

数据科学与大数据技术系列

# Python数据分析 基础教程

王斌会 王术 ○ 编著



中国工信出版集团



电子工业出版社  
PUBLISHING HOUSE OF ELECTRONICS INDUSTRY  
<http://www.phei.com.cn>

数据科学与大数据技术系列

# Python 数据分析基础教程

王斌会 王术 编著



电子工业出版社  
Publishing House of Electronics Industry  
北京 · BEIJING

## 内 容 简 介

本书重点介绍 Python 语言数据处理与数据分析方面的应用技巧，内容涉及数据收集与整理、数据分析软件介绍、Python 编程分析基础、数据的探索性分析、数据的可视化分析、数据的统计分析、数据的模型分析、数据的预测分析、数据的决策分析、数据的案例分析。本书内容丰富，图文并茂，可操作性强且便于查阅，主要面向希望应用 Python 进行数据分析的读者，能有效地帮助读者提高数据处理与分析的水平，提升工作效率。本书建立了学习博客 (<http://blog.leanote.com/DaPy>)，书中的例子数据和习题数据都可直接在该博客下载使用（也可在华信教育资源网 <http://www.hxedu.com.cn> 免费下载）。

本书适合各个层次的数据分析用户阅读，既可作为初学者的入门指南，又可作为中高级用户的参考手册，同时也可作为各大中专院校和培训班的数据分析教材。

未经许可，不得以任何方式复制或抄袭本书之部分或全部内容。

版权所有，侵权必究。

### 图书在版编目(CIP)数据

Python 数据分析基础教程 / 王斌会, 王术编著. —北京: 电子工业出版社, 2018.10

ISBN 978-7-121-33938-7

I. ①P… II. ①王… ②王… III. ①软件工具—程序设计—高等学校—教材 IV. ①TP311.561

中国版本图书馆 CIP 数据核字(2018)第 062017 号

策划编辑：秦淑灵

责任编辑：秦淑灵

印 刷：三河市鑫金马印装有限公司

装 订：三河市鑫金马印装有限公司

出版发行：电子工业出版社

北京市海淀区万寿路 173 信箱 邮编：100036

开 本：787×1092 1/16 印张：12 字数：240 千字

版 次：2018 年 10 月第 1 版

印 次：2018 年 10 月第 1 次印刷

定 价：45.00 元

凡所购买电子工业出版社图书有缺损问题，请向购买书店调换。若书店售缺，请与本社发行部联系，联系及邮购电话：(010) 88254888, 88258888。

质量投诉请发邮件至 [zlts@phei.com.cn](mailto:zlts@phei.com.cn)，盗版侵权举报请发邮件至 [dbqq@phei.com.cn](mailto:dbqq@phei.com.cn)。

本书咨询联系方式：[qinshl@phei.com.cn](mailto:qinshl@phei.com.cn)。

# 前　　言

众所周知，数据分析是以数理统计为基础，运用统计学的基本原理和方法，结合计算机对实际资料和信息进行收集、整理和分析的一门科学。因此，它的原理较为抽象，对学生的数学基础要求也较高，教学中存在大量的数学公式、数学符号、矩阵运算和统计计算，必须借助于现代化的计算工具。

“人生苦短，我要用 Python”，这是网上对 Python 评价最多的一句话。目前我国许多地区的高考试卷中都加入了 Python 编程的内容，更有甚者，一些中小学也开始开设 Python 编程课程，说明 Python 作为一种新兴的编程语言，已深入人心。

本书重点介绍 Python 语言数据处理与数据分析方面的应用技巧，内容涉及数据收集与整理、数据分析软件介绍、Python 编程分析基础、数据的探索性分析、数据的可视化分析、数据的统计分析、数据的模型分析、数据的预测分析、数据的决策分析、数据的案例分析等数据分析方面的内容。

全书共 10 章内容，其中第 1~3 章主要讲解数据分析的一些基础知识，重点介绍如何进行数据的收集、整理和分析，以及 Python 数据的处理和编程技巧；第 4~7 章主要讲解数据分析的一些常用数据分析方法，如数据的可视化、基本数据分析方法和模型分析；第 8~10 章介绍数据的一些简单预测决策方法，并给出了一些应用 Python 方法的数据分析案例。

本书内容丰富，图文并茂，可操作性强且便于查阅，主要面向希望应用 Python 进行数据分析的读者，能有效地帮助读者提高数据处理与分析的水平，提升工作效率。本书适合各层次的数据分析用户阅读，既可作为初学者的入门指南，又可作为中高级用户的参考手册，同时也可作为各大中专院校和培训班的数据分析教材。

为方便读者学习和使用 Python 的数据分析技术，本书具有三大优点。

(1) 使用 Python 科学计算发行版 Anaconda，方便数据分析者使用。

该版本可从 <https://www.anaconda.com/> 下载安装并直接使用。

(2) 公开本书自定义函数的源代码，使用者可以深入理解 Python 函数的编程技巧，用这些函数建立自己的开发包；并建立了本书的学习博客 (<http://blog.leanote.com/DaPy>)，书中的数据、代码、例子、习题都可从该报告下载并直接使用（也可以在华信教育资源网 <http://www.hxedu.com.cn> 免费下载）。

(3) 采用网络化教学平台：Python 的基础版缺少一个面向一般人群的菜单界面，这

对那些只想用其进行数据分析的使用者而言是一大困难，本书采用流行的 Python 网络分析平台 Jupyter (<https://jupyter.org/try>)，该平台可作为数据分析教学软件使用。

书中软件输出的坐标图多数没有标出横、纵坐标的量，目的是与软件界面保持一致。

本书由王斌会、王术共同完成，其中第 1~6 章由王斌会撰写，第 7~10 章由王术撰写，王斌会负责全书统稿。侯雅文、何志峰、颜斌、徐锋和刘霞等进行了校对，在此深表谢意！

本书在写作过程中得到了广东时汇信息科技有限公司的大力支持，并使用了其公司提供的蜜蜂实训平台，为实战操作提供了可靠的应用环境，同时公司协调云计算工程师周剑辉、周政江等对实验步骤进行了详细的验证，在此表示衷心感谢！

由于作者知识和水平有限，书中难免有错误和不足之处，欢迎读者批评指正！

编著者

2018 年 8 月于暨南园

本书编写是基于对大数据时代的理解，通过学习大数据技术，可以更好地理解大数据时代。本书从大数据的基本概念入手，介绍了大数据的特征、大数据的处理方法、大数据的存储、大数据的分析、大数据的可视化、大数据的机器学习、大数据的深度学习、大数据的推荐系统、大数据的实时计算、大数据的流式处理、大数据的分布式系统、大数据的云平台、大数据的开源平台、大数据的实践案例等。通过学习本书，读者可以掌握大数据的基本原理和应用方法，从而更好地应对大数据时代的挑战。

# 目 录

<b>第 1 章 数据的收集与整理</b>	1
1.1 数据的类型	1
1.1.1 按度量尺度分	1
1.1.2 按时间状况分	1
1.2 数据的收集	2
1.2.1 横向数据的收集	2
1.2.2 纵向数据的收集	6
1.3 数据的管理	7
1.3.1 表格管理数据	7
1.3.2 数据库管理数据	8
数据及练习	8
<b>第 2 章 数据分析软件介绍</b>	10
2.1 数据分析软件简介	10
2.2 Python 语言介绍	11
2.2.1 Python 简介	11
2.2.2 Python 的功能	12
2.2.3 Python 编程环境	14
2.3 Python 数据分析平台	17
2.3.1 Jupyter 数据分析平台	18
2.3.2 Python 在线分析平台	23
2.4 Python 编程入门	27
2.4.1 Python 的工作目录	27
2.4.2 Python 分析包（库）	27
2.4.3 Python 中的数据管理	29
数据及练习	29
<b>第 3 章 Python 编程分析基础</b>	30
3.1 Python 数据类型	30
3.1.1 Python 对象	30
3.1.2 数据的基本类型	31
3.1.3 标准数据类型	33
3.2 数值分析库 numpy	34

3.2.1 一维数组（向量）	34
3.2.2 二维数组（矩阵）	35
3.2.3 数组的操作	35
3.3 数据分析库 pandas	36
3.3.1 序列（Series）	36
3.3.2 数据框（DataFrame）	37
3.3.3 数据框的读写	39
3.3.4 数据框的操作	41
3.4 Python 编程运算	45
3.4.1 基本运算	45
3.4.2 控制语句	46
3.4.3 函数定义	47
3.4.4 面向对象	49
数据及练习	50
<b>第4章 数据的探索性分析</b>	52
4.1 数据的描述分析	52
4.1.1 基本描述统计量	52
4.1.2 计数数据汇总分析	53
4.1.3 计量数据汇总分析	53
4.2 基本绘图命令	57
4.2.1 常用的绘图函数	57
4.2.2 基于 pandas 的绘图	66
4.3 数据的分类分析	70
4.3.1 一维频数分析	70
4.3.2 二维集聚分析	73
4.3.3 多维透视分析	77
数据及练习	79
<b>第5章 数据的可视化分析</b>	80
5.1 特殊统计图的绘制	80
5.1.1 数学函数图	80
5.1.2 气泡图	82
5.1.3 三维曲面图	82
5.1.4 三维散点图	83
5.2 seaborn 统计绘图	83
5.2.1 基本概念	84
5.2.2 常用统计图	84
5.3 ggplot 绘图系统	88

5.3.1 qplot 快速制图	89
5.3.2 ggplot 基本绘图	90
数据及练习	95
<b>第 6 章 数据的统计分析</b>	<b>97</b>
6.1 随机变量及其分布	97
6.1.1 均匀分布	97
6.1.2 正态分布	98
6.2 数据分析统计基础	102
6.2.1 统计量的概念	102
6.2.2 统计量的分布	103
6.3 基本统计推断方法	106
6.3.1 参数的估计方法	107
6.3.2 参数的假设检验	109
数据及练习	111
<b>第 7 章 数据的模型分析</b>	<b>113</b>
7.1 简单线性相关模型	113
7.1.1 线性相关的概念	113
7.1.2 相关系数的计算	114
7.1.3 相关系数的检验	115
7.2 简单线性回归模型	116
7.2.1 简单线性模型估计	116
7.2.2 简单线性模型检验	118
7.2.3 简单线性模型预测	119
7.3 分组线性相关与回归	120
7.3.1 分组线性相关分析	120
7.3.2 分组线性回归模型	121
数据及练习	122
<b>第 8 章 数据的预测分析</b>	<b>124</b>
8.1 动态数列的基本分析	124
8.1.1 动态数列的介绍	124
8.1.2 动态数列的分析	126
8.2 动态数列预测分析	130
8.2.1 趋势预测构建	130
8.2.2 平滑预测法	134
8.3 股票数据统计分析	138
8.3.1 股票价格分析	139

8.3.2 股票收益率分析 .....	143
数据及练习 .....	147
<b>第9章 数据的决策分析.....</b>	<b>149</b>
9.1 确定性分析 .....	149
9.1.1 单目标求解 .....	149
9.1.2 多目标求解 .....	150
9.2 不确定性分析 .....	151
9.2.1 分析方法 .....	151
9.2.2 分析原则 .....	152
9.3 风险分析 .....	154
9.3.1 期望值法 .....	154
9.3.2 后悔期望值法 .....	155
数据及练习 .....	155
<b>第10章 数据的案例分析 .....</b>	<b>157</b>
10.1 在线数据获取与分析 .....	157
10.1.1 在线财经数据获取 .....	157
10.1.2 在线股票数据分析 .....	159
10.1.3 新股发行数据分析 .....	161
10.2 证券交易数据的分析 .....	163
10.2.1 历史行情数据分析 .....	163
10.2.2 实时行情数据分析 .....	165
10.2.3 大单交易数据分析 .....	167
10.2.4 公司盈利能力分析 .....	168
10.2.5 公司现金流量分析 .....	169
10.3 宏观经济数据的实证分析 .....	170
10.3.1 存款利率变动分析 .....	170
10.3.2 国内生产总值 GDP 分析 .....	172
10.3.3 工业品出厂价格指数分析 .....	174
10.4 电影票房数据的实时分析 .....	175
10.4.1 实时票房数据分析 .....	175
10.4.2 每日票房数据分析 .....	176
10.4.3 影院日度票房分析 .....	177
数据及练习 .....	178
<b>附录 A 本书的学习博客 .....</b>	<b>179</b>
<b>附录 B 书中的例子数据 .....</b>	<b>181</b>
<b>附录 C 书中的自定义函数 .....</b>	<b>182</b>
<b>参考文献 .....</b>	<b>183</b>

# 第1章 数据的收集与整理

## 1.1 数据的类型

数据是采用某种计量尺度对事物进行计量的结果。采用不同的计量尺度会得到不同类型的数据，通常按数据的收集途径将数据进行如下分类。

### 1.1.1 按度量尺度分

按度量尺度，数据可分为定性数据和定量数据。

#### (1) 定性数据（也称计数数据， quantitative data）

度量事物进行分类的结果。数据表现为类别，用文字来表述，如性别、区域、产品分类等。假如某班学生按性别分为男、女两类，那么性别就构成了一个定性数据。

性别：女，男，男，女，男，男，女，男，女，男，女，女，男，男，女，男，女，女

具体见 1.2.1 节例 1.1 调查数据。

#### (2) 定量数据（也称计量数据， quantitative data）

度量事物的精确测度。结果表现为具体的数值，如身高、体重、家庭收入、成绩等，假如测量某班每个学生的体重，那么体重就构成了一个定量数据。

体重：67, 66, 83, 68, 70, 90, 70, 58, 63, 72, …, 65, 76, 71, 66, 65, 68, 65, 77, 70

具体见 1.2.1 节例 1.1 调查数据。

这类数据的详细分析参见王斌会编著的《数据统计分析及 R 语言编程》一书。

### 1.1.2 按时间状况分

这类数据为动态数列（也称时间序列数据， time series data）：是按照一定的时间间隔对某一变量在不同时间的取值进行观测得到的一组数据，反映在不同时间收集到的数据描述现象随时间变化的情况。比如，收集 2001—2015 年各季度我国各地区国内生产总值（GDP，单位：万亿元）的数据，这些数据便形成时间序列数据。

下面是 GDP 的季度数据：

季度	2001Q1	2001Q2	2001Q3	2001Q4	…	2015Q1	2015Q2	2015Q3	2015Q4
GDP	2.330	2.565	2.687	3.384	…	14.067	17.351	17.316	18.937

下面是 GDP 的年度数据：

年份	2001	2002	2003	2004	...	2012	2013	2014	2015
GDP	10.966	12.033	13.582	15.988	...	51.947	58.802	63.646	67.671

具体见 1.2.2 节例 1.3 日期数据。

这类数据的详细分析参见王斌会编著的《计量经济学模型及 R 语言应用》一书。

## 1.2 数据的收集

数据收集有一定的格式，当对一个观察指标测量了每一观察单位的数据时，通常以向量的形式展现，如  $\mathbf{x}: x_1, x_2, \dots, x_n$ 。

当对每一观察单位测量了多个指标时，通常以双向表的矩阵形式展现，即

$$\mathbf{X}: X_1, X_2, \dots, X_m$$

这里  $X_j (j=1, 2, \dots, m)$  为  $n \times 1$  向量， $\mathbf{X} = (x_{ij})_{n \times m}$ ，如表 1-1 所示。

表 1-1 关系型数据库的结构化数据

id	$X_1$	$X_2$	...	$X_m$
1	$x_{11}$	$x_{12}$	...	$x_{1m}$
2	$x_{21}$	$x_{22}$	...	$x_{2m}$
:	:	:	:	:
$n$	$x_{n1}$	$x_{n2}$	...	$x_{nm}$

不同领域对该数据的观察单位和指标的叫法不同：数学上称它们为行（row）和列（column）的数组或矩阵；统计学上称它们为观测（observation）和变量（variable）的数据集；数据库中称它们为记录（record）和字段（field）的数据表，人工智能中称它们为示例（example）和属性（attribute）的数据集。

为便于大家将注意力集中在如何进行数据分析，而不是将精力花在对数据的收集和输入上，本书采用一种新的数据分析策略，即通篇使用几组数据讲解如何进行数据分析。

### 1.2.1 横向数据的收集

这类数据通常是一个个单独的数据变量，都可单独拿来进行数据分析。

#### 【例 1.1 调查数据】

某高校想给其研究生开设一门有关数据分析方面的通识课程，该校 2015 年共有研究生 2600 名，现按 2% 的比例随机抽取 52 名学生进行问卷调查，为了收集这些学生的信息，我们设计了一个简单调查表，其中前 4 项指标是为进一步的数据分析辅助用的。共调查了这些学生的 8 项指标：学生编号（按年份、学院、专业、序号排列，简记为【学号】；学生

性别（定性变量，简记为【性别】）；学生身高（定量变量，单位 cm，简记为【身高】）；学生体重（定量变量，单位 kg，简记为【体重】）和学生个人年消费支出额（定量变量，单位千元，简记为【支出】）；开设课程的必要性（简记为【开设】）；是否学过相关课程（定性变量，简记为【课程】）；是否学过或用过何种数据分析相关软件（定性变量，简记为【软件】）。

研究生【数据分析】开课信息调查表	
【学号】	1510111001, .....
【性别】	男, 女
【身高】	165
【体重】	67
【支出】	7.5
【开设】	有必要, 不必要, 不清楚
【课程】	编程技术, 概率统计, 统计方法, 都学习过, 都未学过
【软件】	SAS, SPSS, Matlab, R, Excel, Python, No

数据由一些变量及其观测值所组成。本例共有 8 个变量：编号（定性或定量）、开设、课程、软件和性别（定性变量），以及身高、体重和支出（定量变量）等。

为了充分体现现代问卷调查的能力，我们使用问卷星设计网络化调查问卷，只要进入问卷星（<https://www.wjx.cn/>）网站便可快速设计。

下面是我们设计的网络调查问卷，可以输入网址

<https://www.wjx.top/jq/21099021.aspx>

或扫二维码进行答卷。



### 【数据分析】开课调查表



1. 学号 \*

2. 性别 \*

男

女

3. 身高 (cm) \* (从100到200)

4. 体重 (kg) \* (从40到100)

5. 支出 (千元) \* (最大值500)

6. 数据分析开设情况 \*

有必要

不必要

不清楚

7. 课程学习情况 \* [多选题]

编程技术

概率统计

统计方法

都学习过

都未学过

8. 数据分析软件 \* [多选题]

Excel

SPSS

SAS

R

Python

No

表 1-2 是 52 名研究生的个人信息调查数据，按照这个数据的格式，每列为一个指标的不同观测值（变量）；而每行则称为一个观测单位（样品），它是由定量值和定性值组成的向量，每个值相应于一个变量。于是就构成了表 1-2 的数据集，该数据保存在 DaPy\_data.xlsx 文档的基本数据【BSdata】表单中。有时为了方便编程运算，也可将变量名改成英文或拼音格式。

表 1-2 52 名研究生的个人信息调查数据

学号	性别	身高	体重	支出	开设	课程	软件
1510248008	女	167	71	46.0	不清楚	都未学过	No
1510229019	男	171	68	10.4	有必要	概率统计	Matlab
1512108019	女	175	73	21.0	有必要	统计方法	SPSS
1512332010	男	169	74	4.9	有必要	编程技术	Excel
1512331015	男	154	55	25.9	有必要	都学习过	Python
1516248014	男	183	76	85.6	不必要	编程技术	Excel
1516352030	女	169	71	9.1	有必要	编程技术	Excel

续表

学号	性 别	身 高	体 重	支 出	开 设	课 程	软 件
1516171019	女	166	66	2.5	不必要	都未学过	Excel
1516391008	女	165	69	35.6	不必要	都未学过	Excel
1520395019	男	173	63	22.8	有必要	统计方法	R
1520100029	男	184	82	10.3	有必要	都学习过	SAS
1520324035	男	163	66	13.0	有必要	概率统计	Matlab
1522186005	男	162	63	9.8	有必要	都学习过	SPSS
1522160006	女	168	72	35.3	不必要	统计方法	SPSS
1522274026	女	164	66	50.5	有必要	统计方法	SPSS
1523376027	男	180	81	64.1	有必要	统计方法	Excel
1523368030	女	158	63	20.6	不清楚	都学习过	Excel
1524225006	男	179	75	5.8	有必要	编程技术	Python
1524105026	女	163	65	69.4	有必要	编程技术	Python
1524286013	男	160	62	4.8	有必要	都未学过	R
1525235027	女	168	70	8.2	有必要	都学习过	R
1525352033	男	185	83	5.1	有必要	都学习过	SPSS
1526177005	男	174	76	15.8	有必要	概率统计	Excel
1526196010	男	167	72	9.8	不清楚	统计方法	SPSS
1527173011	女	160	62	11.5	不必要	都学习过	Matlab
1527237032	女	163	65	19.4	有必要	统计方法	R
1527289024	男	155	50	10.8	有必要	概率统计	SPSS
1529107020	男	178	78	8.9	不清楚	概率统计	Matlab
1529314037	男	170	70	15.1	有必要	概率统计	SAS
1529245023	男	164	58	21.9	有必要	统计方法	Excel
1529365032	男	172	71	10.4	有必要	都学习过	SPSS
1530273031	男	178	77	35.6	不必要	统计方法	R
1530243029	男	186	87	9.5	不必要	都未学过	No
1531364037	女	171	69	7.3	有必要	都学习过	Excel
1531316038	女	156	56	52.8	有必要	统计方法	Excel
1532304031	女	166	68	47.9	不清楚	统计方法	SAS
1532208040	男	176	78	75.5	不必要	概率统计	Excel
1532292012	男	178	78	28.4	不必要	概率统计	No
1532185004	女	155	54	13.4	不清楚	编程技术	Excel
1533219013	女	163	62	11.1	不清楚	概率统计	Matlab
1533384028	男	158	60	6.1	有必要	编程技术	R
1533172017	女	167	68	27.2	不必要	都未学过	Excel
1537288004	女	173	70	19.1	不清楚	编程技术	Python
1537359035	女	174	71	17.6	不清楚	概率统计	No
1438391022	女	164	62	10.3	有必要	编程技术	Python
1538399025	男	169	65	9.5	有必要	统计方法	SAS
1438120022	男	166	70	35.6	有必要	统计方法	R

续表

学号	性别	身高	体重	支出	开设	课程	软件
1538319004	男	175	68	44.4	不清楚	统计方法	SAS
1538254010	女	166	65	5.3	不清楚	编程技术	Python
1540294017	女	159	58	71.4	不清楚	都学习过	SPSS
1540365026	女	169	73	5.5	有必要	统计方法	Excel
1540388036	女	165	67	56.8	不必要	概率统计	SAS

## 1.2.2 纵向数据的收集

纵向数据是一类比较特殊的数据，这类数据也称为序列数据，它对数据的格式有一定要求，特别是时间序列数据，须注意时间序列数据的输入格式。

### 【例 1.2 季节数据：经济数据】

年度数据有时太过宏观，须研究季节（季度或月度）数据，以了解不同季度或月度 GDP 的变化。现从国家统计局网站 (<http://data.stats.gov.cn/>) 收集到 2001—2015 年每个季度我国 GDP 的数据，就形成了一个时间序列数据集，共 15 年 60 个数据，该数据存放在 DaPy\_data.xlsx 文档的季度数据【QTdata】表中。2001—2015 年我国内生产总值的季度数据如表 1-3 所示。

表 1-3 2001—2015 年我国内生产总值的季度数据

年份	一季度	二季度	三季度	四季度
2001	2.330	2.565	2.687	3.384
2002	2.536	2.797	2.972	3.728
2003	2.886	3.101	3.346	4.249
2004	3.342	3.699	3.956	4.991
2005	3.912	4.280	4.474	5.828
2006	4.532	5.011	5.191	6.897
2007	5.476	6.124	6.410	8.571
2008	6.628	7.419	7.655	9.702
2009	6.982	7.839	8.310	10.96
2010	8.250	9.238	9.729	12.934
2011	9.748	10.901	11.586	15.076
2012	10.837	11.963	12.574	16.573
2013	11.886	12.916	13.908	20.092
2014	12.821	14.083	15.086	21.656
2015	14.067	17.351	17.316	18.937

### 【例 1.3 日期数据：股票数据】

今从某证券网站（此类网站很多）收集到 2005—2017 年苏宁易购（股票代码为 002024）每个交易日的股票基本数据（包括开盘价 Open、最高价 High、最低价 Low、收盘价 Close、

成交量 Volume 及调整收盘价 Adjusted)，这是一种典型的日期时间序列数据集，共 13 年 3180 组数据，该数据存放在 DaPy\_data.xlsx 文档的股票数据【Stock】表中。苏宁电器日交易数据如表 1-4 所示。

表 1-4 苏宁电器日交易数据

date	Open	High	Low	Close	Volume	Adjusted
2005-1-3	0.702	0.717	0.702	0.712	0	0.618
2005-1-4	0.709	0.721	0.694	0.695	10958717	0.603
2005-1-5	0.695	0.708	0.695	0.705	6165072	0.611
2005-1-6	0.702	0.706	0.696	0.696	9845971	0.604
2005-1-7	0.695	0.709	0.694	0.702	13667162	0.608
...	...	...	...	...	...	...
2017-12-25	12.73	12.74	12.25	12.38	65681626	12.38
2017-12-26	12.46	12.54	12.37	12.52	30913299	12.52
2017-12-27	12.54	12.57	12.1	12.18	53813380	12.18
2017-12-28	12.2	12.28	12.06	12.18	33692919	12.18
2017-12-29	12.18	12.33	12.14	12.29	25372331	12.29

进一步，还可以收集股票指数的时数据、分数据、秒数据、毫秒数据和微秒数据，这类数据就形成了高频数据，是一种大数据，限于篇幅，本书将不涉及。

上述数据都是结构化数据，随着大数据时代的来临，出现了大量的非结构化数据，这些数据不只是由数字构成的数据库，还包括大量的文字、图像、影像和视频数据，关于这类数据的分析，限于篇幅，将不重点介绍。

## 1.3 数据的管理

数据管理是利用计算机硬件和软件技术对数据进行有效的收集、存储、处理和应用的过程。对于一般的数据分析而言，电子表格软件已经足以胜任分析所需要的数据管理工作。最常用的电子表格软件有微软 Office 的 Excel 表格软件（收费）和金山 Office 的 WPS 表格软件（免费）。

### 1.3.1 表格管理数据

如果仅做一般数据管理，数据量不太大，而且要求系统免费、跨平台，那么首选的数据管理软件应该是 WPS 表格软件（WPS 表格是与 Excel 兼容度最高的电子表格软件，但 WPS 是免费的，建议使用）。下页是采用 WPS 表格对前面的数据进行管理的界面。

数据保存在 DaPy\_data.xlsx 文档中，可在网址 blog.leanote.com/DaPy 下载该数据。

The screenshot shows a WPS Office spreadsheet application window. The title bar reads "WPS DaPy\_data.xlsx". The ribbon menu includes "开始", "插入", "页面布局", "公式", "数据", "审阅", "视图", and "开发". The "开始" tab is selected. The toolbar below has icons for "剪切", "复制", "粘贴", "格式刷", "字体", "字号", "段落", "对齐方式", "合并居中", "自动换行", and "条件格式". The main area displays a data table with columns labeled A through L. Column A is "学号" (Student ID), B is "性别" (Gender), C is "身高" (Height), D is "体重" (Weight), E is "支出" (Expenditure), F is "开设" (Offered), G is "课程" (Course), H is "软件" (Software), I is blank, J is blank, K is blank, and L is blank. The data consists of 25 rows of student information, such as gender, height, weight, expenditure, course offered, and software used. The bottom of the window shows tabs for "BSdata", "QTdata", "Stock", and "Target".

A	B	C	D	E	F	G	H	I	J	K	L
1	学号	性别	身高	体重	支出	开设	课程	软件			
2	1510248008	女	167	71	46.0	不清楚	都未学过	No			
3	1510229019	男	171	68	10.4	有必要	概率统计	Matlab			
4	1512108019	女	175	73	21.0	有必要	统计方法	SPSS			
5	1512332010	男	169	74	4.9	有必要	编程技术	Excel			
6	1512331015	男	154	55	25.9	有必要	都学习过	Python			
7	1516248014	男	183	76	85.6	没有必要	编程技术	Excel			
8	1516352030	女	169	71	9.1	有必要	编程技术	Excel			
9	1516171019	女	166	66	2.5	没有必要	都未学过	Excel			
10	1516391008	女	165	69	35.6	没有必要	都未学过	Excel			
11	1520395019	男	173	63	22.8	有必要	统计方法	R			
12	1520100029	男	184	82	10.3	有必要	都学习过	SAS			
13	1520324035	男	163	66	13.0	有必要	概率统计	Matlab			
14	1522186005	男	162	63	9.8	有必要	都学习过	SPSS			
15	1522160006	女	168	72	35.3	没有必要	统计方法	SPSS			
16	1522274026	女	164	66	50.5	有必要	统计方法	SPSS			
17	1523376027	男	180	81	64.1	有必要	统计方法	Excel			
18	1523368030	女	158	63	20.6	不清楚	都学习过	Excel			
19	1524225006	男	179	75	5.8	有必要	编程技术	Python			
20	1524105026	女	163	65	69.4	有必要	编程技术	Python			
21	1524286013	男	160	62	4.8	有必要	都未学过	R			
22	1525235027	女	168	70	8.2	有必要	都学习过	R			
23	1525352033	男	185	83	5.1	有必要	都学习过	SPSS			
24	1526177005	男	174	76	15.8	有必要	概率统计	Excel			
25	1526196010	男	167	72	9.8	不清楚	统计方法	SPSS			

### 1.3.2 数据管理数据

当分析的数据量很大时，采用电子表格类软件有很大问题，须采用数据库来管理数据表格，详见相关文献。

## 数据及练习

将下面的数据统一放入一个 Excel 或 WPS 电子表格中，每个 sheet 放一组，并给文档起名为 mydata1.xlsx，以备后用。

1. 某厂对 50 个计件工人某月的工资进行登记，获得以下原始资料（单位：元）。

1465, 1405, 1355, 1225, 1000, 1760, 1755, 1710, 1605, 1535,  
1985, 1965, 1910, 1845, 1810, 2270, 2240, 2190, 2040, 2010,  
2980, 2820, 2600, 2430, 2290, 1375, 1295, 1265, 1175, 1125,  
1735, 1645, 1625, 1595, 1575, 1940, 1880, 1865, 1835, 1815,  
2220, 2110, 2095, 2030, 2030, 2670, 2550, 2520, 2370, 2320,