



# 《大数据基础编程、实验和案例教程（第2版）》

教材官网：

<http://dmlab.xmu.edu.cn/post/bigdatappractice2/>

温馨提示：编辑幻灯片母版，可以修改每页PPT的厦大校徽和底部文字

## 第8章 数据仓库Hive的安装和使用

（PPT版本号：2020年12月版本）



扫一扫访问教材官网

林子雨

厦门大学计算机科学系

E-mail: [ziyulin@xmu.edu.cn](mailto:ziyulin@xmu.edu.cn) ▶▶

主页: <http://dmlab.xmu.edu.cn/linziyu>





# 教材简介

本书是与《大数据技术原理与应用（第3版）》教材配套的唯一指定实验指导书

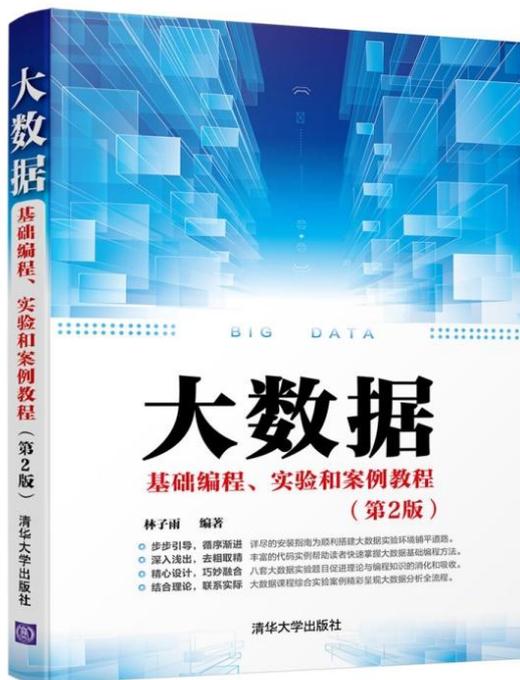
林子雨编著《大数据基础编程、实验和案例教程（第2版）》

清华大学出版社 ISBN:978-7-302-55977-1 定价：69元，2020年10月第2版

教材官网：<http://dbllab.xmu.edu.cn/post/bigdatapRACTICE2/>



扫一扫访问  
教材官网



- 步步引导，循序渐进，详尽的安装指南为顺利搭建大数据实验环境铺平道路
- 深入浅出，去粗取精，丰富的代码实例帮助快速掌握大数据基础编程方法
- 精心设计，巧妙融合，八套大数据实验题目促进理论与编程知识的消化和吸收
- 结合理论，联系实际，大数据课程综合实验案例精彩呈现大数据分析全流程



# 提纲

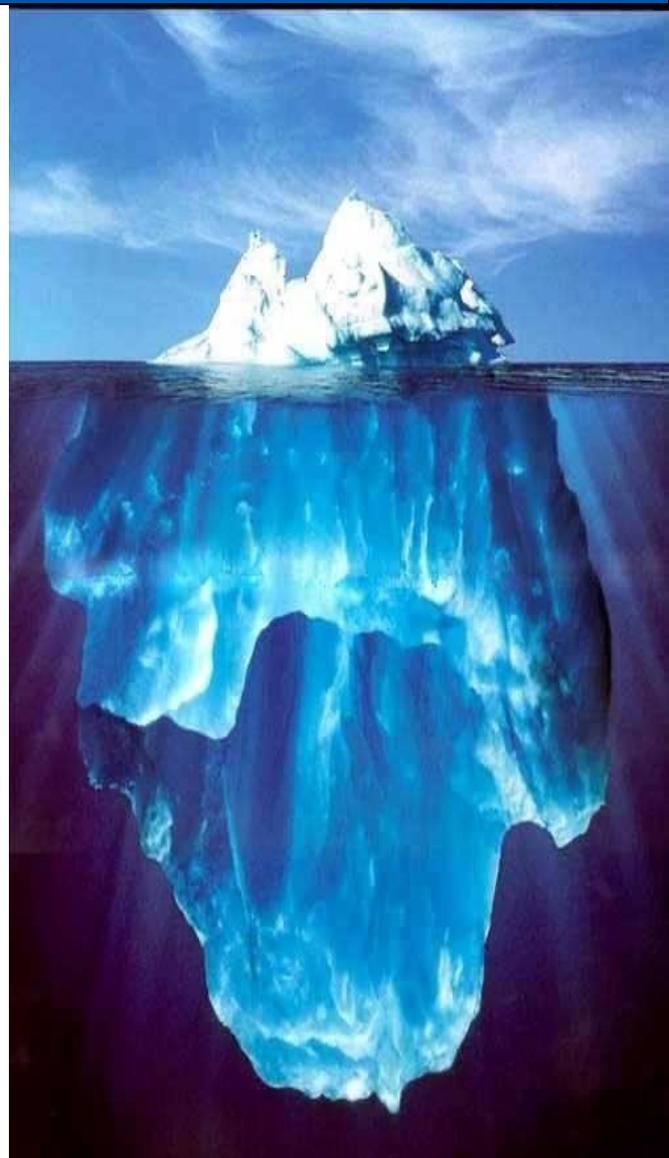
- 8.1 Hive的安装
- 8.2 Hive的数据类型
- 8.3 Hive基本操作
- 8.4 Hive应用实例：WordCount
- 8.5 Hive编程的优势



高校大数据课程

公共服务平台

百度搜索厦门大学数据库实验室网站访问平台





# 8.1 Hive的安装

- 8.1.1 下载安装文件
- 8.1.2 配置环境变量
- 8.1.3 修改配置文件
- 8.1.4 安装并配置MySQL



## 8.1.1 下载安装文件

访问Hive官网（<http://www.apache.org/dyn/closer.cgi/hive/>）下载安装文件  
apache-hive-3.1.2-bin.tar.gz

下载完安装文件以后，需要对文件进行解压。按照Linux系统使用的默认规范，用户安装的软件一般都是存放在“/usr/local/”目录下。请在Linux系统中打开一个终端，执行如下命令：

```
$ sudo tar -zxvf ./apache-hive-3.1.2-bin.tar.gz -C /usr/local # 解压到/usr/local中
$ cd /usr/local/
$ sudo mv apache-hive-3.1.2-bin hive # 将文件夹名改为hive
$ sudo chown -R hadoop:hadoop hive # 修改文件权限
```



## 8.1.2 配置环境变量

为了方便使用，可以把hive命令加入到环境变量PATH中，从而可以在任意目录下直接使用hive命令启动，请使用vim编辑器打开“~/.bashrc”文件进行编辑，命令如下：

```
$ vim ~/.bashrc
```

在该文件的最前面一行添加如下内容：

```
export HIVE_HOME=/usr/local/hive  
export PATH=$PATH:$HIVE_HOME/bin
```

保存该文件并退出vim编辑器，然后，运行如下命令使得配置立即生效：

```
$ source ~/.bashrc
```



## 8.1.3 修改配置文件

将“/usr/local/hive/conf”目录下的hive-default.xml.template文件重命名为hive-default.xml，命令如下：

```
$ cd /usr/local/hive/conf  
$ sudo mv hive-default.xml.template hive-default.xml
```

同时，使用vim编辑器新建一个文件hive-site.xml，命令如下：

```
$ cd /usr/local/hive/conf  
$ vim hive-site.xml
```



## 8.1.3 修改配置文件

在hive-site.xml中输入如下配置信息：

```
<?xml version="1.0" encoding="UTF-8" standalone="no"?>
<?xml-stylesheet type="text/xsl" href="configuration.xsl"?>
<configuration>
  <property>
    <name>javax.jdo.option.ConnectionURL</name>
    <value>jdbc:mysql://localhost:3306/hive?createDatabaseIfNotExist=true</value>
    <description>JDBC connect string for a JDBC metastore</description>
  </property>
  <property>
    <name>javax.jdo.option.ConnectionDriverName</name>
    <value>com.mysql.jdbc.Driver</value>
    <description>Driver class name for a JDBC metastore</description>
  </property>
  <property>
    <name>javax.jdo.option.ConnectionUserName</name>
    <value>hive</value>
    <description>username to use against metastore database</description>
  </property>
  <property>
    <name>javax.jdo.option.ConnectionPassword</name>
    <value>hive</value>
    <description>password to use against metastore database</description>
  </property>
</configuration>
```



## 8.1.4 安装并配置MySQL

### 1. 安装MySQL

这里采用MySQL数据库保存Hive的元数据，而不是采用Hive自带的derby来存储元数据，因此，需要安装MySQL数据库。可以参照“附录B：Linux系统中的MySQL安装及常用操作”，完成MySQL数据库的安装，这里不再赘述。



## 8.1.4 安装并配置MySQL

### 2. 下载MySQL JDBC驱动程序

为了让Hive能够连接到MySQL数据库，需要下载MySQL JDBC驱动程序。可以到MySQL官网（<http://www.mysql.com/downloads/connector/j/>）下载mysql-connector-java-5.1.40.tar.gz。

在Linux系统中打开一个终端，在终端中执行如下命令解压缩文件：

```
$ cd ~  
$ tar -zxvf mysql-connector-java-5.1.40.tar.gz #解压  
$ #下面将mysql-connector-java-5.1.40-bin.jar拷贝到/usr/local/hive/lib目录下  
$ cp mysql-connector-java-5.1.40/mysql-connector-java-5.1.40-bin.jar /usr/local/hive/lib
```



## 8.1.4 安装并配置MySQL

### 3. 启动MySQL

执行如下命令启动MySQL，并进入“mysql>”命令提示符状态：

```
$ service mysql start #启动MySQL服务  
$ mysql -u root -p #登录MySQL数据库
```

### 4. 在MySQL中为Hive新建数据库

现在，需要在MySQL数据库中新建一个名称为hive的数据库，用来保存Hive的元数据。MySQL中的这个hive数据库，是与Hive的配置文件hive-site.xml中的“mysql://localhost:3306/hive”对应起来的，用来保存Hive元数据。在MySQL数据库中新建hive数据库的命令，需要在“mysql>”命令提示符下执行，具体如下：

```
mysql> create database hive;
```



## 8.1.4 安装并配置MySQL

### 5. 配置MySQL允许Hive接入

需要对MySQL进行权限配置，允许Hive连接到MySQL。

```
mysql> grant all on *.* to hive@localhost identified by 'hive';  
mysql> flush privileges;
```

### 6. 启动Hive

Hive是基于Hadoop的数据仓库，会把用户输入的查询语句自动转换成MapReduce任务来执行，并把结果返回给用户。因此，启动Hive之前，需要先启动Hadoop集群，命令如下：

```
$ cd /usr/local/hadoop  
$ ./sbin/start-dfs.sh
```



## 8.1.4 安装并配置MySQL

然后，再执行如下命令启动Hive:

```
$ cd /usr/local/hive  
$ ./bin/hive
```



## 8.2 Hive的数据类型

表 Hive的基本数据类型

类型	描述	示例
<b>TINYINT</b>	1个字节（8位）有符号整数	1
<b>SMALLINT</b>	2个字节（16位）有符号整数	1
<b>INT</b>	4个字节（32位）有符号整数	1
<b>BIGINT</b>	8个字节（64位）有符号整数	1
<b>FLOAT</b>	4个字节（32位）单精度浮点数	1.0
<b>DOUBLE</b>	8个字节（64位）双精度浮点数	1.0
<b>BOOLEAN</b>	布尔类型，true/false	true
<b>STRING</b>	字符串，可以指定字符集	“xmu”
<b>TIMESTAMP</b>	整数、浮点数或者字符串	1327882394（Unix新纪元秒）
<b>BINARY</b>	字节数组	[0,1,0,1,0,1,0,1]



## 8.2 Hive的数据类型

表 Hive的集合数据类型

类型	描述	示例
<b>ARRAY</b>	一组有序字段，字段的类型必须相同	Array(1,2)
<b>MAP</b>	一组无序的键/值对，键的类型必须是原子的，值可以是任何数据类型，同一个映射的键和值的类型必须相同	Map('a',1,'b',2)
<b>STRUCT</b>	一组命名的字段，字段类型可以不同	Struct('a',1,1,0)



## 8.3 Hive基本操作

- 8.3.1 创建数据库、表、视图
- 8.3.2 删除数据库、表、视图
- 8.3.3 修改数据库、表、视图
- 8.3.4 查看数据库、表、视图
- 8.3.5 描述数据库、表、视图
- 8.3.6 向表中装载数据
- 8.3.7 查询表中数据
- 8.3.8 向表中插入数据或从表中导出数据



## 8.3.1 创建数据库、表、视图

- 创建数据库

- ① 创建数据库hive

```
hive> create database hive;
```

- ② 创建数据库hive，因为hive已经存在，所以会抛出异常，加上if not exists关键字，则不会抛出异常

```
hive> create database if not exists hive;
```

- 创建表

- ① 在hive数据库中，创建表usr，含三个属性id， name， age

```
hive> use hive;
```

```
hive>create table if not exists usr(id bigint,name string,age int);
```

- ② 在hive数据库中，创建表usr，含三个属性id， name， age，存储路径为“/usr/local/hive/warehouse/hive/usr”

```
hive>create table if not exists hive.usr(id bigint,name string,age int)  
>location '/usr/local/hive/warehouse/hive/usr';
```



## 8.3.1 创建数据库、表、视图

- 创建表

- ③ 在hive数据库中，创建外部表usr，含三个属性id, name, age，可以读取路径“/usr/local/data”下以“，”分隔的数据。

```
hive>create external table if not exists hive.usr(id bigint,name string,age int)
>row format delimited fields terminated by ','
location '/usr/local/data';
```

- ④ 在hive数据库中，创建分区表usr，含三个属性id, name, age，还存在分区字段sex。

```
hive>create table hive.usr(id bigint,name string,age int) partition by(sex boolean);
```

- ⑤ 在hive数据库中，创建分区表usr1，它通过复制表usr得到。

```
hive> use hive;
hive>create table if not exists usr1 like usr;
```

- 创建视图

- ① 创建视图little\_usr，只包含usr表中id, age属性

```
hive>create view little_usr as select id,age from usr;
```



## 8.3.2 删除数据库、表、视图

- 删除数据库

① 删除数据库hive，如果不存在会出现警告

```
hive> drop database hive;
```

② 删除数据库hive，因为有if exists关键字，即使不存在也不会抛出异常

```
hive> drop database if not exists hive;
```

③ 删除数据库hive，加上cascade关键字，可以删除当前数据库和该数据库中的表

```
hive> drop database if not exists hive cascade;
```



## 8.3.2 删除数据库、表、视图

- 删除表

- ① 删除表usr，如果是内部表，元数据和实际数据都会被删除；如果是外部表，只删除元数据，不删除实际数据

```
hive> drop table if exists usr;
```

- 删除视图

- ① 删除视图little\_usr

```
hive> drop view if exists little_usr;
```



## 8.3.3 修改数据库、表、视图

- 修改数据库

- ① 为hive数据库设置dbproperties键值对属性值来描述数据库属性信息

```
hive> alter database hive set dbproperties('edited-by'='lily');
```

- 修改表

- ① 重命名表usr为用户

```
hive> alter table usr rename to user;
```

- ② 为表usr增加新分区

```
hive> alter table usr add if not exists partition(age=10);
```

- ③ 删除表usr中分区

```
hive> alter table usr drop if exists partition(age=10);
```

- ④ 把表usr中列名name修改为username，并把该列置于age列后

```
hive> alter table usr change name username string after age;
```



## 8.3.3 修改数据库、表、视图

- 修改表

- ⑤ 在对表usr分区字段之前，增加一个新列sex

```
hive>alter table usr add columns(sex boolean);
```

- ⑥ 删除表usr中所有字段并重新指定新字段newid, newname, newage

```
hive>alter table usr replace columns(newid bigint,newname string,newage int);
```

- ⑥ 为usr表设置tblproperties键值对属性值来描述表的属性信息

```
hive> alter table usr set tabproperties('notes'='the columns in usr may be null except id');
```

- 修改视图

- ① 修改little\_usr视图元数据中的tblproperties属性信息

```
hive> alter view little_usr set tabproperties('create_at'='refer to timestamp');
```



## 8.3.4 查看数据库、表、视图

- 查看数据库

- ① 查看Hive中包含的所有数据库

- ```
hive> show databases;
```

- ② 查看Hive中以h开头的所有数据库

- ```
hive> show databases like 'h.*';
```

- 查看表和视图

- ① 查看数据库hive中所有表和视图

- ```
hive> use hive;
```

- ```
hive> show tables;
```

- ② 查看数据库hive中以u开头的所有表和视图

- ```
hive> show tables in hive like 'u.*';
```



## 8.3.5 描述数据库、表、视图

- 描述数据库

- ① 查看数据库hive的基本信息，包括数据库中文件位置信息等

```
hive> describe database hive;
```

- ② 查看数据库hive的详细信息，包括数据库的基本信息及属性信息等

```
hive> describe database extended hive;
```

- 描述表和视图

- ① 查看表usr和视图little\_usr的基本信息，包括列信息等

```
hive> describe hive.usr/ hive.little_usr;
```

- ② 查看表usr和视图little\_usr的详细信息，包括列信息、位置信息、属性信息等

```
hive> describe extended hive.usr/ hive.little_usr;
```

- ③ 查看表usr中列id的信息

```
hive> describe extended hive.usr.id;
```



## 8.3.6 向表中装载数据

- ① 把目录’ /usr/local/data‘下的数据文件中的数据装载进usr表并覆盖原有数据

```
hive> load data local inpath '/usr/local/data' overwrite into table usr;
```

- ② 把目录’ /usr/local/data‘下的数据文件中的数据装载进usr表不覆盖原有数据

```
hive> load data local inpath '/usr/local/data' into table usr;
```

- ③ 把分布式文件系统目录’ hdfs://master\_srever/usr/local/data‘下的数据文件数据装载进usr表并覆盖原有数据

```
hive> load data inpath 'hdfs://master_srever/usr/local/data'  
>overwrite into table usr;
```



## 8.3.7 查询表中数据

该命令和SQL语句完全相同这里不再赘述。



## 8.3.8 向表中插入数据或从表中导出数据

- ① 向表usr1中插入来自usr表的数据并覆盖原有数据

```
hive> insert overwrite table usr1
```

```
> select * from usr where age=10;
```

- ② 向表usr1中插入来自usr表的数据并追加在原有数据后

```
hive> insert into table usr1
```

```
> select * from usr
```

```
> where age=10;
```



## 8.4 Hive应用实例：WordCount

现在我们通过一个实例——词频统计，来深入学习一下Hive的具体使用。首先，需要创建一个需要分析的输入数据文件，然后编写HiveQL语句实现WordCount算法，在Unix下实现步骤如下：

(1) 创建input目录，其中input为输入目录。命令如下：

```
$ cd /usr/local/hadoop  
$ mkdir input
```

(2) 在input文件夹中创建两个测试文件file1.txt和file2.txt，命令如下：

```
$ cd /usr/local/hadoop/input  
$ echo "hello world" > file1.txt  
$ echo "hello hadoop" > file2.txt
```



## 8.4 Hive应用实例：WordCount

(3) 进入hive命令行界面，编写HiveQL语句实现WordCount算法，命令如下：

```
$ hive
```

```
hive> create table docs(line string);
```

```
hive> load data inpath 'input' overwrite into table docs;
```

```
hive> create table word_count as
```

```
select word, count(1) as count from
```

```
(select explode(split(line, ' ')) as word from docs) w
```

```
group by word
```

```
order by word;
```

执行完成后，用select语句查看运行结果如下：

```
OK
Time taken: 2.662 seconds
hive> select * from word_count;
OK
hadoop 1
hello 2
world 1
Time taken: 0.043 seconds, Fetched: 3 row(s)
```



## 8.5 Hive编程的优势

词频统计算法是最能体现MapReduce思想的算法之一，接下来，我们将比较WordCount算法在MapReduce中的编程实现和Hive中编程实现的主要不同点：

1. 采用Hive实现WordCount算法需要编写较少的代码量

- 在MapReduce中，wordcount类由63行Java代码编写而成代码位置：  
%HADOOP\_HOME/share/hadoop/mapreduce/hadoop-mapreduce-examples-2.7.1.jar;
- 而在Hive中只需要编写7行代码

2. 在MapReduce的实现中，需要进行编译生成jar文件来执行算法，而在Hive中不需要。

- HiveQL语句的最终实现需要转换为MapReduce任务来执行，这都是由Hive框架自动完成的，用户不需要了解具体实现细节。



## 8.6 本章小结

**Hive**是一个构建于**Hadoop**顶层的数据仓库工具，主要用于对存储在**Hadoop**文件中的数据集进行数据整理、特殊查询和分析处理。**Hive**在某种程度上可以看作是用户编程接口，本身不存储和处理数据，依赖**HDFS**存储数据，依赖**MapReduce**处理数据。

本章介绍了**Hive**的安装方法，包括下载安装文件、配置环境变量、修改配置文件、安装并配置**MySQL**等。**Hive**支持关系数据库中的大多数基本数据类型，同时**Hive**还支持关系数据库中不常出现的3种集合数据类型。**Hive**提供了类似**SQL**的语句——**HiveQL**，可以很方便地对**Hive**进行操作，包括创建、修改、删除数据库、表、视图等。**Hive**的一大突出优点是，可以把查询语句自动转化成相应的**MapReduce**任务去执行得到结果，这样就可以大大节省用户的编程工作量，本章最后通过一个**WordCount**应用实例，充分展示了**Hive**的这一优点。



# 附录A：主讲教师林子雨简介



## 主讲教师：林子雨

单位：厦门大学计算机科学系

E-mail: [ziyulin@xmu.edu.cn](mailto:ziyulin@xmu.edu.cn)

个人网页: <http://dblab.xmu.edu.cn/post/linziyu>

数据库实验室网站: <http://dblab.xmu.edu.cn>



扫一扫访问个人主页

林子雨，男，1978年出生，博士（毕业于北京大学），全国高校知名大数据教师，现为厦门大学计算机科学系副教授，曾任厦门大学信息科学与技术学院院长助理、晋江市发展和改革局副局长。中国计算机学会数据库专业委员会委员，中国计算机学会信息系统专业委员会委员。国内高校首个“数字教师”提出者和建设者，厦门大学数据库实验室负责人，厦门大学云计算与大数据研究中心主要建设者和骨干成员，2013年度、2017年度和2020年度厦门大学教学类奖教金获得者，荣获2019年福建省精品在线开放课程、2018年厦门大学高等教育成果特等奖、2018年福建省高等教育教学成果二等奖、2018年国家精品在线开放课程。主要研究方向为数据库、数据仓库、数据挖掘、大数据、云计算和物联网，并以第一作者身份在《软件学报》《计算机学报》和《计算机研究与发展》等国家重点期刊以及国际学术会议上发表多篇学术论文。作为项目负责人主持的科研项目包括1项国家自然科学基金青年基金项目(No.61303004)、1项福建省自然科学基金青年基金项目(No.2013J05099)和1项中央高校基本科研业务费项目(No.2011121049)，主持的教改课题包括1项2016年福建省教改课题和1项2016年教育部产学协作育人项目，同时，作为课题负责人完成了国家发改委城市信息化重大课题、国家物联网重大应用示范工程区域试点泉州市工作方案、2015泉州市互联网经济调研等课题。中国高校首个“数字教师”提出者和建设者，2009年至今，“数字教师”大平台累计向网络免费发布超过1000万字高价值的研究和教学资料，累计网络访问量超过1000万次。打造了中国高校大数据教学知名品牌，编著出版了中国高校第一本系统介绍大数据知识的专业教材《大数据技术原理与应用》，并成为京东、当当网等网店畅销书籍；建设了国内高校首个大数据课程公共服务平台，为教师教学和学生学习大数据课程提供全方位、一站式服务，年访问量超过200万次，累计访问量超过1000万次。



# 附录B：大数据学习路线图



大数据学习路线图访问地址：<http://dbllab.xmu.edu.cn/post/10164/>



# 附录C：林子雨大数据系列教材



林子雨大数据系列教材

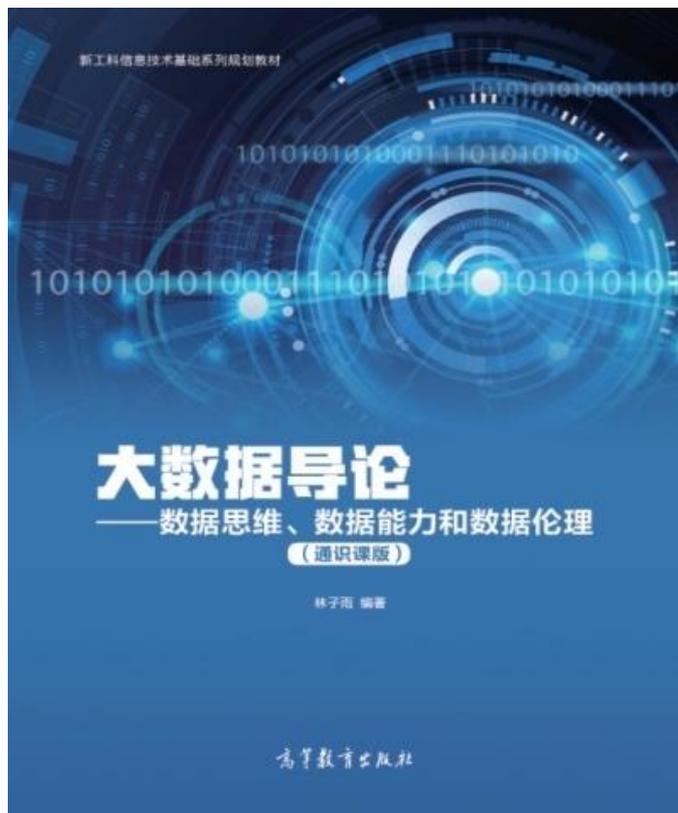
用于导论课、专业课、实训课、公共课

了解全部教材信息：<http://dbllab.xmu.edu.cn/post/bigdatabook/>



# 附录D：《大数据导论（通识课版）》教材

## 开设全校公共选修课的优质教材



本课程旨在实现以下几个培养目标：

- 引导学生步入大数据时代，积极投身大数据的变革浪潮之中
- 了解大数据概念，培养大数据思维，养成数据安全意识
- 认识大数据伦理，努力使自己的行为符合大数据伦理规范要求
- 熟悉大数据应用，探寻大数据与自己专业的应用结合点
- 激发学生基于大数据的创新创业热情

高等教育出版社 ISBN:978-7-04-053577-8 定价：32元

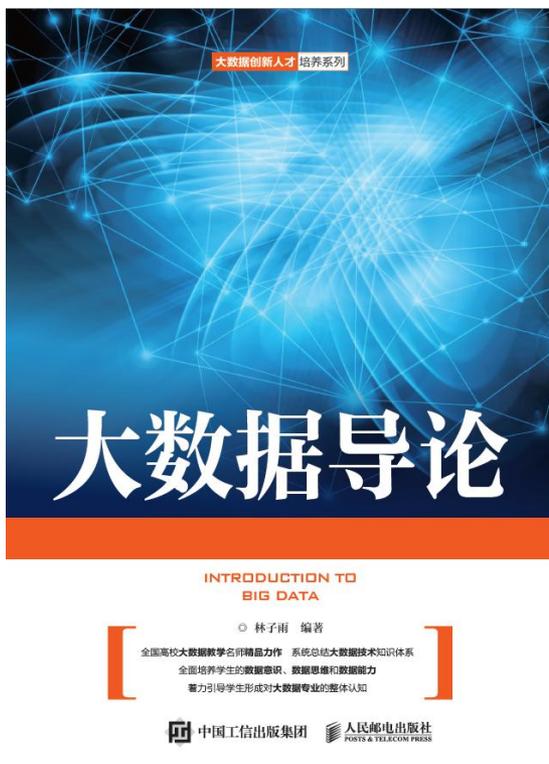
教材官网：<http://dbl原因lab.xmu.edu.cn/post/bigdataintroduction/>



# 附录E：《大数据导论》教材

- 林子雨 编著 《大数据导论》
- 人民邮电出版社，2020年9月第1版
- ISBN:978-7-115-54446-9 定价：49.80元

教材官网：<http://dbl原因.xmu.edu.cn/post/bigdata-introduction/>



开设大数据专业导论课的优质教材



扫一扫访问教材官网



# 附录F：《大数据技术原理与应用》教材

《大数据技术原理与应用——概念、存储、处理、分析与应用（第2版）》，由厦门大学计算机科学系林子雨博士编著，是国内高校第一本系统介绍大数据知识的专业教材。人民邮电出版社 ISBN:978-7-115-44330-4 定价：49.80元

全书共有15章，系统地论述了大数据的基本概念、大数据处理架构Hadoop、分布式文件系统HDFS、分布式数据库HBase、NoSQL数据库、云数据库、分布式并行编程模型MapReduce、Spark、流计算、图计算、数据可视化以及大数据在互联网、生物医学和物流等各个领域的应用。在Hadoop、HDFS、HBase和MapReduce等重要章节，安排了入门级的实践操作，让读者更好地学习和掌握大数据关键技术。

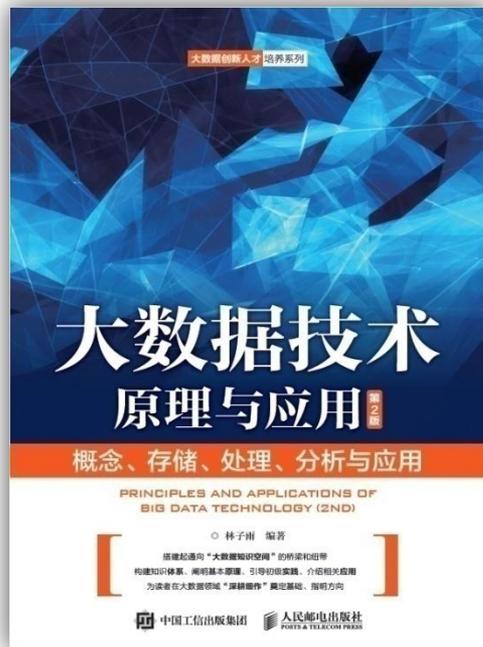
本书可以作为高等院校计算机专业、信息管理等相关专业的大数据课程教材，也可供相关技术人员参考、学习、培训之用。

欢迎访问《大数据技术原理与应用——概念、存储、处理、分析与应用》教材官方网站：

<http://dbllab.xmu.edu.cn/post/bigdata>



扫一扫访问教材官网





# 附录G：《大数据基础编程、实验和案例教程（第2版）》

本书是与《大数据技术原理与应用（第3版）》教材配套的唯一指定实验指导书

大数据教材



1+1黄金组合  
厦门大学林子雨编著

配套实验指导书



- 步步引导，循序渐进，详尽的安装指南为顺利搭建大数据实验环境铺平道路
- 深入浅出，去粗取精，丰富的代码实例帮助快速掌握大数据基础编程方法
- 精心设计，巧妙融合，八套大数据实验题目促进理论与编程知识的消化和吸收
- 结合理论，联系实际，大数据课程综合实验案例精彩呈现大数据分析全流程

林子雨编著《大数据基础编程、实验和案例教程（第2版）》

清华大学出版社 ISBN:978-7-302-55977-1 定价：69元 2020年10月第2版



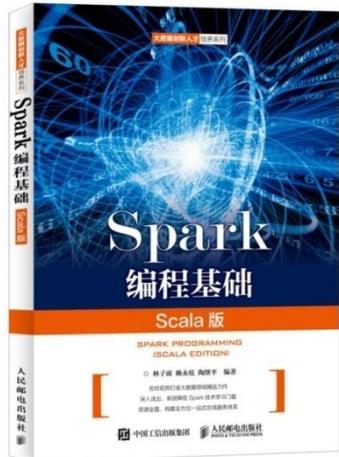
# 附录H: 《Spark编程基础 (Scala版)》

## 《Spark编程基础 (Scala版)》

厦门大学 林子雨, 赖永炫, 陶继平 编著

披荆斩棘, 在大数据丛林中开辟学习捷径  
填沟削坎, 为快速学习Spark技术铺平道路  
深入浅出, 有效降低Spark技术学习门槛  
资源全面, 构建全方位一站式在线服务体系

人民邮电出版社出版发行, ISBN:978-7-115-48816-9  
教材官网: <http://dmlab.xmu.edu.cn/post/spark/>

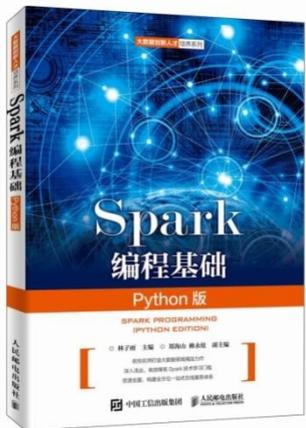


本书以Scala作为开发Spark应用程序的编程语言, 系统介绍了Spark编程的基础知识。全书共8章, 内容包括大数据技术概述、Scala语言基础、Spark的设计与运行原理、Spark环境搭建和使用方法、RDD编程、Spark SQL、Spark Streaming、Spark MLlib等。本书每个章节都安排了入门级的编程实践操作, 以便读者更好地学习和掌握Spark编程方法。本书官网免费提供了全套的在线教学资源, 包括讲义PPT、习题、源代码、软件、数据集、授课视频、上机实验指南等。



# 附录I: 《Spark编程基础 (Python版)》

## 《Spark编程基础 (Python版)》



厦门大学 林子雨, 郑海山, 赖永炫 编著

披荆斩棘, 在大数据丛林中开辟学习捷径  
填沟削坎, 为快速学习Spark技术铺平道路  
深入浅出, 有效降低Spark技术学习门槛  
资源全面, 构建全方位一站式在线服务体系

人民邮电出版社出版发行, ISBN:978-7-115-52439-3

教材官网: <http://dblab.xmu.edu.cn/post/spark-python/>



本书以Python作为开发Spark应用程序的编程语言, 系统介绍了Spark编程的基础知识。全书共8章, 内容包括大数据技术概述、Spark的设计与运行原理、Spark环境搭建和使用方法、RDD编程、Spark SQL、Spark Streaming、Structured Streaming、Spark MLlib等。本书每个章节都安排了入门级的编程实践操作, 以便读者更好地学习和掌握Spark编程方法。本书官网免费提供了全套的在线教学资源, 包括讲义PPT、习题、源代码、软件、数据集、上机实验指南等。



# 附录J：高校大数据课程公共服务平台



## 高校大数据课程

公 共 服 务 平 台

<http://dblab.xmu.edu.cn/post/bigdata-teaching-platform/>



扫一扫访问平台主页



扫一扫观看3分钟FLASH动画宣传片



# 附录K：高校大数据实训课程系列案例教材

为了更好地满足高校开设大数据实训课程的教材需求，厦门大学数据库实验室林子雨老师团队联合企业共同开发了《高校大数据实训课程系列案例》，目前已经完成开发的系列案例包括：

《电影推荐系统》（已经于2019年5月出版）

《电信用户行为分析》（已经于2019年5月出版）

《实时日志流处理分析》

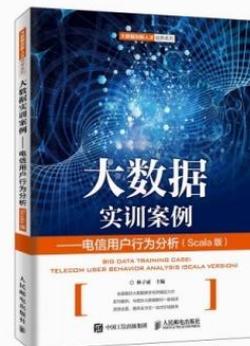
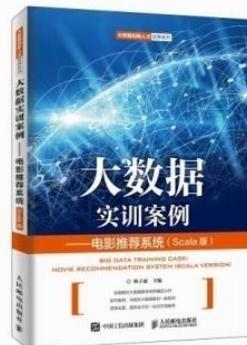
《微博用户情感分析》

《互联网广告预测分析》

《网站日志处理分析》

系列案例教材将于2019年陆续出版发行，教材相关信息，敬请关注网页后续更新！

<http://dbllab.xmu.edu.cn/post/shixunkecheng/>



扫一扫访问大数据实训课程系列案例教材主页

The background of the slide features a blue gradient with several faint, light-blue silhouettes of people. At the top, there are two groups of people standing and holding hands. On the right side, a person is shown in profile, looking towards the center. In the bottom left corner, two people are shown in profile, one appearing to be speaking or gesturing towards the other. The overall theme is one of community and collaboration.

**Thank You!**

**Department of Computer Science, Xiamen University, 2020**