

Data Science and Big Data Analytics

Discovering, Analyzing, Visualizing and Presenting Data

EMC²

数据科学与大数据分析

数据的发现

分析 可视化与表示

[美] EMC Education Services 著

曹逾 刘文苗 李枫林 译

孙宇熙 主审



中国工信出版集团



人民邮电出版社
POSTS & TELECOM PRESS

Data Science and Big Data Analytics

Discovering, Analyzing, Visualizing and Presenting Data

EMC²

数据科学与大数据分析

数据的发现
分析 可视化与表示

[美] EMC Education Services 著

曹逾 刘文苗 李枫林 译

孙宇熙 主审



人民邮电出版社
北京

图书在版编目 (C I P) 数据

数据科学与大数据分析：数据的发现 分析 可视化与表示 / 美国EMC教育服务团队著；曹逾，刘文苗，李枫林译。—北京：人民邮电出版社，2016.7
ISBN 978-7-115-41637-7

I. ①数… II. ①美… ②曹… ③刘… ④李… III.
①数据处理 IV. ①TP274

中国版本图书馆CIP数据核字(2016)第019027号

版权声明

EMC Education Services

Data Science and Big Data Analytics: Discovering, Analyzing, Visualizing and Presenting Data

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，专有出版权属于人民邮电出版社。

版权所有，侵权必究。

◆ 著 [美] EMC Education Services
译 曹 逾 刘文苗 李枫林
主 审 孙宇熙
责任编辑 傅道坤
责任印制 焦志炜
◆ 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：800×1 000 1/16
印张：23.5 彩插：8
字数：515 千字 2016 年 7 月第 1 版
印数：1~3 000 册 2016 年 7 月北京第 1 次印刷
著作权合同登记号 图字：01-2015-2823 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




图 2.10 创新想法提交者和入围者的社交图谱 [27] 可视化




图 2.11 最具影响力创新者的社交图谱可视化




图 3.12 (a) 钻石价格密度图和 (b) 钻石价格对数密度图




图 3.13 用回归研究两个变量




图 3.14 点图用于可视化多个变量




图 3.15 通过条状图来可视化多个变量




图 3.16 箱线图表示中位数家庭收入和地理区域的关系




图 3.18 Fisher[13] 鸢尾属植物数据集的散点图矩阵




图 3.21 直方图更适合利益相关者查看




图 3.22 两个样本数据的分布




图 4.1 当 $k=3$ 时可能的 k 均值聚类簇

图 4.2 质心的初始起点




图 4.3 被关联到最近质心的点

图 4.4 计算每个簇的质心




图 4.6 识别出的学生聚类图




图 4.7 高度分离的簇示例




图 4.8 界限不那么明显的簇示例




图 4.9 把图 4.8 的点划分成 6 个簇




图 4.11 用厘米表示身高的聚类簇




图 4.12 用米表示身高的聚类簇




图 4.13 重新调整属性后的聚类簇




图 5.5 LHS 和 RHS 中的矩阵可视化，使用提升度和置信度进行了填色




图 6.17 用户数与估计的流失率的对比




图 7.7 一个过度拟合的模型，它在训练集上运行良好，但是对未见过的数据则表现糟糕




图 9.4 LDA 背后的直觉





图 9.5 10 个主题在 Cora 数据集中 9 篇科学文档上的分布



图 9.15 5 星评论（左图）和 1 星评论（右图）的 5 个主题



图 9.16 与 bPhone 相关的 tweet 的情感分析




关键点

实施一个早期的流失模型可以识别30%的可能流失的客户



图 12.12 数据科学项目的关键论点示例，以条形图显示

图 12.14 比较两个数据变量的模型细节



BigBox商店地图




图 12.18 以地图形式显示的 45 年开店数据




图 12.28 如何清理图形, 例 1 (清理之前)




图 12.29 如何清理图形——例 1 (清理之后)