



# 《数据采集与预处理》

教材官网: <http://dblab.xmu.edu.cn/post/data-collection/>

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1章 概述

(PPT版本号: 2022年1月版本)



林子雨 副教授

厦门大学计算机科学与技术系

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

主页: <http://dblab.xmu.edu.cn/linziyu>





# 提纲

- 1.1 数据
- 1.2 数据分析过程
- 1.3 数据采集与预处理的任务
- 1.4 数据采集
- 1.5 数据清洗
- 1.6 数据集成
- 1.7 数据转换
- 1.8 数据脱敏

本PPT是以下教材的配套讲义  
林子雨编著《数据采集与预处理》  
人民邮电出版社

教材官网:

<http://dbllab.xmu.edu.cn/post/data-collection>



大数据创新人才培养系列

## 数据采集与预处理

INTRODUCTION TO  
BIG DATA

© 林子雨 编著

全国高校大数据教学名师精品力作 系统总结大数据技术知识体系  
全面培养学生的数据意识、数据思维和数据处理能力  
着力引导学生形成对大数据专业的整体认知



中国工信出版集团



人民邮电出版社  
POSTS & TELECOM PRESS



# 1.1 数据

- 1.1.1 数据的概念
- 1.1.2 数据类型
- 1.1.3 数据组织形式
- 1.1.4 数据的价值
- 1.1.5 数据爆炸



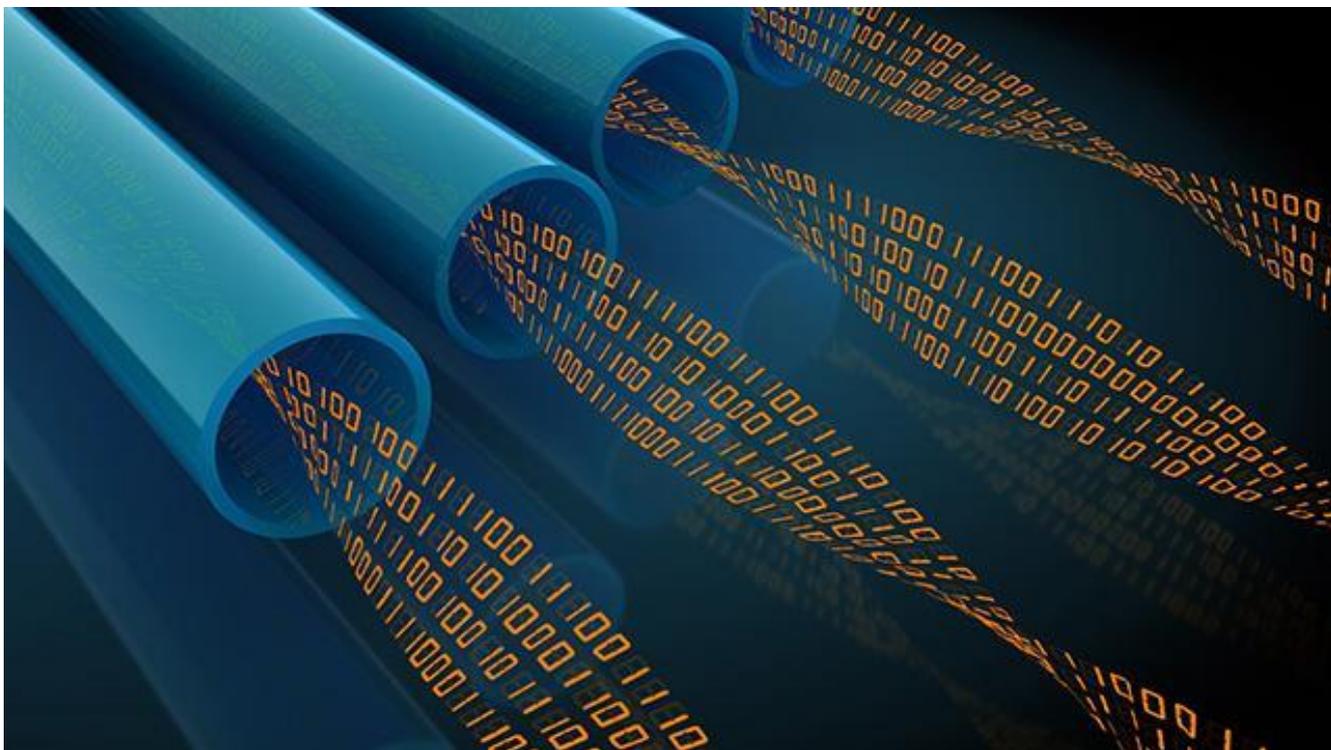
## 1.1.1 数据的概念

- 数据是指对客观事件进行记录并可以鉴别的符号，是对客观事物的性质、状态以及相互关系等进行记载的物理符号或这些物理符号的组合，是可识别的、抽象的符号
- 数据和信息是两个不同的概念，信息是较为宏观的概念，它由数据的有序排列组合而成，传达给读者某个概念方法等，而数据则是构成信息的基本单位，离散的数据没有任何实用价值。



## 1.1.1 数据的概念

数据也被称为“未来的石油”





## 1.1.2 数据类型





## 1.1.3 数据组织形式

计算机系统中的数据组织形式主要有两种，即文件和数据库。

(1) 文件：计算机系统中的很多数据都是以文件形式存在的，比如一个WORD文件、一个文本文件、一个网页文件、一个图片文件等等

(2) 数据库：计算机系统中另一种非常重要的数据组织形式就是数据库，今天，数据库已经成为计算机软件开发的基础和核心



## 1.1.4 数据的价值

在过去，一旦数据的基本用途实现了，往往就会被删除，一方面是由于过去的存储技术落后，人们需要删除旧数据来存储新数据，另一方面则是人们没有认识到数据的潜在价值。

数据的价值不会因为不断被使用而削减，反而会因为不断重组而产生更大的价值

各类收集来的数据都应当被尽可能长时间地保存下来，同时也应当在一定条件下与全社会分享，并产生价值



## 1.1.5数据爆炸

人类进入信息社会以后，数据以自然方式增长，其产生不以人的意志为转移

从1986年开始到2010年的20年时间里，全球数据的数量增长了100倍，今后的数据量增长速度将更快，我们正生活在一个“数据爆炸”的时代





## 1.2 数据分析过程

典型的数据分析过程包括（如图1-2所示）：数据采集与预处理、数据存储与管理、数据处理与分析、数据可视化等，具体如下：

（1）数据采集与预处理：采用各种技术手段把外部各种数据源产生的数据实时或非实时地采集、预处理并加以利用。

（2）数据存储与管理：利用计算机硬件和软件技术对数据进行有效的存储和应用的过程，其目的在于充分有效地发挥数据的作用。

（3）数据处理与分析：数据分析是指用适当的分析方法（来自统计学、机器学习和数据挖掘等领域），对收集来的数据进行分析，提取有用信息和形成结论的过程。

（4）数据可视化：将数据集中的数据以图形图像形式表示，并利用数据分析和开发工具发现其中未知信息的处理过程。

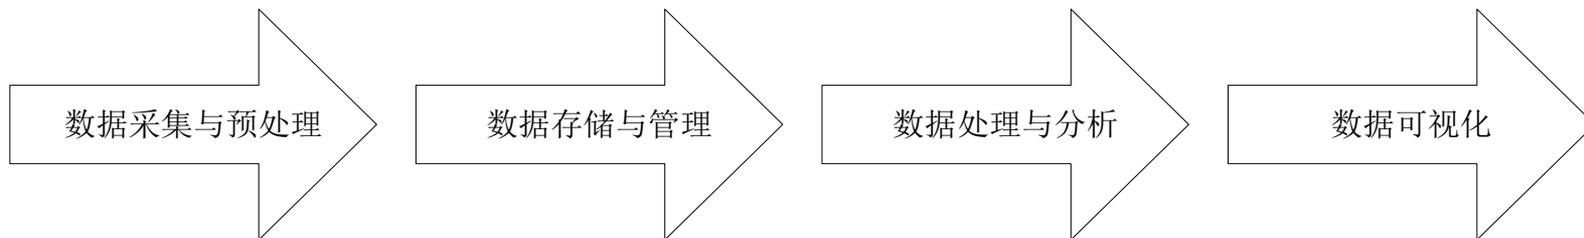


图1-2 典型的数据分析过程



## 1.3 数据采集与预处理的任务

数据采集与预处理包含了数据采集和数据预处理两大任务。

数据采集是指从传感器和智能设备、企业在线系统、企业离线系统、社交网络和互联网平台等获取数据的过程。需要采集的数据包括RFID数据、传感器数据、用户行为数据、社交网络交互数据及移动互联网数据等各种类型的结构化、半结构化及非结构化的海量数据。数据采集技术是大数据技术的重要组成部分，已经广泛应用于国民经济各个领域，随着大数据技术的发展和普及，大数据采集技术会迎来更加广阔的发展前景。



# 1.3 数据采集与预处理的任务

数据预处理是一个广泛的领域，其总体目标是为后续的数据分析工作提供可靠和高质量的数据，减少数据集规模，提高数据抽象程度和数据分析效率。在实际处理过程中，我们需要根据应用问题的具体情况选择合适的数据分析方法。数据预处理的任务主要包括数据清洗、数据集成、数据转换和数据脱敏等（如图1-3所示）。经过这些步骤，我们可以从大量的数据属性中提取出一部分对目标输出有重要影响的属性，降低源数据的维数，去除噪声，为数据分析算法提供干净、准确且有针对性的数据，减少数据分析算法的数据处理量，改进数据质量，提高分析效率。

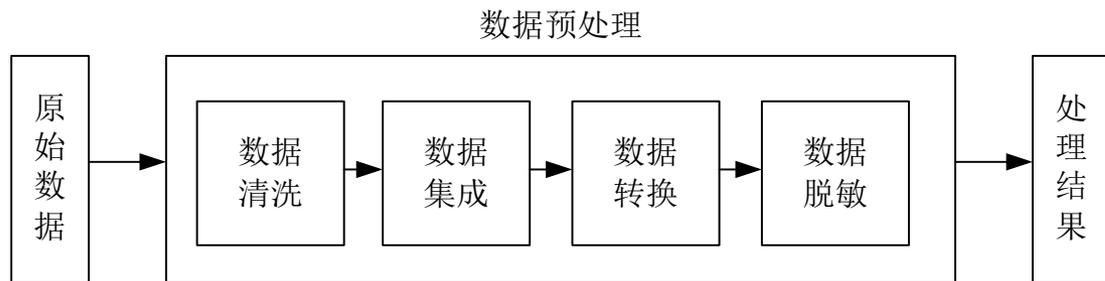


图1-3 数据预处理的主要任务



# 1.4 数据采集

1.4.1 数据采集概念

1.4.2 数据采集的三大要点

1.4.3 数据采集的数据源



## 1.4.1 数据采集概念

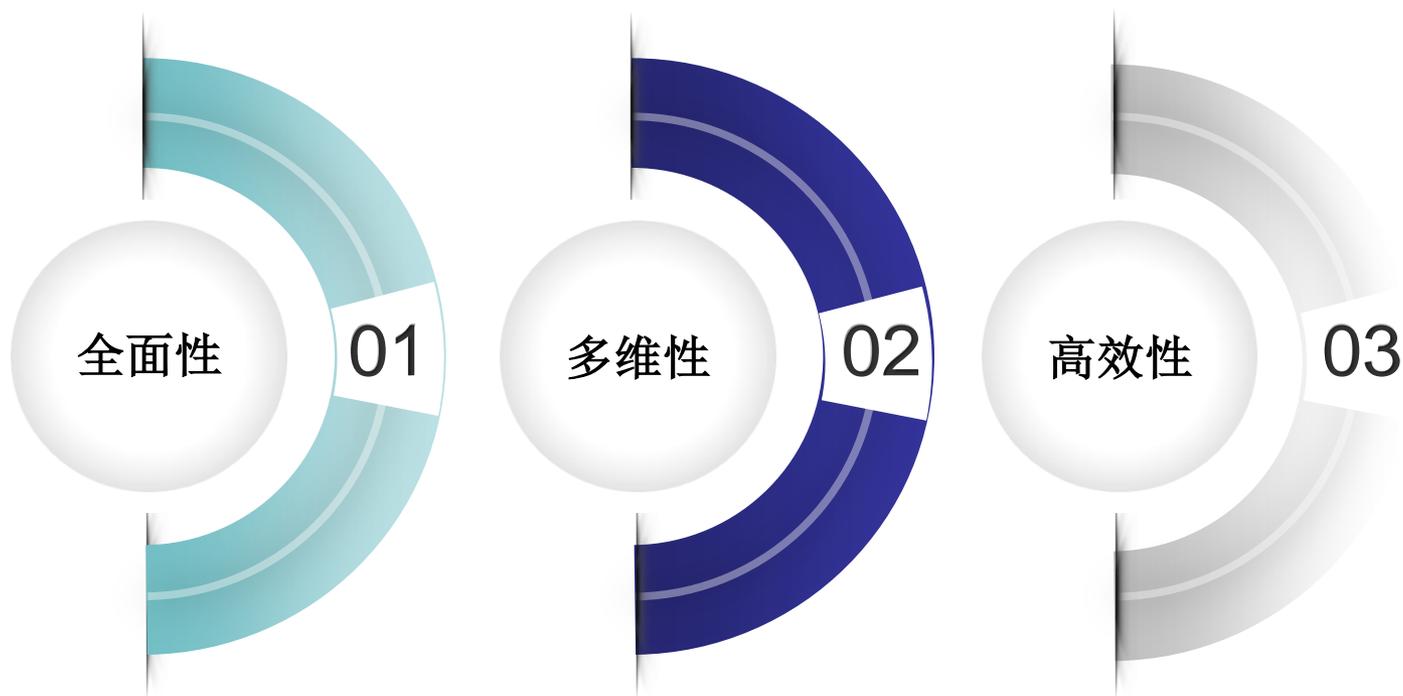
数据采集，又称“数据获取”，是数据分析的入口，也是数据分析过程中相当重要的一个环节，它通过各种技术手段把外部各种数据源产生的数据实时或非实时地采集并加以利用。

表1-1 传统的数据采集与大数据采集区别

	传统的数据采集	大数据采集
数据源	来源单一，数据量相对较少	来源广泛，数据量巨大
数据类型	结构单一	数据类型丰富，包括结构化、半结构化和非结构化
数据存储	关系数据库和并行数据仓库	分布式数据库，分布式文件系统

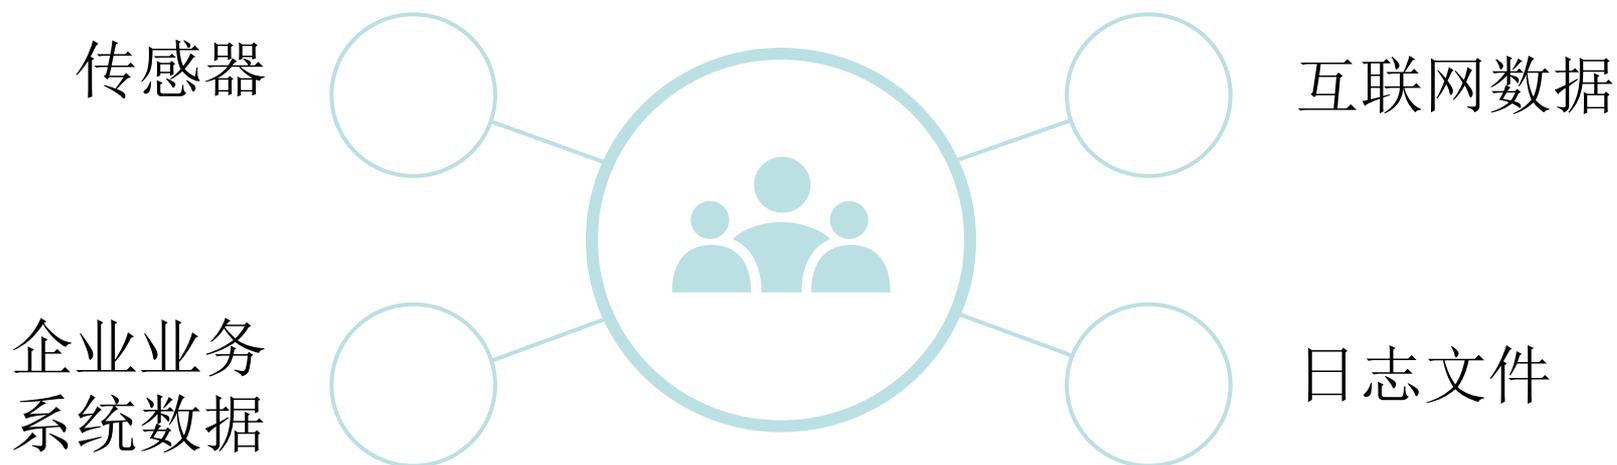


## 1.4.2 数据采集的三大要点





# 1.4.3数据采集的数据源





## 1.4.3数据采集的数据源

### 1.传感器数据

- 传感器是一种检测装置，能感受到被测量的信息，并能将感受到的信息，按一定规律变换成为电信号或其他所需形式的信息输出，以满足信息的传输、处理、存储、显示、记录和控制等要求。在工作现场，我们会安装很多的各种类型的传感器，如压力传感器、温度传感器、流量传感器、声音传感器、电参数传感器等等。
- 传感器对环境的适应能力很强，可以应对各种恶劣的工作环境。在日常生活中，如温度计、麦克风、DV录像、手机拍照功能等都属于传感器数据采集的一部分，支持图片、音频、视频等文件或附件的采集工作。



## 1.4.3 数据采集的数据源

### 2. 互联网数据

互联网数据的采集通常是借助于网络爬虫来完成的。所谓“网络爬虫”，就是一个在网上到处或定向抓取网页数据的程序。抓取网页的一般方法是，定义一个入口页面，然后一般一个页面中会包含指向其他页面的URL，于是从当前页面获取到这些网址加入到爬虫的抓取队列中，然后进入到新页面后再递归地进行上述的操作。爬虫数据采集方法可以将非结构化数据从网页中抽取出来，将其存储为统一的本地数据文件，并以结构化的方式存储。它支持图片、音频、视频等文件或附件的采集，附件与正文可以自动关联。



## 1.4.3数据采集的数据源

### 3.日志文件

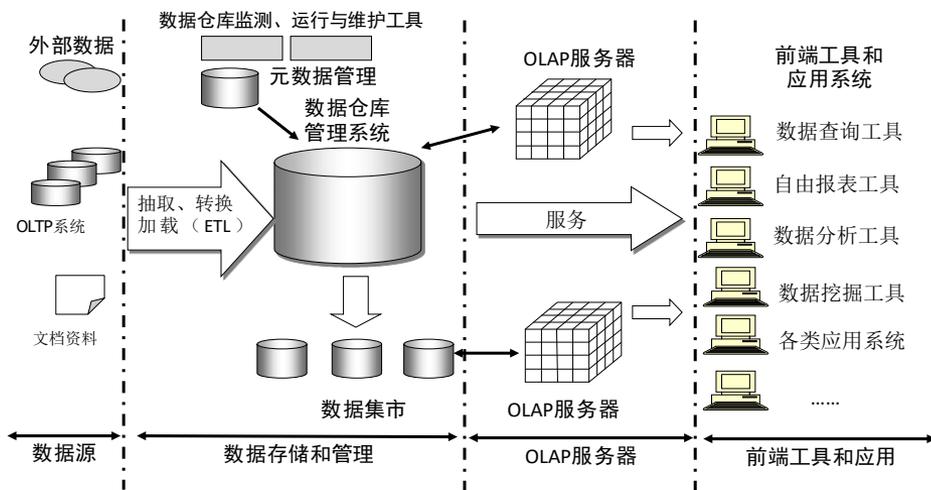
许多公司的业务平台每天都会产生大量的日志文件。日志文件数据一般由数据源系统产生，用于记录数据源的执行的各种操作活动，比如网络监控的流量管理、金融应用的股票记账和Web服务器记录的用户访问行为。对于这些日志信息，我们可以得到出很多有价值的信息。通过对这些日志信息进行采集，然后进行数据分析，就可以从公司业务平台日志数据中挖掘得到具有潜在价值的信息，为公司决策和公司后台服务器平台性能评估提供可靠的数据保证。系统日志采集系统做的事情就是收集日志数据提供离线和在线的实时分析使用。很多互联网企业都有自己的海量数据采集工具，多用于系统日志采集，如Hadoop的Chukwa，Cloudera的Flume，Facebook的Scribe等，这些工具均采用分布式架构，能满足每秒数百MB的日志数据采集和传输需求。



# 1.4.3数据采集的数据源

## 4.企业业务系统数据

一些企业会使用传统的关系型数据库MySQL和Oracle等来存储业务系统数据，除此之外，Redis和MongoDB这样的NoSQL数据库也常用于数据的存储。企业每时每刻产生的业务数据，以数据库一行记录形式被直接写入到数据库中。企业可以借助于ETL（Extract-Transform-Load）工具，把分散在企业不同位置的业务系统的数据，抽取、转换、加载到企业数据仓库中，以供后续的商务智能分析使用（如图所示）。通过采集不同业务系统的数据并统一保存到一个数据仓库中，就可以为分散在企业不同地方的商务数据提供一个统一的视图，满足企业的各种商务决策分析需求。





## 1.4.4 数据采集方法

数据采集是数据系统必不可少的关键部分，也是数据平台的根基。根据不同的应用环境及采集对象，有多种不同的数据采集方法，包括：

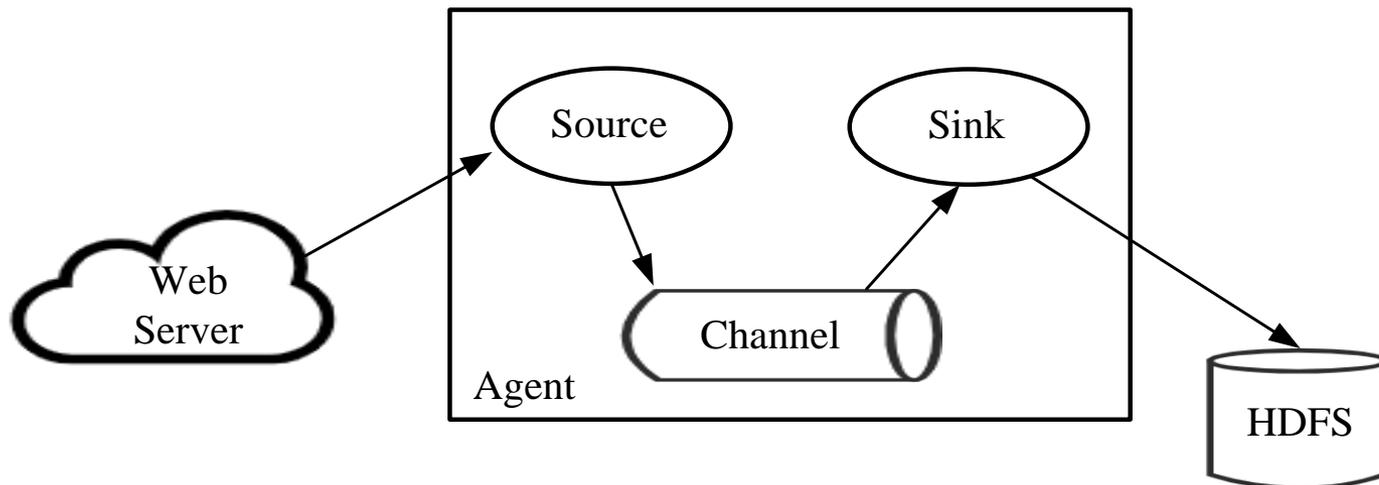
- 系统日志采集
- 分布式消息订阅分发
- ETL
- 网络数据采集



## 1.4.4 数据采集方法

### 1. 系统日志采集

Flume是Cloudera提供的一个高可用的，高可靠的，分布式的海量日志采集、聚合和传输的系统，Flume支持在日志系统中定制各类数据发送方，用于收集数据；同时，Flume提供对数据进行简单处理，并写到各种数据接受方（可定制）的能力。



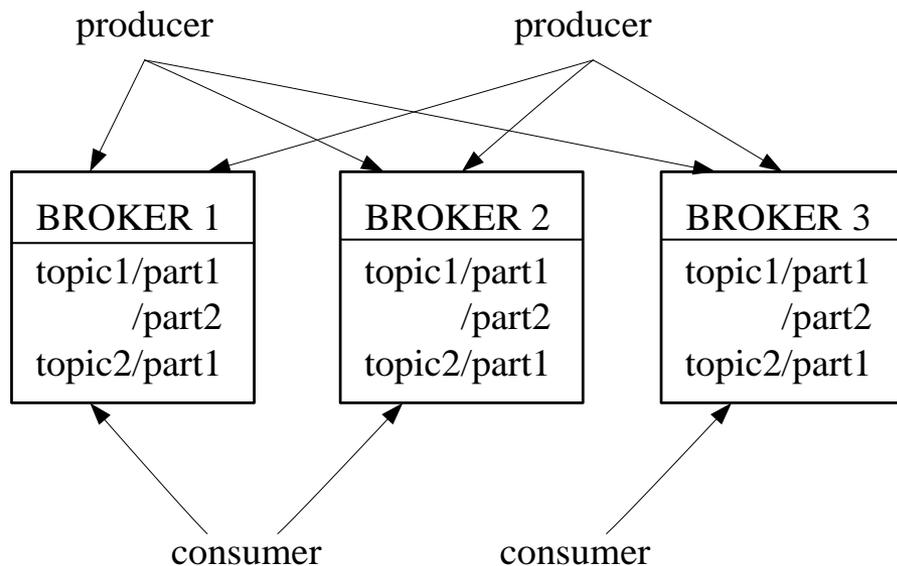


# 1.4.4数据采集方法

## 2.分布式消息订阅分发

分布式消息订阅分发也是一种常见的数据采集方式，其中，**Kafka**就是一种具有代表性的产品。**Kafka**是由**LinkedIn**公司开发的一种高吞吐量的分布式发布订阅消息系统，用户通过**Kafka**系统可以发布大量的消息，同时也能实时订阅消费消息。

**Kafka**的架构包括以下组件：话题、生产者、服务代理、消费者

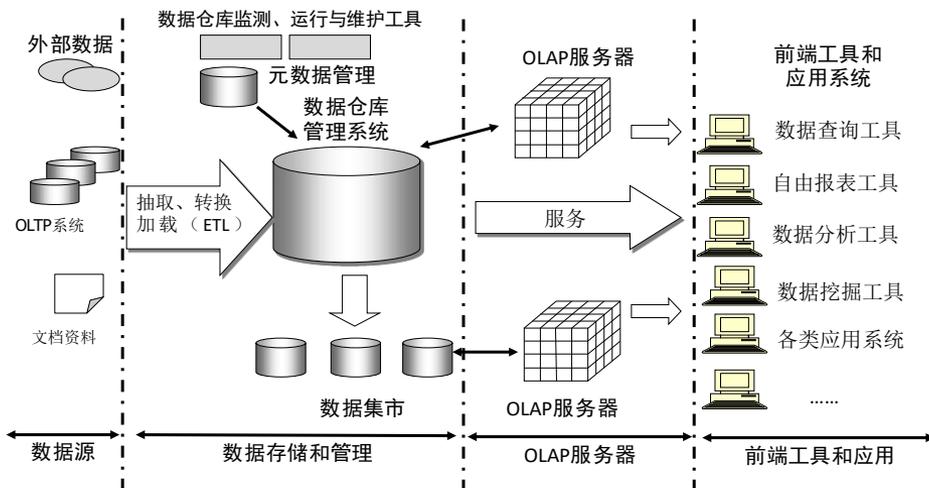




# 1.4.4数据采集方法

## 3. ETL

ETL是英文Extract-Transform-Load的缩写，常用于数据仓库中的数据采集和预处理环节（如图所示）。顾名思义，ETL从原系统中抽取数据，并根据实际商务需求对数据进行转换，并把转换结果加载到目标数据存储中。可以看出，ETL既包含了数据采集环节，也包含了数据预处理环节。



Kettle是一款国外开源的ETL工具，使用Java语言编写，可以在Windows、Linux、Unix上运行，数据抽取高效、稳定。



# 1.4.4数据采集方法

## 4.网络数据采集

网络数据采集是指通过网络爬虫或网站公开应用程序编程接口等方式从网站上获取数据信息。该方法可以将非结构化数据从网页中抽取出来，将其存储为统一的本地数据文件，并以结构化的方式存储。它支持图片、音频、视频等文件的采集，文件与正文可以自动关联。网络数据采集的应用领域十分广泛，包括搜索引擎与垂直搜索平台搭建与运营，综合门户与行业门户、地方门户、专业门户网站数据支撑与流量运营，电子政务与电子商务平台的运营，知识管理与知识共享，企业竞争情报系统的运营，BI商业智能系统，信息咨询与信息增值，信息安全和信息监控等。



# 1.5 数据清洗

- 1.5.1 数据清洗的应用领域
- 1.5.2 数据清洗的实现方式
- 1.5.3 数据清洗的内容
- 1.5.4 数据清洗的注意事项
- 1.5.5 数据清洗的基本流程
- 1.5.6 数据清洗的评价标准



## 1.5.1 数据清洗的应用领域

数据清洗的主要应用领域包括数据仓库与数据挖掘、数据质量管理。

(1) 数据仓库与数据挖掘。数据清洗对于数据仓库与数据挖掘应用来说，是核心和基础，它是获取可靠、有效数据的一个基本步骤。数据仓库是为了支持决策分析的数据集合，在数据仓库领域，数据清洗一般是应用在几个数据库合并时或者多个数据源进行集成时。例如，指代同一个实体的记录，在合并后的数据库中就会出现重复的记录。数据清洗就是要把这些重复的记录识别出来并消除它们。数据挖掘是建立在数据仓库基础上的增值技术，在数据挖掘领域，经常会遇到挖掘出来的特征数据存在各种异常情况，如数据缺失、数据值异常等。对于这些情况，如果不加以处理，就会直接影响到最终挖掘模型的使用效果，甚至会使得创建模型任务失败。因此，在数据挖掘过程中，数据清洗是第一步。



## 1.5.1 数据清洗的应用领域

(2) 数据质量管理。数据质量管理贯穿数据生命周期的全过程。在数据生命周期中，可以通过数据质量管理的方法和手段，在数据生成、使用、消亡的过程里，及时发现有缺陷的数据，然后借助数据管理手段，将数据正确化和规范化，从而达到符合要求的数据质量标准。总体而言，数据质量管理覆盖质量评估、数据去噪、数据监控、数据探查、数据清洗、数据诊断等方面，而在这个过程中，数据清洗是决定数据质量好坏的重要因素。



## 1.5.2 数据清洗的实现方式

数据清洗按照实现方式，可以分为手工清洗和自动清洗。

(1) 手工清洗。手工清洗是通过人工方式对数据进行检查，发现数据中的错误。这种方式比较简单，只要投入足够的人力、物力、财力，也能发现所有错误，但效率低下。在大数据量的情况下，手工清洗数据几乎是不可能的。

(2) 自动清洗。自动清洗是通过专门编写的计算机应用程序来进行数据清洗。这种方法能解决某个特定的问题，但不够灵活，特别是在清理过程需要反复进行时（一般来说,数据清理一遍就达到要求的很少），程序复杂，清理过程变化时工作量大。而且，这种方法也没有充分利用目前数据库提供的强大的数据处理能力。



## 1.5.3数据清洗的内容

数据清洗主要是对缺失值、重复值、异常值和数据类型有误的数据进行处理，数据清洗的内容主要包括：

(1) 缺失值处理。由于调查、编码和录入误差，数据中可能存在一些缺失值，需要给予适当的处理。常用的处理方法有：估算、整例删除、变量删除和成对删除。

(2) 异常值处理。根据每个变量的合理取值范围和相互关系，检查数据是否合乎要求，发现超出正常范围、逻辑上不合理或者相互矛盾的数据。

(3) 数据类型转换。数据类型往往会影响到后续的数据处理分析环节，因此，需要明确每个字段的数据类型，比如，来自A表的“学号”是字符型，而来自B表的字段是日期型，在数据清洗的时候就需要对二者的数据类型进行统一处理。

(4) 重复值处理。重复值的存在会影响数据分析和挖掘结果的准确性，所以，在数据分析和建模之前需要进行数据重复性检验，如果存在重复值，还需要进行重复值的删除。



## 1.5.4 数据清洗的注意事项

在进行数据清洗时，需要注意如下事项：

(1) 数据清洗时优先进行缺失值、异常值和数据类型转换的操作，最后进行重复值的处理。

(2) 在对缺失值、异常值进行处理时，要根据业务的需求进行处理，这些处理并不是一成不变的，常见的填充包括：统计值填充（常用的统计值有均值、中位数、众数）、前/后值填充（一般使用在前后数据存在关联的情况下，比如数据是按照时间进行记录的）、零值填充。

(3) 在数据清洗之前，最为重要的对数据表的查看，要了解表的结构和发现需要处理的值，这样才能将数据清洗彻底。

(4) 数据量的大小也关系着数据的处理方式。

(5) 在导入数据表后，一般需要将所有列一个个地进行清洗，来保证数据处理的彻底性，有些数据可能看起来是可以正常使用的，实际上在进行处理时可能会出现问題（比如某列数据在查看时看起来是数值类型，但是其实这列数据的类型却是字符串，这就会导致在进行数值操作时无法使用）。



## 1.5.5 数据清洗的基本流程

数据清洗的基本流程一共分为**5**个步骤，分别是数据分析、定义数据清洗的策略和规则、搜寻并确定错误实例、纠正发现的错误以及干净数据回流。具体如下：

- (1) 数据分析。
- (2) 定义数据清洗的策略和规则。
- (3) 搜寻并确定错误实例。
- (4) 纠正发现的错误。
- (5) 干净数据回流。



## 1.5.6 数据清洗的评价标准

数据清洗的评价标准包括以下几个方面：

- (1) 数据的可信性。
- (2) 数据的可用性。
- (3) 数据清洗的代价。



## 1.6 数据集成

数据处理常常涉及数据集成操作，即将来自多个数据源的数据，结合在一起形成一个统一的数据集合，以便为数据处理工作的顺利完成提供完整的数据基础。

在数据集成过程中，需要考虑解决以下几个问题：

- (1) 模式集成问题。
- (2) 冗余问题。
- (3) 数据值冲突检测与消除问题。



# 1.7 数据转换

1.7.1 数据转换策略

1.7.2 平滑处理

1.7.3 规范化处理



## 1.7.1 数据转换策略

常见的数据转换策略包括：

(1) 平滑处理。帮助除去数据中的噪声，常用的方法包括分箱、回归和聚类等。

(2) 聚集处理。对数据进行汇总操作。例如，每天的数据经过汇总操作可以获得每月或每年的总额。这一操作常用于构造数据立方体或对数据进行多粒度的分析。

(3) 数据泛化处理。用更抽象（更高层次）的概念来取代低层次的数据对象。例如，街道属性可以泛化到更高层次的概念，如城市、国家，再比如年龄属性可以映射到更高层次的概念，如青年、中年和老年。

(4) 规范化处理。将属性值按比例缩放，使之落入一个特定的区间，比如0.0~1.0。常用的数据规范化方法包括Min-Max规范化、Z-Score规范化和小数定标规范化等。

(5) 属性构造处理。根据已有属性集构造新的属性，后续数据处理直接使用新增的属性。例如，根据已知的质量和体积属性，计算出新的属性——密度。

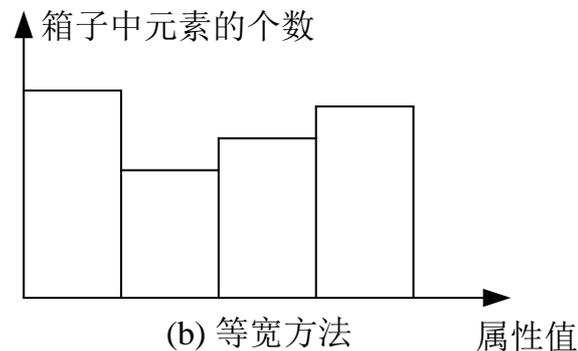
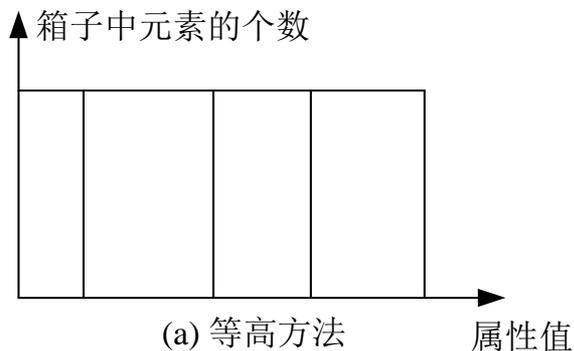


# 1.7.2 平滑处理

噪声是指被测变量的一个随机错误和变化。平滑处理旨在帮助去掉数据中的噪声，常用的方法包括分箱、回归和聚类等。

## 1.分箱

分箱（Bin）方法通过利用被平滑数据点的周围点（近邻），对一组排序数据进行平滑，排序后的数据被分配到若干箱子（称为 Bin）中。如图5所示，对箱子的划分方法一般有两种，一种是等高方法，即每个箱子中元素的个数相等，另一种是等宽方法，即每个箱子的取值间距（左右边界之差）相同。





# 1.7.2 平滑处理

## 1.分箱

这里给出一个实例介绍分箱方法。假设有一个数据集  $X=\{4,8,15,21,21,24,25,28,34\}$ ，这里采用基于平均值的等高分箱方法对其进行平滑处理，则分箱处理的步骤如下：

(1) 把原始数据集 $X$ 放入以下三个箱子：

箱子1: 4,8,15

箱子2: 21,21,24

箱子3: 25,28,34

(2) 分别计算得到每个箱子的平均值：

箱子1的平均值: 9

箱子2的平均值: 22

箱子3的平均值: 29

(3) 用每个箱子的平均值替换该箱子内的所有元素：

箱子1: 9,9,9

箱子2: 22,22,22

箱子3: 29,29,29

(4) 合并各个箱子中的元素得到新的数据集 $\{9,9,9,22,22,22,29,29,29\}$ 。



## 1.7.2 平滑处理

### 1.分箱

此外，还可以采用基于箱子边界的等高分箱方法对数据进行平滑处理。利用边界进行平滑时，对于给定的箱子，其最大值与最小值就构成了该箱子的边界，利用每个箱子的边界值（最大值或最小值）可替换该箱子中的所有值。这时的分箱结果如下：

箱子1: 4,4,15

箱子2: 21,21,24

箱子3: 25,25,34

合并各个箱子中的元素得到新的数据集  
{4,4,15,21,21,24,25,25,34}。



# 1.7.2 平滑处理

## 2. 回归

可以利用拟合函数对数据进行平滑。例如，借助线性回归方法（包括多变量回归方法），就可以获得多个变量之间的拟合关系，从而达到利用一个（或一组）变量值来预测另一个变量取值的目的。如图所示，利用回归分析方法所获得的拟合函数，能够帮助平滑数据并除去其中的噪声。

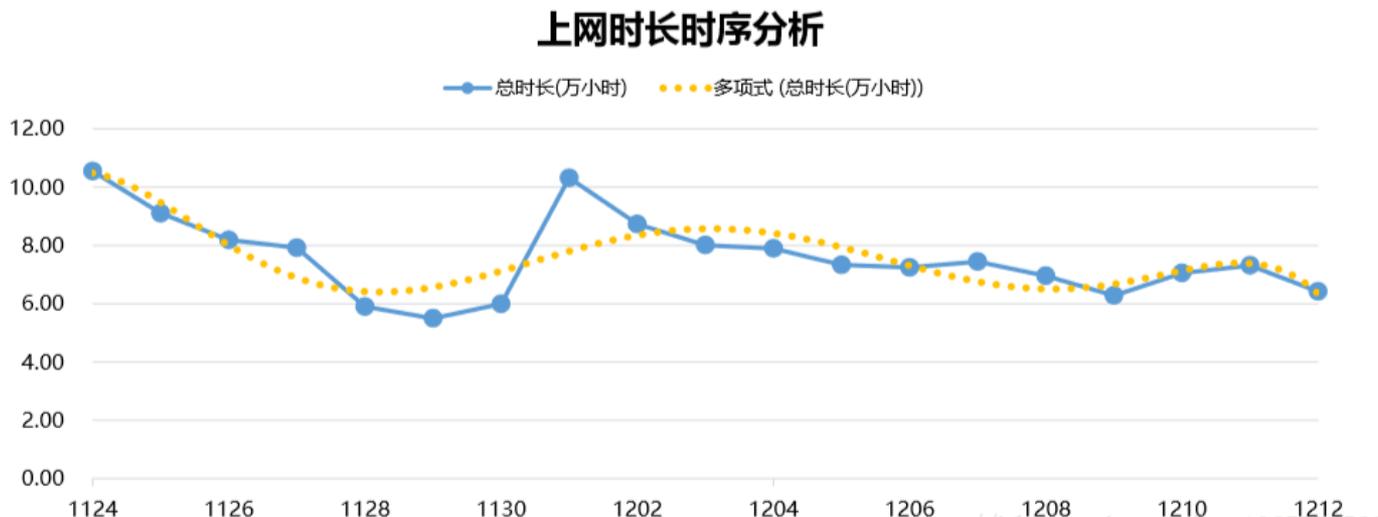


图 对数据进行线性回归拟合



## 1.7.2 平滑处理

### 3. 聚类

通过聚类分析方法可帮助发现异常数据。如图所示，相似或相邻近的数据聚合在一起形成了各个聚类集合，而那些位于这些聚类集合之外的数据对象，则被认为是异常数据。

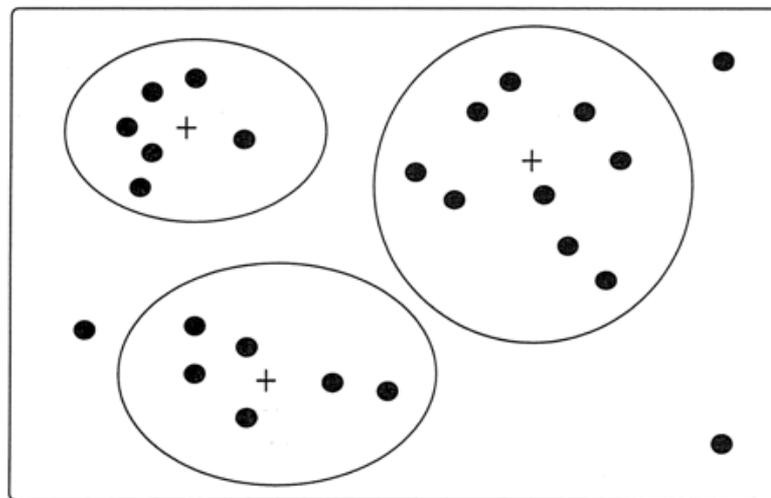


图 基于聚类分析方法的异常数据监测



## 1.7.3 规范化处理

### 1. Min-Max规范化

Min-Max规范化方法对被转换数据进行一种线性转换，其转换公式如下：

$x = (\text{待转换属性值} - \text{属性最小值}) / (\text{属性最大值} - \text{属性最小值})$

例如，假设属性的最大值和最小值分别是87000元和11000元，现在需要利用Min-Max规范化方法，将“顾客收入”属性的值映射到0~1 的范围内，则“顾客收入”属性的值为72400元时，对应的转换结果如下：

$(72400 - 11000) / (87000 - 11000) = 0.808$

Min-Max规范化比较简单，但是也存在一些缺陷，当有新的数据加入时，可能导致最大值和最小值的变化，需要重新定义属性最大值和最小值。



# 1.7.3 规范化处理

## 2. Z-Score规范化

Z-Score规范化的主要目的就是不同量级的数据统一转化为同一个量级，统一用计算出的Z-Score值衡量，以保证数据之间的可比性。其转换公式如下：

$z = (\text{待转换属性值} - \text{属性平均值}) / \text{属性标准差}$

假设我们要比较学生A与学生B的考试成绩，A的考卷满分是100分（及格60分），B的考卷满分是700分（及格420分）。很显然，A考出的70分与B考出的70分代表着完全不同的意义。但是从数值来讲，A与B在数据表中都是用数字70代表各自的成绩。那么如何能够用一个同等的标准来比较A与B的成绩呢？Z-Score就可以解决这一问题。

假设A班级的平均分是80，标准差是10，A考了90分；B班的平均分是400，标准差是100，B考了600分。通过上面的公式，我们可以计算得出，A的Z-Score是1（即 $(90-80)/10$ ），B的Z-Score是2（即 $(600-400)/100$ ），因此，B的成绩更为优异。若A考了60分，B考了300分，则A的Z-Score是-2，B的Z-Score是-1，这时，A的成绩比较差。



# 1.7.3 规范化处理

## 2. Z-Score规范化

Z-Score的优点是不需要知道数据集的最大值和最小值，对离群点规范化效果好。此外，Z-Score能够应用于数值型的数据，并且不受数据量级的影响，因为它本身的作用就是消除量级给分析带来的不便。

但是Z-Score也有一些缺陷。首先，Z-Score对于数据的分布有一定的要求，正态分布是最有利于Z-Score计算的。其次，Z-Score消除了数据具有的实际意义，A的Z-Score与B的Z-Score与他们各自的分数不再有关系，因此，Z-Score的结果只能用于比较数据间的结果，数据的真实意义还需要还原原值。



## 1.7.3 规范化处理

### 3. 小数定标规范化

小数定标规范化方法通过移动属性值的小数位置来达到规范化的目的。所移动的小数位数取决于属性绝对值的最大值。其转换公式为：

$x = \text{待转换属性值} / (10 \text{的} k \text{次方})$

其中， $k$ 为能够使该属性绝对值的最大值的转换结果小于1的最小值。比如，假设属性的取值范围是-957~924，则该属性绝对值的最大值为957，很显然，这时 $k=3$ 。当属性的值为426时，对应的转换结果如下：  
 $426 / 10 \text{的} 3 \text{次方} = 0.426$

小数定标法的优点是直观简单，缺点是并没有消除属性间的权重差异。



# 1.8数据脱敏

1.8.1数据脱敏原则

1.8.2数据脱敏方法



## 1.8.1 数据脱敏原则

数据脱敏不仅要执行“数据漂白”，抹去数据中的敏感内容，同时也需要保持原有的数据特征、业务规则和数据关联性，保证开发、测试以及大数据类业务不会受到脱敏的影响，达成脱敏前后的数据一致性和有效性，具体如下：

(1) 保持原有数据特征。数据脱敏前后必须保证数据特征的保持，例如：身份证号码由十七位数字本体码和一位校验码组成，分别为区域地址码（6位）、出生日期（8位）、顺序码（3位）和校验码（1位）。那么身份证号码的脱敏规则就需要保证脱敏后依旧保持这些特征信息。

(2) 保持数据之间的一致性。在不同业务中，数据和数据之间具有一定的关联性。例如：出生年月或年龄和出生日期之间的关系。同样，身份证信息脱敏后仍需要保证出生年月字段和身份证中包含的出生日期之间的一致性。



## 1.8.1 数据脱敏原则

(3) 保持业务规则的关联性。保持数据业务规则的关联性是指数据脱敏时数据关联性以及业务语义等保持不变，其中数据关联性包括：主外键关联性、关联字段的业务语义关联性等。特别是高度敏感的账户类主体数据，往往会贯穿主体的所有关系和行为信息，因此需要特别注意保证所有相关主体信息的一致性。

(4) 多次脱敏之间的数据一致性。相同的数据进行多次脱敏，或者在不同的测试系统进行脱敏，需要确保每次脱敏的数据始终保持一致性，只有这样才能保障业务系统数据变更的持续一致性以及广义业务的持续一致性。



## 1.8.2数据脱敏方法

数据脱敏的方法主要包括：

(1) 数据替换。用设置的固定虚构值替换真值。例如将手机号码统一替换为13900010002。

(2) 无效化。通过对数据值的截断、加密、隐藏等方式使敏感数据脱敏，使其不再具有利用价值，例如将地址的值替换为“\*\*\*\*\*”。数据无效化与数据替换所达成的效果基本类似。

(3) 随机化。采用随机数据代替真值，保持替换值的随机性以模拟样本的真实性。例如用随机生成的姓和名代替真值。

(4) 偏移和取整。通过随机移位改变数字数据，例如把日期“2018-01-02 8:12:25”变为“2018-01-02 8:00:00”。偏移取整在保持了数据的安全性的同时，保证了范围的大致真实性，此项功能在大数据利用环境中具有重大价值。

(5) 掩码屏蔽。掩码屏蔽是针对账户类数据的部分信息进行脱敏时的有力工具，比如银行卡号或是身份证号的脱敏。比如，把身份证号码“220524199209010254”替换为“220524\*\*\*\*\*0254”。

(6) 灵活编码。在需要特殊脱敏规则时，可执行灵活编码以满足各种可能的脱敏规则。比如用固定字母和固定位数的数字替代合同编号真值。



# 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与技术系

E-mail: ziyulin@xmu.edu.cn

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

数据库实验室网站: <http://dblab.xmu.edu.cn>

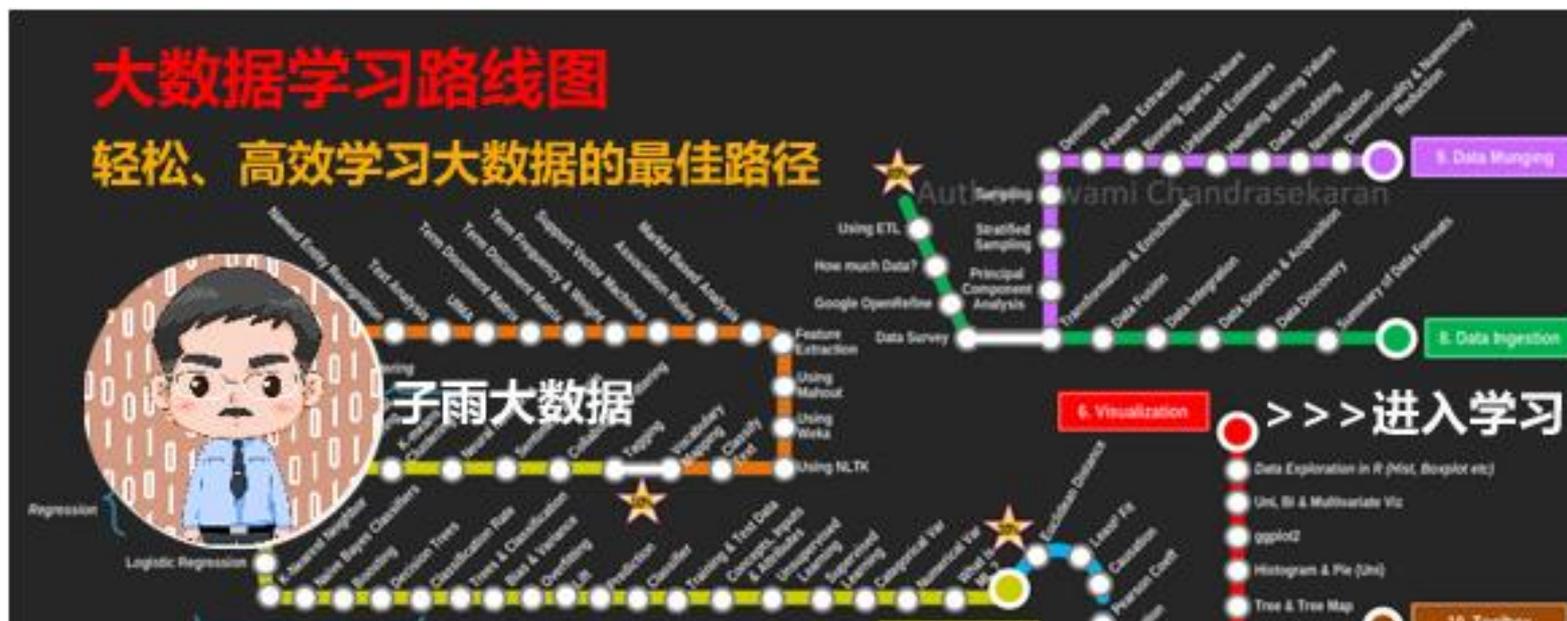


扫一扫访问个人主页

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，厦门大学信息学院实验教学中心主任，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400万次，累计访问量超过1500万次。



# 附录B：大数据学习路线图



大数据学习路线图访问地址：<http://dblab.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

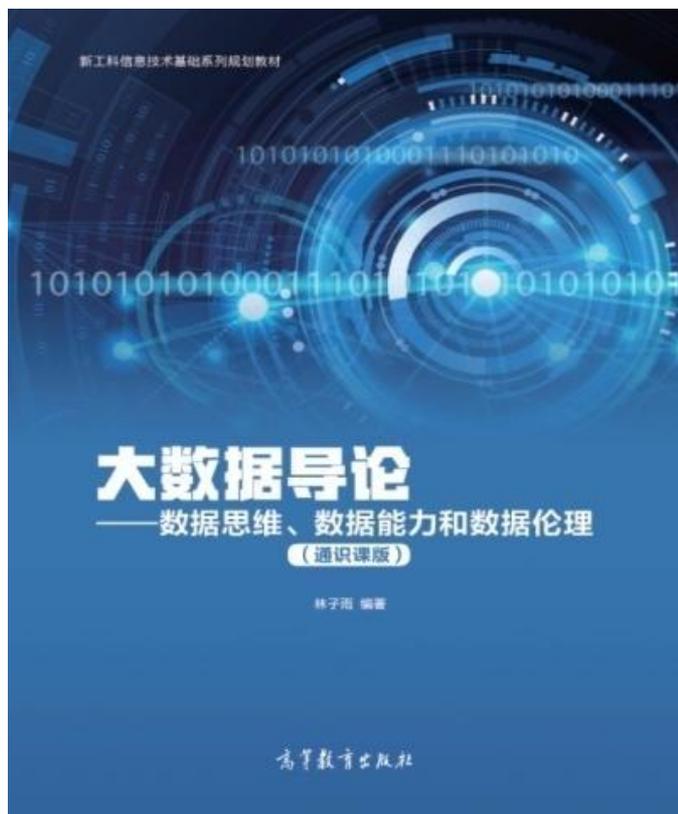
用于导论课、专业课、实训课、公共课

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 版次：2020年2月第1版  
教材官网：<http://dbllab.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（第3版）》教材

《大数据技术原理与应用——概念、存储、处理、分析与应用（第3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:978-7-115-54405-6 定价：59.80元

全书共有17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、Flink、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、MapReduce、Spark和Flink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。

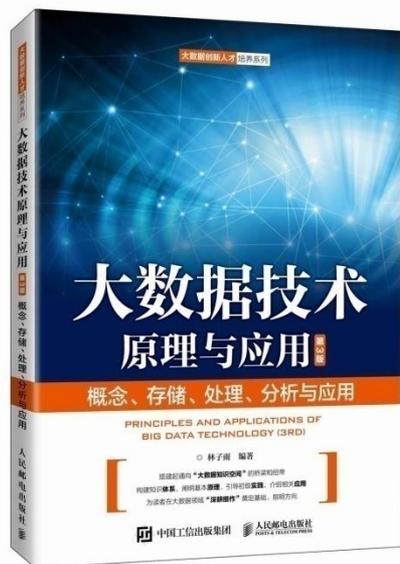
本书可以作为高等院校计算机专业、信息管理等相关专业的大数据课程教材，也可供相关技术人员参考、学习、培训之用。

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/bigdata3>



扫一扫访问教材官网

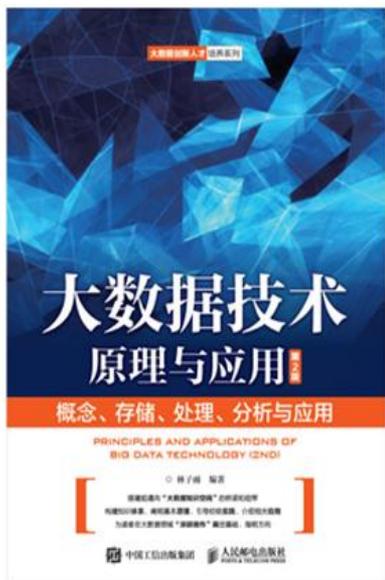




# 附录G：《大数据基础编程、实验和案例教程（第2版）》

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

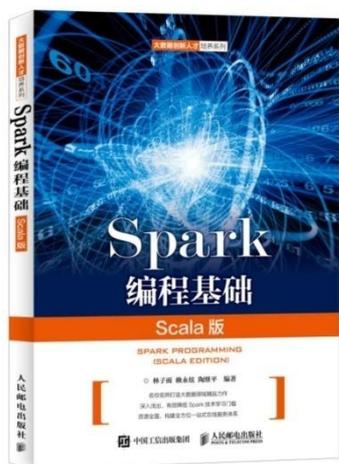


# 附录H: 《Spark编程基础 (Scala版)》

## 《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)》

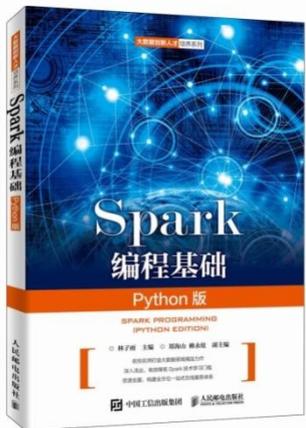
## 《Spark编程基础 (Python版)》

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://dbllab.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://dbllab.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》

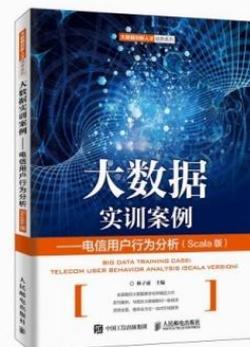
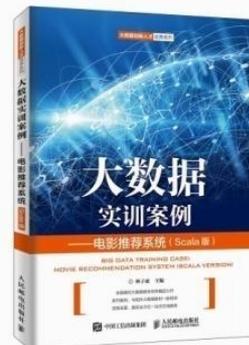
《微博用户情感分析》

《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 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 upwards with their hand to their face. On the left side, two people are shown in profile, one appearing to be speaking or gesturing towards the other. The overall scene suggests a community or a group of people.

**Thank You!**

**Department of Computer Science, Xiamen University, 2022**