



[PACKT]
PUBLISHING

■ ■ ■ 智能系统与技术丛书

Designing Machine Learning Systems with Python

机器学习系统设计 Python语言实现

[美] 戴维·朱利安 (David Julian) 著

李洋 译



机械工业出版社
China Machine Press

Designing Machine Learning Systems with Python

机器学习系统设计 Python语言实现

[美] 戴维·朱利安 (David Julian) 著

李洋 译



机械工业出版社
China Machine Press

图书在版编目 (CIP) 数据

机器学习系统设计：Python 语言实现 / (美) 戴维·朱利安 (David Julian) 著；李洋译。
—北京：机械工业出版社，2017.5
(智能系统与技术丛书)

书名原文：Designing Machine Learning Systems with Python

ISBN 978-7-111-56945-9

I. 机… II. ①戴… ②李… III. 机器学习－系统设计 IV. TP181

中国版本图书馆 CIP 数据核字 (2017) 第 096698 号

本书版权登记号：图字：01-2017-0486

David Julian: *Designing Machine Learning Systems with Python* (ISBN: 978-1-78588-295-1).

Copyright © 2016 Packt Publishing. First published in the English language under the title “Designing Machine Learning Systems with Python”.

All rights reserved.

Chinese simplified language edition published by China Machine Press.

Copyright © 2017 by China Machine Press.

本书中文简体字版由 Packt Publishing 授权机械工业出版社独家出版。未经出版者书面许可，不得以任何方式复制或抄袭本书内容。

机器学习系统设计：Python 语言实现

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：陈佳媛

责任校对：殷 虹

印 刷：三河市宏图印务有限公司

版 次：2017 年 6 月第 1 版第 1 次印刷

开 本：186mm×240mm 1/16

印 张：12.5

书 号：ISBN 978-7-111-56945-9

定 价：59.00 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

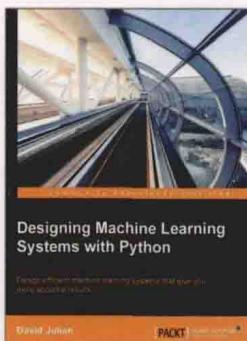
封底无防伪标均为盗版

本书法律顾问：北京大成律师事务所 韩光 / 邹晓东

内容简介

本书介绍了机器学习系统设计的整个过程，以及相关的Python库，并在各个知识环节中都给出了Python示例，为设计高效机器学习系统提供详实指南。

本书共9章，第1章介绍机器学习的设计原理和相关模型；第2章讲解Python中众多针对机器学习任务的程序包；第3章涵盖大数据、数据属性、数据源、数据处理和分析等主题，介绍基本的数据类型、结构和属性；第4章探索最常见的机器学习模型，即逻辑模型、树状模型和规则模型；第5章研究机器学习最常用的技术，创建线性回归和Logistic回归的假设语句；第6章介绍人工神经网络算法；第7章讨论特征的不同类型，即定量特征、有序特征和分类特征，以及如何结构化和变换特征；第8章介绍主要的集成方法及其在Scikit-learn中的实现；第9章介绍模型选择和参数调优技术，并将这些技术应用于一些案例研究之中。



原书封面

作者简介

戴维·朱利安（David Julian）数据分析师、信息系统咨询顾问和培训讲师。他目前正致力于Urban Ecological Systems和Blue Smart Farms (<http://www.bluesmartforms.com.au>) 的机器学习项目，该项目旨在发现和预测温室作物虫害。

华章 IT
HZBOOKS | Information Technology



译者序

2016年，对于计算机相关从业者（和职业围棋手）而言，毋庸置疑，最具冲击力的大事件就是AlphaGo的成功了。对此，即便是如我本人这样最迟钝的计算机工程师，也终于不能无动于衷，感觉是时候跳出if-else的懒惰，捡起尘封多年乃至遗忘的线性规划和微积分等知识，投身于人工智能的汪洋了。历经60载的孕育，人工智能的时代终于到来了。

回想起本世纪初，我曾参与了电信公司的一个营销项目，这个项目的目标是建立一系列客户指标，以反映客户的价值和分类，使营销人员能够进行精准营销和客户关怀。对于这个项目，当时的术语是，数据仓库和集市，旋转、切片、透视等统计分析，分类和聚类等数据挖掘，等等。当工作作风一向是直接有效（简单粗暴）的市场营销专家，了解到数据仓库和统计工具软硬件的昂贵、数据挖掘工作的繁杂之后，他们提出直接拿一套指标变量和决策阈值，然后用if-else来决定对付客户的营销手段。好吧，指标变量还好，但是优化的决策边界怎么拿？最终，一份虚构臆想的报告出炉了，对此，我至今仍怀有深深的罪恶感。

如今，市场营销的专家作风依旧吧？但是，即便是初出茅庐（大有可为）的软件工程师，也完全能够用触手可得的开源工具和计算环境，建立起一个机器学习系统，获得一些令人信服的决策边界优化解，让那些令人哭笑不得的推销短信变得更少，让短信垃圾成为雪中送炭，想要获取信息的人们无须再从一些衣冠楚楚、侃侃而谈的顾问手里购买一纸空洞的报告了。这就是人工智能的时代，在自动驾驶成为投资大鳄眼中的香饽饽时，人工智能已经无所不在了。本书也是如此，对于计算机科学专业的小伙伴们来说，书中的内容都不陌生，但当这些都成为随手可得、随时要用的东西时，就证明了我们已经身

处其时。

本书涵盖了建立机器学习系统的方方面面，相对比较基础，其中最有价值的是，书中介绍了机器学习系统设计的整个过程，以及相关的 Python 库，并在各个知识环节中都给出了 Python 示例。无论对于机器学习系统的新兵还是老手，本书都有一定的参考价值。对于机器学习系统的初学者而言，本书较为系统地介绍了相关知识，同时也在一开始就给出了语言和环境，能够让大家甩开膀子，撸起袖子，伸手开干；而对于机器学习系统的老手而言，其更多的参考价值在于如何使用 Python 来实现那些概念。

但需要注意的是，本书绝不是机器学习的学科教材，也不是 Python 库的用户手册，更不是实际项目的设计文档。因此，本书并没有对各种模型提供完整的解释和严格的推导，也没有对 Python 库的各种对象和函数提供完整详尽的说明，更不会对实际问题给出详细的解决方案和实现。但本书确实是一个简明的指引，并富有逻辑，让我们能够按图索骥，由此及彼，较为系统地了解 Python 机器学习系统设计的方方面面，并以此为线索，展开更多的阅读和深入的学习。同时，书中的诸多示例也能在一定程度上为我们解决类似问题提供思路。

在人工智能的时代，翻译一本机器学习的书籍，对译者而言也是幸甚至哉，借此与各路志士同仁共勉。

李洋

2017 年 2 月

前　　言

机器学习是计算世界所见的最大趋势之一。机器学习系统具有意义深远且令人兴奋的能力，能够在各种应用领域为人们提供重要的洞察力，从具有开创性的挽救生命的医学研究到宇宙基础物理方面的发现，从为我们提供更健康、更清洁的食物到互联网分析和建立经济模型，等等。事实上，就某种意义而言，这项技术在我们的生活中已经无所不在。要想进入机器学习的领域，并且对其具有充分的认知，就必须能够理解和设计服务于某一项目需要的机器学习系统。

本书的主要内容

第1章从机器学习的基础知识开始，帮助你用机器学习的范式进行思考。你将学到机器学习的设计原理和相关模型。

第2章讲解了Python中众多针对机器学习任务的程序包。本章会让你初步了解一些大型库，包括NumPy、SciPy、Matplotlib和Scikit-learn等。

第3章讲解了原始数据可能有多种不同格式，其数量和质量也可能各不相同。有时，我们会被数据淹没；而有时，我们希望从数据中榨取最后一滴信息。数据要成为信息，需要有意义的结构。本章我们介绍了一些宽泛的主题，如大数据、数据属性、数据源、数据处理和分析等。

第4章在逻辑模型中探索了逻辑语言，并创建了假设空间映射；在树状模型中，我们发现其具有广泛作用域并易于描述和理解；在规则模型中，我们讨论了基于有序规则列表和无序规则集的模型。

第 5 章介绍了线性模型，它是使用最广泛的模型之一。线性模型是众多高级非线性技术的基础，例如，支持向量机（SVM）和神经网络。本章还研究了机器学习最常用的技术，创建线性回归和 logistic 回归的假设语句。

第 6 章介绍了机器学习最强大的人工神经网络算法。我们将看到这些网络如何成为大脑神经元的简化模型。

第 7 章讨论了特征的不同类型，即定量特征、有序特征和分类特征。我们还将详细学习如何结构化和变换特征。

第 8 章解释了集成机器学习背后的动机和成因，其来源于清晰的直觉并具有丰富的理论历史基础。集成机器学习的类型在于模型本身，以及围绕着三个主要问题（如何划分数据、如何选择模型、如何组合其结果）的考量。

第 9 章着眼于一些设计策略，以确保你的机器学习系统最优。我们将学习模型选择和参数调优技术，并将所学知识应用于一些案例研究之中。

阅读前的准备工作

你需要有学习机器学习的意愿，并需要下载安装 Python 3。Python 3 的下载地址是：<https://www.python.org/downloads/>。

本书的读者对象

本书的读者包括数据学家、科学家，或任何好奇的人。你需要具备一些线性代数和 Python 编程的基础，对机器学习的概念有基本了解。

CONTENTS

目 录

译者序	2.9 总结	57
前言		
第1章 机器学习的思维	3.1 什么是数据	58
1.1 人机界面	3.2 大数据	59
1.2 设计原理	3.2.1 大数据的挑战	60
1.2.1 问题的类型	3.2.2 数据模型	62
1.2.2 问题是否正确	3.2.3 数据分布	63
1.2.3 任务	3.2.4 来自数据库的数据	67
1.2.4 统一建模语言	3.2.5 来自互联网的数据	68
1.3 总结	3.2.6 来自自然语言的数据	70
第2章 工具和技术	3.2.7 来自图像的数据	72
2.1 Python 与机器学习	3.2.8 来自应用编程接口的数据	72
2.2 IPython 控制台	3.3 信号	74
2.3 安装 SciPy 栈	3.4 数据清洗	76
2.4 NumPy	3.5 数据可视化	78
2.4.1 构造和变换数组	3.6 总结	80
2.4.2 数学运算		
2.5 Matplotlib	第4章 模型——从信息中学习	81
2.6 Pandas	4.1 逻辑模型	81
2.7 SciPy	4.1.1 一般性排序	83
2.8 Scikit-learn	4.1.2 解释空间	84
	4.1.3 覆盖空间	86

4.1.4 PAC 学习和计算复杂性	87
4.2 树状模型	88
4.3 规则模型	92
4.3.1 有序列表方法	94
4.3.2 基于集合的规则模型	95
4.4 总结	98
第 5 章 线性模型	100
5.1 最小二乘法	101
5.1.1 梯度下降	102
5.1.2 正规方程法	107
5.2 logistic 回归	109
5.3 多分类	113
5.4 正则化	115
5.5 总结	117
第 6 章 神经网络	119
6.1 神经网络入门	119
6.2 logistic 单元	121
6.3 代价函数	126
6.4 神经网络的实现	128
6.5 梯度检验	133
6.6 其他神经网络架构	134
6.7 总结	135
第 7 章 特征——算法眼中的世界	136
7.1 特征的类型	137
7.1.1 定量特征	137
7.1.2 有序特征	138
7.1.3 分类特征	138
7.2 运算和统计	139
7.3 结构化特征	141
7.4 特征变换	141
7.4.1 离散化	143
7.4.2 归一化	144
7.4.3 校准	145
7.5 主成分分析	149
7.6 总结	151
第 8 章 集成学习	152
8.1 集成学习的类型	152
8.2 Bagging 方法	153
8.2.1 随机森林	154
8.2.2 极端随机树	155
8.3 Boosting 方法	159
8.3.1 AdaBoost	161
8.3.2 梯度 Boosting	163
8.4 集成学习的策略	165
8.5 总结	168
第 9 章 设计策略和案例研究	169
9.1 评价模型的表现	169
9.2 模型的选择	174
9.3 学习曲线	176
9.4 现实世界中的案例研究	178
9.4.1 建立一个推荐系统	178
9.4.2 温室虫害探测	185
9.5 机器学习一瞥	188
9.6 总结	190

CHAPTER I

第 1 章

机器学习的思维

机器学习系统具有意义深远且令人兴奋的能力，能够在各种应用领域为人们提供重要的洞察力；从具有开创性的挽救生命的医学研究到宇宙基础物理方面的发现，从为我们提供更健康、更清洁的食物到互联网分析和建立经济模型，等等。事实上，就某种意义而言，这项技术在我们的生活中已经无所不在。物联网的蔓延正产生着惊人的数据量，很显然，智能系统正以相当剧烈的方式改变着社会。Python 及其库等开源工具，以及以 Web 为代表的越来越多的开源知识库，使学习和应用这门技术有了新的和令人兴奋的途径，也使学习过程更为容易和廉价。本章将涵盖如下主题：

- 人机界面
- 设计原理
- 模型
- 统一建模语言

1.1 人机界面

如果你有幸用过微软 Office 套件的早期版本，你大概还能记得 Mr Clippy 办公助手。这一功能出现在 Office 97 中，每当你在文档开头输入“亲爱的”，它就会不请自来，从电脑屏幕的右下角蹦出来，询问“你好像在写信，需要帮助吗？”

在 Office 的早期版本中，Mr Clippy 是默认开启的，几乎被所有软件用户嘲笑过，这可以作为机器学习的第一次大败笔而载入史册。

那么，为什么这个欢乐的 Mr Clippy 会如此遭人痛恨呢？在日常办公任务中使用自动化助手不一定是个坏主意。实际上，自动化助手的后期版本，至少是最好的那几个，可以在后台无缝运行，并能明显提高工作效率。文本预测有很多例子，有些很搞笑，大错特错，但大多数并没有失败，它们悄无声息，已经成为我们正常工作流的一部分。

在这一点上，我们需要区分错误和失败的不同。Mr Clippy 的失败是因为它的突兀和差劲的设计，而它的预测并不一定是错误的；也就是说，它可能给出了正确的建议，但那时你已经知道你正在写一封信件。文本预测的错误率很高，经常会得出错误的预测，但这并没有失败，主要是因为它的失败方式被设计为悄无声息的。

设计任何与人机界面紧耦合（系统工程的说法）的系统都很困难。与一般的自然界事物一样，我们并非总能预测人类行为。表情识别系统、自然语言处理和手势识别技术等，开启了人机交互的新途径，对机器学习专家而言，所有这些都具有重要的应用。

每当设计需要人机输入的系统时，我们应当预见所有可能的人机交互方式，而不仅仅是我们在所期望的那些方式。在本质上，我们对这些系统试图要做的是，培养它们对人类经验全景的一些理解。

在 Web 的早期，搜索引擎使用的是一种简单的系统，以文章中出现搜索条件的次数为基础。很快，Web 开发者就通过增加关键词与搜索引擎展开了博弈。显然，这将导致一场围绕关键词的竞赛，Web 将变得极为烦人。随后，为了提供更为准确的搜索结果，人们又设计了度量优质引用链接的页面排名系统。而今，现代搜索引擎都使用了更为复杂和秘密的算法。

对机器学习设计师同样重要的是，人机交互中所产生的数据量一直在增长。这会带

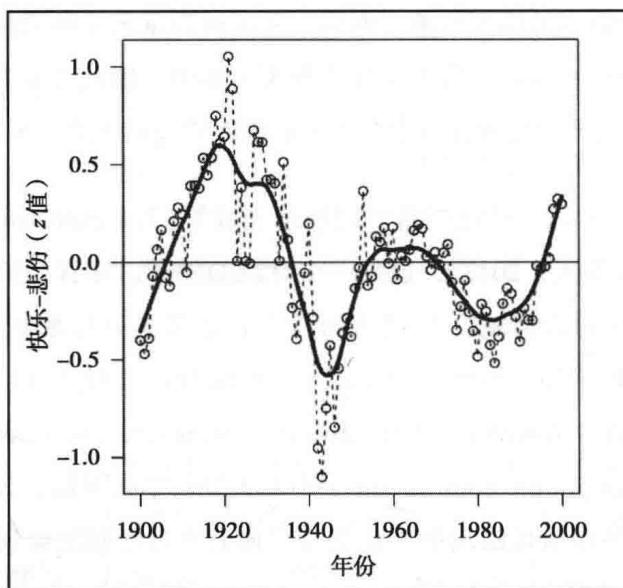
来诸多挑战，尤其是数据的庞大浩瀚。然而，算法的力量正是在于从海量数据中提取知识和洞察力，这对于较小规模的数据集几乎是不可能的。因此，如今大量的人机交互被数字化，而我们才刚刚开始理解和探索其中的数据能够被利用的众多途径。

有项研究的题目为《20世纪书籍中的情绪表现》(*The expression of emotion in 20th century books*, Acerbi 等人, 2013)，这是一个有趣的例子。尽管严格地说，该研究属于数据分析而非机器学习，但就一些理由而言，它还是具有说明性的。该研究的目的是，从 20 世纪的书籍中抽取情绪内容文本，以情绪分值的形式进行图表化。通过访问 Gutenberg 数字图书馆、WordNet (<http://wordnet.princeton.edu/wordnet/>) 和 Google 的 Ngram 数据库 (books.google.com/ngrams) 中的大量数字化书籍，该研究的作者能够绘制出 20 世纪文学作品中所反映出的文化变迁。他们通过绘制情绪词语使用的趋势来实现其研究目的。

在该研究中，作者对每个词语进行标记(1-gram 分词算法)，并与情绪分值和出版年份进行关联。诸如快乐、悲伤、恐惧等情绪词语，可以依据其表达的正面或负面情绪进行评分。情绪分值可以从 WordNet (wordnet.princeton.edu) 获得。WordNet 给每个情绪词语都赋予了情绪反应分值。最后，作者对每一情绪词语的出现次数进行了计数：

$$M = \frac{1}{n} \sum_{i=1}^n \frac{c_i}{C_{the}} M_z = \frac{M - \mu_M}{\sigma_M}$$

在此式中， c_i 表示特定情绪词语的计数， n 表示情绪词语的总数(不是所有词语，仅包括具有情绪分值的词语)， C_{the} 表示文本中 *the* 的计数。在归一化总和时，考虑到一些年份出版或数字化的书籍数量更多，同时晚期的书籍趋向于包含更多的技术语言，因此使用了词语 *the* 而不是所有词语的计数。对于在相当长的一段时期内的散文文本中的情绪，这种表示更为精确。最后，通过正态分布对分值进行归一化，即 M_z ，减去均值后除以标准差。



上图摘自《20世纪书籍中的情绪表现》(*The expression of emotion in 20th century books*, Alberto Acerbi, Vasileios Lampos, Phillip Garnett, R. Alexander Bentley) 美国科学公共图书馆。

这里，我们可以看到该项研究所生成的一张图表。该图显示了这一时期所著书籍的快乐 - 悲伤分值，从中可以明显看出二战时期的负面倾向。

这项研究之所以有趣，有如下一些原因。首先，它是一项数据驱动的科学研究所，在过去，类似的研究内容被认为是诸如社会学和人类学的软科学，但在该研究中，给出了坚实的实验基础。此外，尽管其研究结论令人印象深刻，但其实现过程相对容易。这主要得益于 WordNet 和 Google 已经完成的那些卓越努力。其亮点在于，如何使用互联网上免费的数据资源和软件工具，例如 Python 的数据和机器学习包等，任何具备数据技能和动机的人都能够从事这方面的研究。

1.2 设计原理

我们经常拿系统设计和其他事物的设计进行类比，例如建筑设计。在一定程度上，

这种类比是正确的，它们都是依据规格说明，在结构体中放置设计好的组件。但当我们考虑到它们各自的运行环境时，这种类比就会瓦解。在建筑设计上，通常会假设，当景观正确形成后就不会再改变。

软件环境则有些不同。系统是交互和动态的。我们设计的任何系统，诸如电子、物理，或人类，都会嵌入在其他系统中。同样，在计算机网络中有不同的层（应用层、传输层、物理层，等等），具有不同的含义和功能集，所以在项目中，需要在不同的层完成所需执行的活动。

作为这些系统的设计师，我们必须对其背景（即我们所工作的领域）具有强烈意识。领域知识能够赋予我们工作的背景，为我们在数据中发现模式提供线索。

机器学习项目可以分解为如下 6 项不同的活动：

- 定义目标和规格说明
- 准备和探索数据
- 建立模型
- 实现
- 测试
- 部署

设计师主要关注前三项活动。但是，他们通常需要在其他活动中扮演主要角色，并且在许多项目中必须如此。同时，这些活动在项目的时间表中不一定是线性序列。但重点是，这些都是明确不同的活动。这些活动可以并行进行，或者彼此相互作用，但通常会涉及不同类型的任务，在人力和其他资源、项目阶段和外在性上相互分离。而且，我们需要考虑到不同的活动所涉及的操作模式也彼此不同。想想看，我们在勾勒想法时、进行特定分析任务时，以及编写一段代码时，大脑工作方式的差异。

通常，最困难的是从何下手。我们可以先专研某一问题的不同要素，构思其中的特征集，或者考虑用什么模型。这样就能得出目标和规格说明的定义。或者我们可能不得