

HZ BOOKS
华章科技

10余位数据挖掘领域资深专家和科研人员，10余年大数据挖掘咨询与实施经验结晶。本书注重易用性和实践性，旨在让读者快速掌握运用Python语言进行数据分析与挖掘的方法，从应用层面讲解初学者最急切需要了解的功能，深入浅出地介绍了数据挖掘中常用的建模实现函数



技术丛书



Python and Data Mining

Python与数据挖掘

张良均 杨海宏 何子健 杨征◎等著



机械工业出版社
China Machine Press



技术丛书

Python and Data Mining

Python与数据挖掘

张良均 杨海宏 何子健 杨坦 杨征 陈婷婷 陈玉辉 施兴◎等著



机械工业出版社
China Machine Press

图书在版编目 (CIP) 数据

Python 与数据挖掘 / 张良均等著. —北京: 机械工业出版社, 2016.11
(大数据技术丛书)

ISBN 978-7-111-55261-1

I.P… II. 张… III. 软件工具—程序设计 IV. TP311.56

中国版本图书馆 CIP 数据核字 (2016) 第 260795 号

Python 与数据挖掘

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: 李 艺

责任校对: 殷 虹

印 刷: 北京市荣盛彩色印刷有限公司

版 次: 2016 年 11 月第 1 版第 1 次印刷

开 本: 186mm×240mm 1/16

印 张: 11.75

书 号: ISBN 978-7-111-55261-1

定 价: 49.00 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) 88379426 88361066

投稿热线: (010) 88379604

购书热线: (010) 68326294 88379649 68995259

读者信箱: hzit@hzbook.com

版权所有·侵权必究

封底无防伪标均为盗版

本书法律顾问: 北京大成律师事务所 韩光 / 邹晓东

为什么要写本书？

Python 是什么？

Python 是一种带有动态语义的、解释性的、面向对象的高级编程语言。其高级内置数据结构，结合动态类型和动态绑定，使其对于敏捷软件开发非常具有吸引力。同时，Python 作为脚本型（胶水）语言连接现有的组件也十分高效。Python 语法简洁，可读性强，从而能降低程序的维护成本。不仅如此，Python 支持模块和包，鼓励程序模块化和代码重用。

Python 语言的解释性使其语法更接近人类的表达和思维过程，开发程序的效率极高。习惯使用 Python 者，总习惯在介绍 Python 时强调一句话：“人生苦短，我用 Python。”由于没有编译步骤，“写代码—测试—调试”的流程能被快速地反复执行。

作为一款用途广泛的语言，Python 在数据分析与机器学习领域的表现，称得上“一任群芳妒”。2016 年 3 月，国外知名技术问答社区 StackOverflow 发布了《2016 年开发者调查报告》。此调查号称是有史以来最为全面的开发者调查。其中，数据科学家的十大技术栈中，有 7 个包含 Python。具体来说，数据科学家中有 63% 正在使用 Python，44% 正在使用 R 语言。而且，27% 的人同时使用这两种语言。Python 还在“最多人使用的技术”“最受欢迎技术”“需求度最高技术”等榜单中名列前茅。

Python 的明显优势：

- Python 作为一款优雅、简洁的开源编程语言，吸引了世界各地顶尖的编程爱好者的注意力。每天都有数量众多的开源项目更新自己的功能，作为第三方模块为其他开发者提供更加高效、便利的支持。
- Python 提供了丰富的 API 和工具，以便程序员能够轻松地使用 C、C++、Cython 来编写扩充模块，从而集成多种语言的代码，协同工作。一些算法在底层用 C 实现后，封装在 Python 模块中，性能非常高效。
- Python 受到世界各地开发者的一致喜爱，在世界范围内被广泛使用。这意味着读者可以通过查看代码范例，快速学习和掌握相关内容。
- Python 语言简单易学，语法清晰。Python 开发者的哲学是“用一种方法，最好是只有一种方法来做一件事”。通常，相较其他语言，Python 的源代码被认为具有更好的可读性。

2004 年，Python 已在 Google 内部使用，他们的宗旨是：Python where we can, C++ where we must，即在操控硬件的场合使用 C++，在快速开发时使用 Python。

总的来说，Python 是一款用于数据统计、分析、可视化等任务，以及机器学习、人工智能等领域的高效开发语言。它能满足几乎所有数据挖掘下所需的数据处理、统计模型和图表绘制等功能需求。大量的第三方模块所支持的内容涵盖了从统计计算到机器学习，从金融分析到生物信息，从社会网络分析到自然语言处理，从各种数据库各种语言接口到高性能计算模型等领域。随着大数据时代的来临，数据挖掘将更加广泛地渗透到各行各业中去，而 Python 作为数据挖掘里的热门工具，将会有更多不同行业的人加入到 Python 爱好者的行列中来。完全面向对象的 Python 的教学工作也将成为高校中数学与统计学专业的重点发展对象，这是大数据时代下的必然趋势。

本书特色

笔者从实际应用出发，结合实际例子及应用场景，深入浅出地介绍 Python 开发环境的搭建、Python 基础入门、函数、面向对象编程、实用模块和图表绘制及常用的建模算法在 Python 中的实现方式。本书的编排以 Python 语言的函数应用为主，先介绍了函数

的应用场景及使用格式，再给出函数的实际使用示例，最后对函数的运行结果做出了解释，将掌握函数应用的所需知识点按照实际使用的流程展示出来。

为方便读者理解 Python 语言中相关函数的使用，本书配套提供了书中使用的示例的代码及所用的数据，读者可以从“泰迪杯”全国数据挖掘挑战赛网站（<http://www.tipdm.org/ts/755.jhtml>）上免费下载。读者也可通过热线电话（40068-40020）、企业 QQ（40068-40020）或以下微信公众号咨询获取。



TipDM



张良均〈大数据挖掘产品与服务〉

本书适用对象

□ 开设有数据挖掘课程的高校教师和学生。

目前国内不少高校将数据挖掘引入本科教学中，在数学、计算机、自动化、电子信息、金融等专业开设了数据挖掘技术相关的课程，但目前这一课程的教学使用的工具仍然为 SPSS、SAS 等传统统计工具，并没有使用 Python 作为教学工具。本书提供了有关 Python 语言的从安装到使用的一系列知识，将能有效指导高校教师和学生使用 Python。

□ 数据挖掘开发人员。

这类人员可以在理解数据挖掘应用需求和设计方案的基础上，结合本书提供的 Python 的使用方法快速入门并完成数据挖掘应用的编程实现。

□ 进行数据挖掘应用研究的科研人员。

许多科研院所为了更好地对科研工作进行管理，纷纷开发了适应自身特点的科研业务管理系统，并在使用过程中积累了大量的科研信息数据。Python 可以提供一个优异的环境对这些数据进行挖掘分析应用。

□ 关注高级数据分析的人员。

Python 作为一个广泛用于数据挖掘领域的编程语言，能为数据分析人员提供快速的、可靠的分析依据。

如何阅读本书

本书主要分为两大部分，基础篇和建模应用篇。基础篇介绍了有关 Python 开发环境的搭建、Python 基础入门、函数、面向对象编程、实用模块和图表绘制等基础知识。建模应用篇主要介绍了目前数据挖掘中常用的建模方法在 Python 中的实现函数，并对输出结果进行了解释，有助于读者快速掌握应用 Python 进行分析挖掘建模的方法。读者可结合本书提供的示例代码及数据进行上机实验，快速掌握书中所介绍的 Python 的使用方法。

第一部分是基础篇（1～6 章）。第 1 章旨在让读者从全局把握数据挖掘、常用工具对比、Python 开发环境的搭建以及本书的写作习惯；第 2 章正式开始讲解 Python 的基础知识，包括操作符、变量类型、流程控制、数据结构等内容；第 3、4 章主要对 Python 面向对象的特性进行介绍，包括函数、类与对象等基本概念；第 5 章介绍主流的数据分析与挖掘的模块，以及其中具体的方法及对应的功能，旨在让读者对各个模块建立强大的直觉；第 6 章继续拓展了模块的相关内容，提及图表绘制的专用模块（Matplotlib 和 Bokeh），深入浅出地展示如何方便地绘制点、线、图等。

第二部分是建模应用篇（7～11 章）。本部分主要对数据挖掘中的常用算法进行介绍，强调在 Python 中对应函数的使用方法及其结果的解释说明。内容涵盖五大主流的数据挖掘算法，包括分类与预测、聚类分析建模、关联规则分析、智能推荐和时间序列分析。按照模型建立至模型评价的架构进行介绍，使读者能熟练掌握从建模到对模型评价的完整建模过程。

勘误和支持

除封面署名外，参加本书编写工作的还有杨坦、刘名军、陈婷婷、陈玉辉、施兴、

黄博、王路、黄东鑫等。由于水平有限，编写时间仓促，书中难免会出现一些错误或者不准确的地方，恳请读者批评指正。本书内容的更新将及时在“泰迪杯”全国数据挖掘挑战赛网站（www.tipdm.org）上发布。读者可通过作者微信公众号 TipDM（微信号：TipDataMining）、TipDM 官网（www.tipdm.com）反馈有关问题。也可通过热线电话（40068-40020）或企业 QQ（40068-40020）进行咨询。

如果您有更多的宝贵意见，欢迎发送邮件至邮箱 13560356095@qq.com，期待能够得到您的真挚反馈。

致谢

本书编写过程中得到了广大高校师生的大力支持！在此谨向华南农业大学、华南师范大学、广东工业大学、广东技术师范学院、华南理工大学、韩山师范学院、中山大学、贵州师范学院等单位给予支持的领导及师生致以深深的谢意。

在本书的编辑和出版过程中还得到了参与“泰迪杯”全国数据挖掘挑战赛（<http://www.tipdm.org>）的众多师生及机械工业出版社杨福川老师无私的帮助与支持，在此一并表示感谢。

张良均

目录 Contents

前言

第一部分 基础篇

第1章 数据挖掘概述	2	2.1.2 赋值操作符	17
1.1 数据挖掘简介	2	2.1.3 比较操作符	18
1.2 工具简介	3	2.1.4 逻辑操作符	18
1.2.1 WEKA	3	2.1.5 操作符优先级	18
1.2.2 RapidMiner	4	2.2 数字数据	19
1.2.3 Python	5	2.2.1 变量与赋值	19
1.2.4 R	5	2.2.2 数字数据类型	20
1.3 Python 开发环境的搭建	6	2.3 流程控制	20
1.3.1 Python 安装	6	2.3.1 if 语句	21
1.3.2 Python 初识	11	2.3.2 while 循环	23
1.3.3 与读者的约定	14	2.3.3 for 循环	25
1.4 小结	15	2.4 数据结构	27
第2章 Python基础入门	16	2.4.1 列表	28
2.1 常用操作符	16	2.4.2 字符串	31
2.1.1 算术操作符	17	2.4.3 元组	35
		2.4.4 字典	36
		2.4.5 集合	39
		2.5 文件的读写	40
		2.5.1 改变工作目录	40
		2.5.2 txt 文件读取	41
		2.5.3 csv 文件读取	42
		2.5.4 文件输出	43


2.5.5	使用JSON处理数据	43
2.6	上机实验	44
第3章	函数	47
3.1	创建函数	48
3.2	函数参数	50
3.3	可变对象与不可变对象	52
3.4	作用域	53
3.5	上机实验	55
第4章	面向对象编程	56
4.1	简介	56
4.2	类与对象	58
4.3	__init__方法	59
4.4	对象的方法	61
4.5	继承	65
4.6	上机实验	68
第5章	Python实用模块	69
5.1	什么是模块	69
5.2	NumPy	70
5.3	Pandas	75
5.4	SciPy	81
5.5	scikit-learn	84
5.6	其他Python常用模块	87
5.7	小结	88
5.8	上机实验	88
第6章	图表绘制入门	89
6.1	Matplotlib	89

6.2	Bokeh	94
6.3	其他优秀的绘图模块	97
6.4	小结	97
6.5	上机实验	97

第二部分 建模应用篇

第7章	分类与预测	100
7.1	回归分析	100
7.1.1	线性回归	101
7.1.2	逻辑回归	104
7.2	决策树	107
7.2.1	ID3算法	107
7.2.2	其他树模型	111
7.3	人工神经网络	113
7.4	kNN算法	122
7.5	朴素贝叶斯分类算法	124
7.6	小结	127
7.7	上机实验	127
第8章	聚类分析建模	129
8.1	K-Means聚类分析函数	129
8.2	系统聚类算法	133
8.3	DBSCAN聚类算法	138
8.4	上机实验	142
第9章	关联规则分析	144
9.1	Apriori关联规则算法	145
9.2	Apriori在Python中的实现	146

9.3 小结	149	10.4 上机实验	157
9.4 上机实验	149	第11章 时间序列分析	159
第10章 智能推荐	151	11.1 ARIMA 模型	159
10.1 基于用户的协同过滤算法	152	11.2 小结	171
10.2 基于用户的协同过滤算法在 Python 中的实现	154	11.3 上机实验	172
10.3 小结	157	参考文献	174



Part 1

第一部分

基础篇

- 第1章 数据挖掘概述
 - 第2章 Python基础入门
 - 第3章 函数
 - 第4章 面向对象编程
 - 第5章 Python实用模块
 - 第6章 图表绘制入门
- 

数据挖掘概述

广义的数据挖掘是指针对收集的大规模数据，应用整套科学工具和挖掘技术（如数据、计算、可视化、分析、统计、实验、问题定义、建模与验证等），从数据之中发现隐含的、对决策有参考意义的信息、价值和趋势。因此，数据挖掘是一个横跨多学科的计算机科学分支。强调它隶属计算机科学范畴，是希望读者认识到这个领域的核心需求，尽早摆脱对编程实现的恐惧，避免陷入“数据挖掘只需将模型或算法套用于数据集之上”的误区。这也是本书的写作目的之一。

1.1 数据挖掘简介

随着计算机技术的全面发展，企业生产、收集、存储和处理数据的能力大大提高，数据量与日俱增。数据的积累实质上是企业的经验和业务的沉淀。越来越多的企业引入“数据思维”——不只是依赖于数据的统计分析，更强调对数据进行挖掘，期待从这一“未来世界的石油”中发现潜在的价值。这一迫切的“开采”需求在世界范围内酝酿了一次“大数据”变革。

数据挖掘的确是 21 世纪最具话题性的技术之一，包含数据预处理、算法应用、模型评价、结果检验等多个部分，并依靠其丰富的内涵向外延伸出数据分析、数据 ETL、机

器学习等多个领域。

1.2 工具简介

数据挖掘软件的历史并不长，甚至连“数据挖掘”这个术语也是在 19 世纪 90 年代中期才正式被提出。如今，商用数据挖掘软件和开源工具都已经非常成熟，不仅提供易用的可视化界面，还集成了数据处理、建模、评估等一整套功能。

部分开源的数据挖掘软件，采用可视化编程的设计思路。之所以这么做，是因为它能够足够灵活和易用，更适合缺乏计算机科学知识的用户，如 WEKA 和 RapidMiner。

当用户拥有较多特定的分析需求，或正在自行实现一个改进的机器学习算法时，脚本型语言如 Python 和 R 将更符合需要。同时，脚本型语言兼具运行效率和开发效率，支持敏捷型的迭代更新。

1.2.1 WEKA

用 Java 编写的 WEKA 是一款知名的数据挖掘工作平台，它因解决数据挖掘任务的实际需求而生，集成了大量能处理数据挖掘任务的机器学习算法，这些算法能被用户直接应用于数据集之上。同时，WEKA 允许开发者使用 Java 语言，调用其分析组件，基于 WEKA 的架构进行二次开发，融入更多的数据挖掘算法，并嵌入到软件或者应用之中，自动完成数据挖掘任务，开发新的机器学习框架。

WEKA 支持多种标准数据挖掘任务，包括数据预处理，分类、回归分析、聚类、关联规则等算法的应用，以及特征工程和可视化。其欢迎界面如图 1-1 所示。




图 1-1 WEKA 欢迎界面

1.2.2 RapidMiner

RapidMiner 的目标是：“成为一个能将数据变成宝贵的战略资产的现代平台”，已被广泛使用于商业应用、学术研究、教育、敏捷开发等领域。

RapidMiner 是一个支持数据挖掘、文本挖掘、机器学习、商业分析等任务的集成环境，如图 1-2 所示。其图形化界面采用了类似 Windows 资源管理器中的树状结构来组织分析组件，提供 500 多种分析组件作为计算单元（Operator），服务于数据挖掘的各个阶段，如数据预处理、变换、探索、建模、评估及结果可视化。这些计算单元有详细的 XML 文件记录。

RapidMiner 是基于 WEKA 二次开发的应用，这意味着它可以调用 WEKA 中的各种分析组件。




图 1-2 RapidMiner Studio 工作界面

1.2.3 Python

Python 是一门编程语言。随着 NumPy、SciPy、Matplotlib 和 Pandas 等众多程序库的开发, Python 在科学计算和数据分析领域占据着越来越重要的地位。在大多数数据任务上, Python 的运行效率已经可以媲美 C/C++ 语言。2016 年 2 月 11 日, 科学家宣布: 人类在去年 9 月首次直接探测到了引力波! 引力波高峰只持续了四分之一秒, 同时仪器接收了大量干扰噪声, 需要处理的数据量以 TB 计, 如图 1-3 所示。其中, Python 的 GWPY 模块提供专业的数据分析支持。




图 1-3 利用公开引力波数据绘制波形图

1.2.4 R

R 语言是一种为统计计算和图形显示而设计的语言环境, 是贝尔实验室 (Bell Laboratory) 的 Rick Becker、John Chambers 和 Allan Wilks 开发的 S 语言的一种实现, 包含一系列统计与图形显示工具, 如图 1-4 所示。它是由一个庞大且活跃的 global 研究社区维护, 主要包括核心的标准包和各个专业领域的第三方包, 提供丰富的统计分析和数据挖掘功能。

R 语言至少拥有以下优势: ①方便地从各种类型的数据源中获取数据; ②高可拓展性; ③出色的统计计算功能; ④顶尖水准的制图功能; ⑤不断贡献强大功能的开源社区。它与 Python 同属数据挖掘主流编程语言, 而从功能与代码风格的角度来评价, R 与 MATLAB 是最像的。




图 1-4 R-Studio 工作界面

1.3 Python 开发环境的搭建

所谓编程语言，意指“与计算机交流时使用的语言”。它是一种被标准化的交流技巧，用于连接程序员的思维和计算机的操作。学习编程语言的第一关，就是安装和环境配置。我们必须与计算机约定如何理解代码、指令和语法，才能够顺利地计算机交流，赋予它复杂的功能。Python 便是其中的一种“方言”。

本节将向大家详细介绍，如何在不同的操作系统上快捷地使用 Python 进行编程实现。

1.3.1 Python 安装

对于新手，Python 及其第三方模块在安装环节有许多已知的难题。比如源码编译的