



大数据技术与应用专业规划教材
教育部-阿里云产学合作专业综合改革项目规划教材

大数据 基础及应用



◎ 吕云翔 钟巧灵 衣志昊 编著



清华大学出版社



大数据技术与应用专业规划教材
教育部-阿里云产学合作专业综合改革项目规划教材

大数据 基础及应用

◎ 吕云翔 钟巧灵 衣志昊 编著



清华大学出版社
北京

内 容 简 介

本书从大数据的基本概念开始,由浅入深地领会大数据的精髓。本书除了讲述必要的大数据理论之外,还通过大数据实践来讲述大数据技术的应用,包括如何运用阿里云大数据计算平台分析和解决实际问题,很好地体现了大数据理论与实践的有机结合。

本书分为三大部分,分别是大数据概述及基础、大数据处理和大数据分析与应用。其中,大数据概述及基础部分重点介绍数据组织、重要数据结构、大数据协同技术以及大数据存储技术等内容;大数据处理部分重点介绍大数据处理框架,包括大数据批处理和流处理框架等内容;大数据分析与应用部分重点介绍数据分析技术和机器学习的相关内容,以及如何利用阿里云的数据加平台进行基本的大数据开发工作。

本书既可以作为高等院校计算机科学、软件工程及相关专业“大数据”课程的教材,也可以供系统分析师、系统架构师、软件开发工程师和项目经理,以及其他准备或正在学习大数据技术的读者(包括参加计算机等级考试或相关专业自学考试的人员)阅读和参考。

本书封面贴有清华大学出版社防伪标签,无标签者不得销售。

版权所有,侵权必究。侵权举报电话:010-62782989 13701121933

图书在版编目(CIP)数据

大数据基础及应用/吕云翔等编著. —北京: 清华大学出版社, 2017

(大数据技术与应用专业规划教材)

ISBN 978-7-302-46691-8

I. ①大… II. ①吕… III. 数据处理 IV. ①TP274

中国版本图书馆 CIP 数据核字(2017)第 038743 号

责任编辑: 魏江江 王冰飞

封面设计: 刘 键

责任校对: 焦丽丽

责任印制: 宋 林

出版发行: 清华大学出版社

网 址: <http://www.tup.com.cn>, <http://www.wqbook.com>

地 址: 北京清华大学学研大厦 A 座 邮 编: 100084

社 总 机: 010-62770175 邮 购: 010-62786544

投稿与读者服务: 010-62776969, c-service@tup.tsinghua.edu.cn

质 量 反 馈: 010-62772015, zhiliang@tup.tsinghua.edu.cn

课 件 下 载: <http://www.tup.com.cn>, 010-62795954

印 装 者: 清华大学印刷厂

经 销: 全国新华书店

开 本: 185mm×260mm 印 张: 15.75 字 数: 311 千字

版 次: 2017 年 3 月第 1 版 印 次: 2017 年 3 月第 1 次印刷

印 数: 1~2000

定 价: 39.50 元

产品编号: 072901-01

DT 时代的数据思维与智能思维

本套云计算大数据丛书出版正值信息科技领域进入新一轮巨变，中国经济面临转型机遇的特殊时期。全球信息科技行业伴随着云计算、大数据、物联网、人工智能的发展即将进入一个泛智能的时代，云计算成为数字经济的基础设施；数据驱动、泛在智能成为各行各业转型升级的基础，不仅传统的 IT 从业人员面临能力升级，大多数在校大学生也面临新一轮知识体系的更新，各个垂直行业面临新一轮的人才升级。新一代人才教育与培训，需要一套产学研一体的培训课程体系，这是阿里云愿意投身云计算大数据网络安全人才培养体系的时代背景。云计算、大数据、网络安全不仅关乎网络强国的大使命，也逐步成为各行各业专业人才的“元学科”，会逐步成为高等与职业教育的通识课程，一些发达国家已经在中小学立法普及编程课，已经开始指向这个趋势。“懂云计算，有数据思维，理解智能化”，未来可能是每一个工程技术人员与专业人士的必要素质。

2016 年开始，全球信息科技进入一个新的加速爆发周期，可能发生的大概率事件是：二十年之内，有一半的人类知识工作者会被人工智能替代，有服务能力的机器人会诞生，全世界的产业工人会少于机器人；虚拟现实和增强现实会替代今天的智能手机，变成一个新的入口；各行各业都会需要基于物联网的智能化，“中国制造”会成为广泛意义的“中国智造”。

新一轮科技带来了生活方式的变革、生产方式的变革，还有学习方式的变革，这几个趋势的背后，是云计算作为一种普惠科技的基础设施，大数据成为新能源，智能化成为一种新常识。

2016年,全世界的短视频总量增长了6倍,直播业务在中国增长了10倍,远在偏远小镇的青年可以通过直播做电子商务,转化率可以提升十倍以上。当一个技术的使用成本趋近于零的时候,会带来广泛的社会效应。十年以前的直播只有电视台能做,需要专门的摄像机等设备,而今天的直播只需要一个手机,而且是多对多带互动的。无论是短视频,还是直播,背后都有云计算作为普惠科技的支撑作用,由此带来的,所有与知识传播有关的教育,包括整个内容行业,都会被它改变,随着大数据和人工智能的加入,人类学习的方式交互性会更强,“学习系统”会根据不同人的理解程度做个性化的推荐与辅导。

这意味着知识生产与知识传播方式的根本性转变,这个恰恰是云计算、人工智能等科技与各行各业产生化学反应的交叉点,数据是这个转变的新能源。

在2016年10月,阿里云和法院系统合作,发布了一个面向法律服务的智能应用“法小淘”,通过把数千万份法律判例文本化,“法小淘”智能应用可以为普通老百姓以及初级律师提供“打官司”的咨询服务,根据用户输入的案件信息给出建议,包括推荐合适的律师。貌似与科技远离的法律服务也用上了人工智能,这是垂直行业泛智能化的一个小例子。

中国制造进入智能时代

在工业界,阿里云跟中石化合作,协助他们做了企业的电商平台;与徐工合作,推动工厂基于工业云的智能化;与上汽合作,推出具有智能服务的互联网汽车,都收到积极的市场反馈。中国制造,面临智能化的产业机遇,借助互联网人口和产业布局两大优势成为未来的第一智能产品制造国。

在接下来的几年,互联网+智能制造的叠加会在很多个垂直领域出现,数据智能与制造业结合,产生“跨界重混”的效果,甚至制造业就不是以制造为主,而是以服务化为主。这个巨大的重构背后依赖云和大数据。也因为这个需求,我们可预见工业企业对云计算大数据人才的需求会越来越强烈。

“创业化生存”与共享经济的兴起

创业化,会成为一种常态,越来越多的年轻人开始告别公司,兴起中的数字经济体都是基于云平台的网络化协作组织;云计算成为共享经济的超级容器,催生新一代创业者和“斜杠青年”。十年以后,或许一半以上的从业者都是“斜杠青年”,今天美国就有数千万人是跨工作、跨公司的“斜杠青年”。

过去十年,云计算使得创业公司的创业门槛降低了10倍,没有云计算,Airbnb、NetFlix、推特、Uber等公司不可能这么快成长壮大,新一代创业者的一个核心能力就是要懂技术,理解数据和算法的价值,缺少技术理解力的创业者将面临更大的同质化压力。一句话,无论是草根创业,还是做一个“斜杠青年”,必要的数据思维是生存本能。

创业化和共享经济的崛起,有赖于云计算作为基础设施,大数据作为新能源的全新范式,新一代创业公司需要大量的科技人才。

在未来的经济环境里,普惠云科技的基础设施化、制造的智能化、软件的泛化以及数据无处不在,是一个大趋势,并且不断向各行各业渗透。本套丛书就是希望在这个普惠科技与各行各业深度融合的时代为下一代科技人才的培养提供更多产业界的经验与实践。

感谢清华大学出版社出版本套云计算与大数据方面的系列教材。感谢各位高校老师的辛苦努力和用心付出,使得本系列教材能够付梓出版。

——阿里云业务总经理 刘松

FOREWORD

前言

互联网技术不断发展,各种技术不断涌现,其中大数据技术已成为一颗闪耀的新星。我们已经处于数据世界,互联网每天产生大量的数据,利用好这些数据可以给我们的生活带来巨大的变化以及提供极大的便利。目前大数据技术受到越来越多的机构的重视,因为大数据技术可以为其创造巨大的利润,其中的典型代表是个性化推荐以及大数据精准营销。

本书在讲述大数据的基本概念、原理与方法的基础上,详细而全面地介绍了可以实际用于大数据实践的各种技能,旨在使学生通过有限课时的学习后,不仅能对大数据技术的基本原理有所认识,而且能够具备基本的大数据技术开发能力以及运用大数据技术解决基本的数据分析问题,理解大数据框架(尤其是阿里云大数据计算平台),在阿里云大数据平台上进行基本的大数据开发工作的能力。

本书分为三大部分,分别是大数据概述及基础、大数据处理和大数据分析与应用。其中,大数据概述及基础部分重点介绍数据组织、重要数据结构、大数据协同技术以及大数据存储技术等内容;大数据处理部分重点介绍大数据处理框架,包括大数据批处理和流处理框架等内容;大数据分析与应用部分重点介绍数据分析技术和机器学习的相关内容,以及如何利用阿里云的数加平台进行基本的大数据开发工作。

本书与其他类似著作的不同之处在于,除了讲述必要的大数据理论之外,还通过大数据实践来讲述大数据技术的应用,包括如何运用阿里云大数据计算平台解决和分析实际的问题,如阿里云 MaxCompute 和 StreamCompute 等。本书的最后一章“大数据实践:基于数加平台的推荐系统”是学生在做课程设计时可供模仿的一个项目,它完整地体现了理论与实践的有机结合。

本书的理论知识的教学安排建议如下。

章 节	内 容	学 时 数
第 1 章	大数据概念和发展背景	1
第 2 章	大数据系统架构概述	1~2
第 3 章	分布式通信与协同	2~4
第 4 章	大数据存储	4~6
第 5 章	分布式处理	2
第 6 章	Hadoop MapReduce 解析	2~4
第 7 章	Spark 解析	2~4
第 8 章	流计算	2
第 9 章	图计算	2
第 10 章	阿里云大数据计算服务平台	2
第 11 章	集群资源管理与调度	4~6
第 12 章	数据分析	2~4
第 13 章	数据挖掘与机器学习技术	2~4
第 14 章	大数据实践：基于数加平台的推荐系统	4~5

建议理论教学时数：32~48 学时。

建议实验(实践)教学时数：16~32 学时。

教师可以按照自己对大数据的理解适当地删除一些章节，也可以根据教学目标，灵活地调整章节的顺序，增减各章的学时数。

在本书成书的过程中，得到了万昭祎、李旭、苏俊洋以及阿里巴巴的李妹芳等人的大力支持，在此表示衷心的感谢。

由于大数据是一门新兴学科，大数据的教学方法本身还在探索之中，加之我们的水平和能力有限，本书难免有疏漏之处。恳请各位同仁和广大读者给予批评指正，也希望各位能将实践过程中的经验和心得与我们交流(yunxianglu@hotmail.com)。

作 者

2017 年 1 月

CONTENTS

目
录

第一部分 大数据概述及基础

第 1 章 大数据概念和发展背景	3
1.1 什么是大数据	3
1.2 大数据的特点	3
1.3 大数据的发展	4
1.4 大数据的应用	5
1.5 习题	6
第 2 章 大数据系统架构概述	7
2.1 总体架构概述	7
2.1.1 总体架构设计原则	7
2.1.2 总体架构参考模型	9
2.2 运行架构概述	11
2.2.1 物理架构	11
2.2.2 集成架构	11
2.2.3 安全架构	12
2.3 阿里云飞天系统体系架构	13
2.3.1 阿里云飞天整体架构	13
2.3.2 阿里云飞天平台内核	15
2.3.3 阿里云飞天开放服务	15
2.3.4 阿里云飞天的特色	17
2.4 主流大数据系统厂商	18
2.4.1 阿里云数加平台	18
2.4.2 Cloudera	19

2.4.3 Hortonworks	20
2.4.4 Amazon	20
2.4.5 Google	21
2.4.6 微软	21
2.5 习题	22
第3章 分布式通信与协同	23
3.1 数据编码传输	23
3.1.1 数据编码概述	23
3.1.2 LZSS 算法	24
3.1.3 Snappy 压缩库	25
3.2 分布式通信系统	26
3.2.1 远程过程调用	26
3.2.2 消息队列	27
3.2.3 应用层多播通信	27
3.2.4 阿里云夸父 RPC 系统	28
3.2.5 Hadoop IPC 的应用	29
3.3 分布式协同系统	30
3.3.1 Chubby 锁服务	30
3.3.2 ZooKeeper	32
3.3.3 阿里云女娲协同系统	33
3.3.4 ZooKeeper 在 HDFS 高可用方案中的使用	33
3.4 习题	35
第4章 大数据存储	36
4.1 大数据存储技术的发展	37
4.2 海量数据存储的关键技术	38
4.2.1 数据分片与路由	38
4.2.2 数据复制与一致性	43
4.3 重要数据结构和算法	44
4.3.1 Bloom Filter	44
4.3.2 LSM Tree	46
4.3.3 Merkle Tree	47
4.3.4 Cuckoo Hash	49
4.4 分布式文件系统	49
4.4.1 文件存储格式	49

4.4.2 GFS	52
4.4.3 HDFS	54
4.4.4 阿里云盘古	55
4.5 分布式数据库 NoSQL	56
4.5.1 NoSQL 数据库概述	56
4.5.2 KV 数据库	57
4.5.3 列式数据库	58
4.5.4 图数据库	60
4.5.5 文档数据库	62
4.6 阿里云数据库	63
4.6.1 云数据库 Redis	63
4.6.2 云数据库 RDS	66
4.6.3 云数据库 Memcache	68
4.7 大数据存储技术的趋势	72
4.8 习题	72

第二部分 大数据处理

第 5 章 分布式处理	75
5.1 CPU 多核和 POSIX Thread	75
5.2 MPI 并行计算框架	76
5.3 Hadoop MapReduce	77
5.4 Spark	78
5.5 数据处理技术的发展	79
5.6 习题	80
第 6 章 Hadoop MapReduce 解析	81
6.1 Hadoop MapReduce 架构	81
6.2 Hadoop MapReduce 与高效能计算、网格计算的区别	83
6.3 MapReduce 工作机制	83
6.3.1 Map	84
6.3.2 Reduce	85
6.3.3 Combine	85
6.3.4 Shuffle	85
6.3.5 Speculative Task	86
6.3.6 任务容错	87

6.4 应用案例	88
6.4.1 WordCount	88
6.4.2 WordMean	91
6.4.3 Grep	93
6.5 MapReduce 的缺陷与不足	95
6.6 习题	95
第 7 章 Spark 解析	96
7.1 Spark RDD	96
7.2 Spark 与 MapReduce 的对比	97
7.3 Spark 的工作机制	98
7.3.1 DAG 工作图	98
7.3.2 Partition	99
7.3.3 Lineage 容错方法	100
7.3.4 内存管理	100
7.3.5 数据持久化	102
7.4 数据的读取	102
7.4.1 HDFS	102
7.4.2 Amazon S3	102
7.4.3 HBase	103
7.5 应用案例	103
7.5.1 日志挖掘	103
7.5.2 判别西瓜好坏	104
7.6 Spark 的发展趋势	107
7.7 习题	107
第 8 章 流计算	108
8.1 流计算概述	108
8.2 流计算与批处理系统的对比	109
8.3 Storm 流计算系统	109
8.4 Samza 流计算系统	112
8.5 阿里云流计算	113
8.6 集群日志文件的实时分析	115
8.7 流计算的发展趋势	119
8.8 习题	120

第 9 章 图计算	121
9.1 图计算概述	121
9.2 图计算与流计算、批处理的对比	123
9.3 Spark GraphX	124
9.4 Pregel	126
9.5 航班机场状态分析	127
9.6 图计算的发展趋势	128
9.7 习题	129
第 10 章 阿里云大数据计算服务平台	130
10.1 MaxCompute 概述	130
10.2 MR 计算	131
10.3 SQL 计算	138
10.4 Graph 计算	140
10.5 习题	144
第 11 章 集群资源管理与调度	145
11.1 集群资源统一管理系统	146
11.1.1 集群资源管理概述	146
11.1.2 Apache YARN	147
11.1.3 Apache Mesos	152
11.1.4 Google Omega	153
11.2 资源管理模型	154
11.2.1 基于 slot 的资源表示模型	154
11.2.2 基于最大最小公平原则的资源分配模型	154
11.3 资源调度策略	155
11.3.1 调度策略概述	155
11.3.2 Capacity Scheduler 调度	156
11.3.3 Fair Scheduler 调度	158
11.4 在 YARN 上运行计算框架	160
11.4.1 MapReduce on YARN	160
11.4.2 Spark on YARN	161
11.4.3 YARN 程序设计	162
11.5 阿里云伏羲调度系统	168
11.5.1 伏羲调度系统架构	168

11.5.2 5K 挑战	169
11.5.3 伏羲优化实践	170
11.6 习题	171

第三部分 大数据分析与应用

第 12 章 数据分析	175
-------------------	-----

12.1 数据操作与绘图	175
12.1.1 数据结构	175
12.1.2 绘图功能	176
12.2 初级数据分析	177
12.2.1 描述性统计分析	178
12.2.2 回归诊断	178
12.3 交互式数据分析	179
12.3.1 交互式数据分析的特征	179
12.3.2 交互式数据处理的典型应用	179
12.3.3 典型的处理系统	180
12.4 数据仓库与分析	181
12.4.1 数据仓库的基本架构	182
12.4.2 数据仓库的实现步骤	182
12.4.3 分布式数据仓库 Hive	184
12.4.4 数据仓库之 SQL 分析	186
12.4.5 阿里云 MaxCompute 数据仓库案例	187
12.5 习题	192

第 13 章 数据挖掘与机器学习技术	193
--------------------------	-----

13.1 相关理论基础知识	193
13.1.1 数据挖掘与机器学习简介	193
13.1.2 关联分析	194
13.1.3 分类与回归	197
13.1.4 聚类分析	200
13.1.5 离群点检测	201
13.1.6 复杂数据类型的挖掘	202
13.2 应用实践	203
13.2.1 广告点击率预测	203
13.2.2 并行随机梯度下降	203

13.2.3 自然语言处理：文档相似性的计算	204
13.2.4 阿里云 PAI 与 ET	205
13.3 深度学习	207
13.3.1 深度学习简介	207
13.3.2 DistBelief	208
13.3.3 TensorFlow	209
13.4 数据挖掘与机器学习的发展趋势	212
13.5 习题	212
第 14 章 大数据实践：基于数加平台的推荐系统	213
14.1 数据集简介	213
14.2 数据探索	214
14.3 方案设计	216
14.4 训练集构造	216
14.4.1 MapReduce 环境配置	216
14.4.2 MapReduce 代码编写	217
14.4.3 特征提取与标签提取	222
14.4.4 训练集采样	224
14.4.5 缺失值填充	225
14.5 模型训练与预测	225
14.6 模型预测的准确性评测	229
14.7 特征重要性的评估	230
14.8 总结	231
参考文献	232

第一部分

大数据概述及基础

