已经被注释掉了，所以如果你有本书的电子版，例如，http://adv-r.had.co.nz，你就可以很简单将例子复制并粘贴到 R 中。为了与正常的注释相区别，将注释输出的注释符设定为 `#>`。

1.8 声明

本书是在 Rstudio（http://www.rstudio.com/ide/）中使用 Rmarkdown（http://rmarkdown.rstudio.com/）编写的。使用 knitr（http://yihui.name/knitr）和 pandoc（http://johnmacfarlane.net/pandoc/）将原始的 Rmarkdown 转换成 html 和 pdf 。本书的网站（http://adv-r.had.