

会计大数据管理分析

暨南大学 **MPAcc** 2025 级

王新路

2025 年 11 月 04 日

Table of contents

课程信息	11
教师信息	11
课程内容	11
课程考核	11
微助教课堂	12
课件下载	12
1 Python 环境配置	13
1.1 安装 Python	13
1.2 安装 VS Code	13
1.3 测试安装	13
1.4 pip 设置阿里云镜像	14
1.5 UV 安装 (可选)	14
1.5.1 simple install	14
1.5.2 Or, native install	14
1.5.3 设置 project 镜像	15
1.5.4 设置 User 镜像	15
1.5.5 uv 简单实用	15
1.6 AI 编程工具 (可选)	15
2 Python 入门	16
2.1 Why Python	16
2.1.1 最受欢迎的编程语言	16
2.2 Hello World Demo	16
2.2.1 Jupyter Notebook 快捷键	17
2.3 编程：让机器执行你的指令	17

2.3.1	现实生活中的指令（煎蛋步骤）	17
2.3.2	编程中的指令	17
2.4	数据类型	18
2.4.1	字符串和数字的区别	18
2.5	字符串 Strings 介绍	19
2.5.1	特殊字符串	19
2.5.2	字符串索引切片	20
2.5.3	字符串基本操作	21
2.6	数字类型	22
2.6.1	数字运算	22
2.6.2	数字类型检查	22
2.6.3	类型转换	23
2.6.4	数字字符转换	23
2.7	变量	24
2.7.1	变量示例	24
2.7.2	变量命名规则	24
2.7.3	练习：判断合法的变量名？	24
2.7.4	注意事项	24
2.7.5	变量赋值	25
2.8	字符串格式化	25
2.8.1	这样会出错	26
2.8.2	正确的方式	26
2.8.3	Format string 方式	26
2.8.4	Format String 更多例子	26
2.9	函数	27
2.9.1	无返回值函数	27
2.9.2	自定义函数	28
2.9.3	Lambda 函数（可选）	29
2.10	容器数据类型（ container ）	29
2.10.1	列表 List	29
2.10.2	元组 Tuple	31
2.10.3	集合 Set	32

2.10.4	字典 Dict	33
2.11	流程控制	35
2.11.1	for 循环	35
2.11.2	布尔类型	36
2.11.3	条件判断	37
2.11.4	if 语句	37
2.11.5	循环控制关键字	39
2.11.6	while 循环	40
2.12	模块和包	41
2.12.1	包 Package	41
2.12.2	自己的模块 Module	42
2.13	错误处理	42
2.14	Markdown 基本语法	43
2.14.1	标题	43
2.14.2	强调	44
2.14.3	列表	44
2.14.4	链接	45
2.14.5	图片	45
2.14.6	引用	45
2.14.7	代码	45
2.14.8	分割线	46
2.14.9	表格	46
2.14.10	公式	46
2.14.11	Markdown Display	47
2.14.12	Markdown 编辑器	47
3	python 调用 LLM	48
3.1	配置环境变量 KEY	48
3.2	不同模型调用	48
3.2.1	zhipu AI	48
3.2.2	deepseek	49
3.2.3	阿里千问	49
3.3	模型回复结构	50

3.4	简单问答	51
3.4.1	display response markdown	54
3.4.2	模型列表	54
3.5	自定义函数	54
3.6	JSON output 格式化	55
3.7	财务数据 sentiment analysis	58
3.8	订餐系统	61
3.8.1	messages 结构	61
4	pandas 数据框	64
4.1	Pandas 处理表格数据	64
4.1.1	安装所需包	64
4.1.2	导入 pandas	64
4.1.3	创建示例数据	64
4.2	DataFrame 结构与属性	65
4.2.1	索引 (index)	66
4.2.2	列名 (columns)	66
4.2.3	值 (values)	67
4.2.4	形状 (shape)	67
4.2.5	数据类型 (dtypes)	67
4.2.6	基本信息 (info)	67
4.3	DataFrame 行列操作	68
4.3.1	访问列	68
4.3.2	访问行	69
4.3.3	转置	70
4.3.4	查看头尾数据	71
4.3.5	创建 DataFrame	72
4.4	DataFrame 导入与导出	73
4.4.1	读取 CSV 文件	73
4.4.2	读取 Excel 文件	74
4.4.3	处理大文件	74
4.4.4	导出数据	75
4.4.5	错误处理	75

4.5	数据清洗 (Data Cleaning)	76
4.5.1	检查缺失值	76
4.5.2	处理缺失值	77
4.5.3	检测重复数据	79
4.5.4	数据类型转换	81
4.5.5	数据验证	84
4.6	DataFrame 筛选与条件过滤	86
4.6.1	切片操作	87
4.6.2	条件筛选	88
4.6.3	使用 <code>isin</code> 筛选	90
4.6.4	<code>query()</code> 方法	91
4.7	数据操作	91
4.7.1	赋值	91
4.7.2	排序	93
4.7.3	按值排序	93
4.7.4	重命名	94
4.7.5	选择性重命名	94
4.7.6	删除行/列	95
4.7.7	删除列	95
4.8	统计计算与自定义函数	96
4.8.1	统计量	96
4.8.2	标准差	96
4.8.3	描述性统计	96
4.8.4	财务计算	97
4.8.5	财务比率计算	101
4.9	实用工具函数	105
4.9.1	自定义函数	105
4.9.2	字符串操作	105
4.9.3	获取字符串长度	106
4.9.4	判断是否包含特定字符	106
4.9.5	字符串索引	107
4.9.6	随机抽样	107

4.9.7 按比例抽样	107
4.10 数据合并	108
4.10.1 concat 合并	108
4.10.2 merge 合并	110
4.11 时间日期处理	111
4.12 数据可视化	113
4.13 分组与聚合 (Grouping & Aggregation)	115
4.13.1 基本分组	115
4.13.2 多维度聚合	117
4.13.3 创建汇总表 (带小计和合计)	119
4.13.4 条件聚合	120
4.13.5 Excel 风格的对比	122
4.13.6 数据透视表 (Pivot Tables)	123
4.14 综合案例: 销售收入分析	130
4.14.1 步骤 1: 准备数据	130
4.14.2 步骤 2: 数据清洗与验证	132
4.14.3 步骤 3: 财务分析	133
4.14.4 步骤 4: 应收账款分析	139
4.14.5 步骤 5: 生成管理报告	141
4.15 总结与下一步	144
4.15.1 Pandas 核心概念回顾	144
4.15.2 与 Excel 的对比	144
4.15.3 学习建议	144
4.15.4 下一步学习方向	145
4.15.5 推荐资源	145
5 SQL 入门与实战	146
5.1 SQL 语言简介	146
5.1.1 数据库基础概念	146
5.1.2 SQLite3 介绍	146
5.2 DB Browser for SQLite GUI 工具	147
5.2.1 安装和使用	147
5.2.2 优势	147

5.3	使用 Python 接入 SQLite3	147
5.3.1	创建数据库和表	148
5.4	使用 Pandas 与 SQLite3 交互	152
5.4.1	创建会计分录表	152
5.4.2	高级 SQL 操作	157
5.4.3	DISTINCT - 去重查询	187
5.4.4	CASE 语句 - 条件逻辑	189
5.4.5	UNION - 合并查询结果	192
5.4.6	处理大数据: 使用 chunksize	194
5.5	综合案例: 企业财务分析仪表盘	196
5.5.1	步骤 1: 综合数据准备	196
5.5.2	步骤 2: 收入成本分析	197
5.5.3	步骤 3: 客户价值与信用分析	199
5.5.4	步骤 4: 应收账款健康度分析	201
5.5.5	步骤 5: 财务健康度综合评分	202
5.5.6	案例总结	205
5.5.7	关闭数据库连接	207
5.6	总结	208
5.6.1	本章学习内容回顾	208
5.6.2	SQL 在会计工作中的价值	209
5.6.3	下一步学习建议	209
6	文件路径与数据持久化	211
6.1	环境准备	211
6.2	路径操作基础	211
6.3	路径拆分	212
6.4	文本文件读写	213
6.5	文件重命名	215
6.6	COPY/MOVE/DELETE 文件/文件夹	216
6.7	文件搜索与批量处理	217
6.8	保存和加载 Python 单个对象	219
6.9	保存和加载 Python 多个对象	220
6.10	DataFrame 拆分例子	221

6.11 DataFrame 读取例子	221
7 文本分析入门	223
7.1 Spacy 模型	223
7.2 加载模型	223
7.2.1 自定义分词	228
7.2.2 自定义 stopwords	228
7.3 加载审计数据	229
7.4 清洗文本	229
7.5 词频向量	230
7.5.1 基于词典的方法	236
7.6 词云	238
7.7 词表占比	269
7.8 相似度	273
8 可视化	276
8.1 Matplotlib 数据可视化	276
8.1.1 设置绘图样式	277
8.1.2 关于 plt.show()	278
8.2 Pandas plot	283
8.3 Plotly 交互式可视化	297
8.3.1 安装 Plotly	297
8.3.2 Plotly Express 基础示例	298
8.4 Seaborn 可视化库	300
8.5 folium 地图可视化	304
9 网络爬虫	318
9.1 网页基础知识	318
9.1.1 核心概念	318
9.2 爬虫基础	321
9.2.1 分析网址规律	321
9.2.2 requests 库	321
9.2.3 Response 响应对象	323
9.2.4 巨潮资讯网	325

9.3	模拟浏览器	350
9.3.1	异步 API 示例 (Notebook 推荐)	350
9.3.2	完整的网页自动化示例	351
9.3.3	同步 API (仅供参考, 不在 Notebook 中使用)	353
9.4	解析 HTML	353
9.4.1	方法一: 使用 Parsel + CSS 选择器	354
9.4.2	方法二: 使用 Parsel + XPath	360
9.4.3	下载图片示例	364
9.5	总结	364

课程信息

教师信息

- 王新路 (8) + 谭有超 (4) = 12
- Office: 管理学院 603 室
- Office Hour: 预约

课程内容

1. Python 基础
2. Pandas 数据分析
3. SQL 应用
4. 数据可视化
5. 简单文本分析
6. 网络爬虫
7. AI 自动化工具的应用

课程考核

形式	说明	分值
教学过程	考勤、讨论、回答问题	15%
课后作业	认真完成	20%
数据分析案例	小组报告	65%

微助教课堂

关注微助教服务号 -> 学生 (S) -> 全部 (A) -> 加入课堂 -> 输入课堂编号

- 暨南大学会计大数据管理分析 (周一下午): **PN087**
- 暨南大学会计大数据管理分析 (周二下午): **PN088**
- 暨南大学会计大数据管理分析 (周二晚上): **PN089**

课件下载

[课程介绍 ppt 下载](#)

1 Python 环境配置

1.1 安装 Python

Anaconda 是 Python 发行版本，包含了常用的 Python 包，可以快速安装和管理 Python 环境，适合于数据科学、机器学习、深度学习等领域的用户。Miniconda 是 Anaconda 的轻量级版本，包含 Python、conda、pip 三个基本包，适合于服务器环境。

- 推荐使用 Anaconda 安装 [下载](#)，时间比较久耐心等待。
 - 安装的路径上（位置）不要有中文或空格，每一层文件夹名只能有字母数字和下划线。

1.2 安装 VS Code

- 安装 VS Code: [下载](#)
- 安装 VS code 的 Python 插件:
 - [Python Extension](#) 点击安装
 - [Jupyter Extension](#) 点击安装

1.3 测试安装

- 打开 VS Code -> File -> New File -> Jupyter Notebook
 - 右上角:[Select Kernel]->[Select Another Kernel]->[Python Environment]
-> 选择你的 Python 环境
 - 点击 + Code -> 输入 `print("Hello, World!")` 并运行。

1.4 pip 设置阿里云镜像

```
pip config set global.index-url https://mirrors.aliyun.com/pypi/simple/
```

1.5 UV 安装 (可选)

安装uv用于管理 packages 和 python 版本:

1.5.1 simple install

```
pip install uv
```

1.5.2 Or, native install

On macOS and Linux.

```
curl -LsSf https://astral.sh/uv/install.sh | sh
```

On Windows

```
powershell -ExecutionPolicy ByPass -c "irm  
↔ https://astral.sh/uv/install.ps1 | iex"
```

或者

```
winget install --id=astral-sh.uv -e
```

或者

uv release page: <https://github.com/astral-sh/uv/releases> 可以下载最新版本的.exe

1.5.3 设置 project 镜像

```
[[tool.uv.index]]  
url = "https://mirrors.aliyun.com/pypi/simple/"  
default = true
```

1.5.4 设置 User 镜像

C:\Users\sean\AppData\Roaming\uv\uv.toml
~/.config/uv/uv.toml

```
[[index]]  
url = "https://mirrors.aliyun.com/pypi/simple/"  
default = true
```

1.5.5 uv 简单实用

```
uv init project_name # 创建项目  
uv venv # 创建虚拟环境  
uv add <package> # 安装包  
uv remove <package> # 删除包  
uv sync # 同步
```


1.6 AI 编程工具（可选）

- [vs code extension: Cline 点击安装](#)
- [vs code extension: GitHub.copilot 点击安装](#)
- [vs code extension: GitHub.copilot chat 点击安装](#)
- [vs code extension: LingMa 点击安装](#)

2 Python 入门

[点击下载本章节代码](#)

2.1 Why Python



2.1.1 最受欢迎的编程语言

- 支持性社区
- ChatGPT 等 AI 工具更可靠

2.2 Hello World Demo

让我们开始第一个 Python 程序：

1 + 1

2

2.2.1 Jupyter Notebook 快捷键

- 执行单元格程序 Shift + Enter (Shift + Return on a Mac)
- 插入新单元格 B (below) 或 A (above)
- 删除单元格 D + D (按两次 D)
- 保存 Ctrl + S (Cmd + S on a Mac)
- # 开始的行为注释，不会被执行

2.3 编程：让机器执行你的指令

2.3.1 现实生活中的指令（煎蛋步骤）

1. 将一个鸡蛋打入小碗中，确保没有蛋壳，放在一旁备用。
2. 在不粘锅中加入黄油或其他油脂，用中高火加热一分钟。
3. 将鸡蛋倒入锅中，煮三到四分钟。
4. 上桌，根据个人口味添加盐和胡椒。

2.3.2 编程中的指令

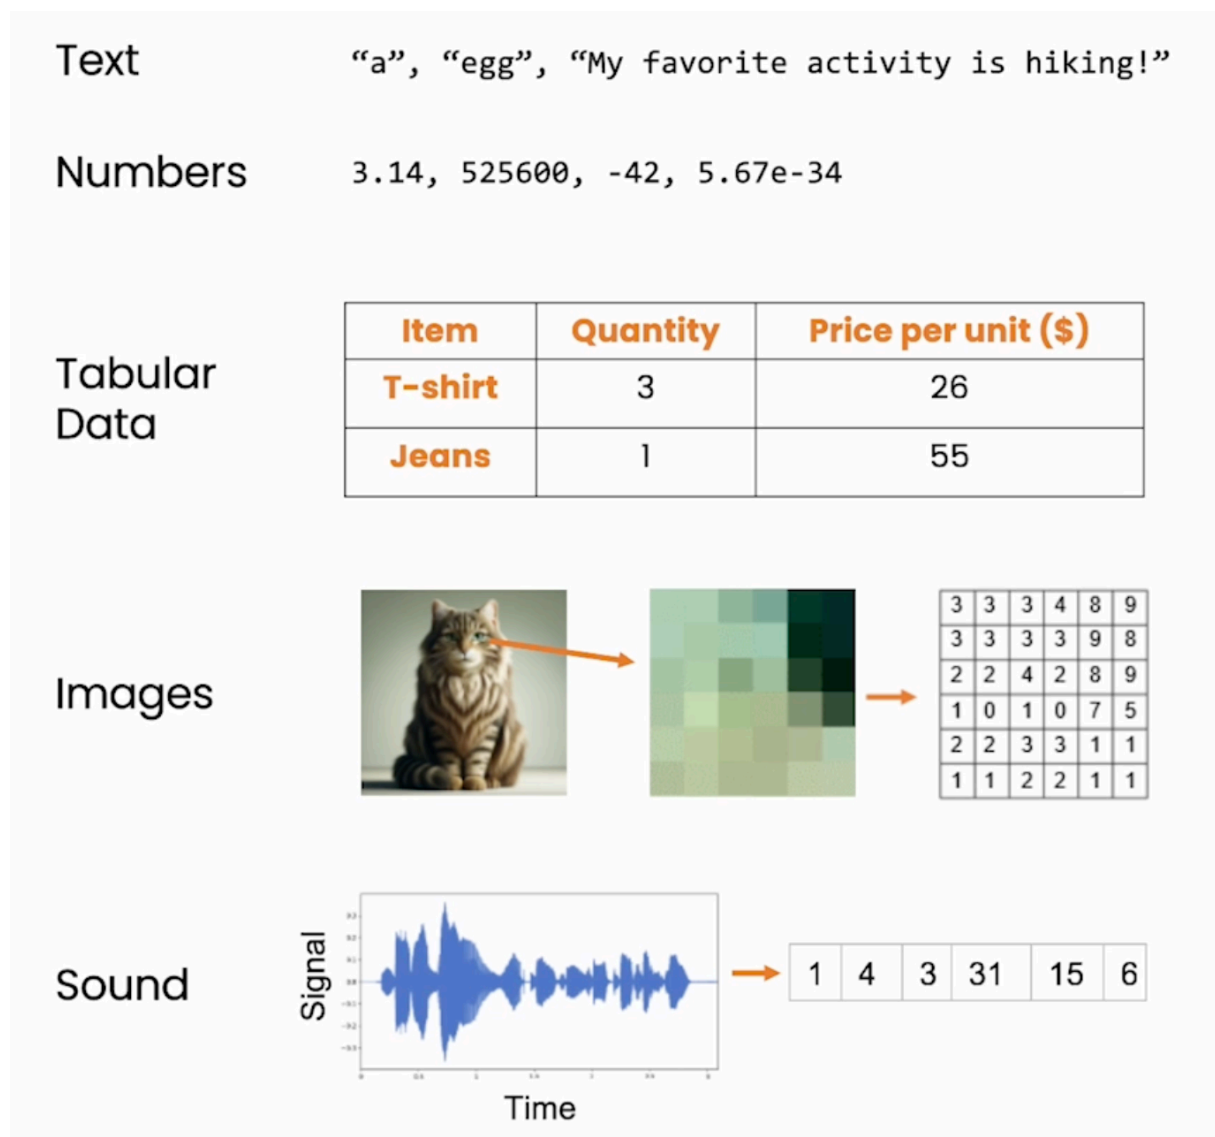
```
# 赋值给 num1 和 num2
num1 = 37
num2 = 5

# 计算和
sum = num1 + num2

# 展示结果
print(sum)
```

A set of instructions to perform a task

2.4 数据类型



编程本质上就是在处理文字和数字。常见的数据类型比如日期、时间、货币、百分比、电话号码、邮件地址、网址等等。

2.4.1 字符串和数字的区别

- 数字用来加减乘除，并且是有意义的
- 字符串用于切片、提取一部分、粘贴一起、打印消息等等

2.5 字符串 Strings 介绍

- Python 中的字符串是由文本、数字或符号字符组成的任意组合，并且用双引号或者单引号括起来。
- 引号之间的所有内容都是字符串的一部分，包括空格。

例如:

- "Hello, world"
- "My favorite drink is Earl Grey tea"
- "_ (ツ) _! "
- "2.99"
- " 大数据 Big Data 》。! 你好"

注意: 引号必须是英文的引号 " "，而不是中文的引号 “”。

2.5.1 特殊字符串

```
print("Hello World!")
```

Hello World!

```
type("Hello World!")
```

str

```
print(""" 这是一个多行字符串的实例  
也可以使用换行符。""")
```

这是一个多行字符串的实例
也可以使用换行符。

特殊字符

- `\n` 换行符, 例如 `print("Hello\nWorld")`
 - Windows 系统中, 会使用 `\r\n` (回车加换行) 作为新行的标记。
- `\t` 制表符; `\"` 双引号; `\'` 单引号

注意事项

函数的概念会在后面继续讲。我们可以用 `"""` 来创建多行字符串。

如果写成 `print("Hello"World")` 会出现错误: `SyntaxError: EOL while scanning string literal`。

2.5.2 字符串索引切片




图 2.1: Python String Indexing

语法: `string[start:stop:step]`


```
a = "Python is easy"
len(a)
```

14

```
print(a[1]) # y
```

y

```
print(a[1:4]) # yth
```

yth

```
print(a[1:4:2]) # yt
```

yh

2.5.3 字符串基本操作

```
"Hello" in "Hello World!"
```

True

```
"hello" not in "Hello World!"
```

True

```
"hello" + " World!"
```

'hello World!'

```
"hello" * 2
```

```
'hellohello'
```

```
"hello".upper()
```

```
'HELLO'
```

2.6 数字类型

Python 中的数字类型有三种：整数 (**int**)、浮点数 (**float**) 和复数。

- int: 3, 400, -2, 0
- float: 3.0, 3.14, -2.5

2.6.1 数字运算

```
print (10 % 3) # Modulus  
print (2 ** 3) # Exponentiation  
print (10 // 3) # Floor division
```

```
1
```

```
8
```

```
3
```

```
print(3 + 2 * (1 - 1) + 2 ** 2 )
```

```
7
```

2.6.2 数字类型检查

```
print(type(3)) # Int
print(type(3.0)) # Float
```

```
<class 'int'>
<class 'float'>
```

2.6.3 类型转换

```
print(float(3)) # Int to Float
print(int(3.0)) # Float to Int
```

3.0

3

2.6.4 数字字符转换

```
n = 3
print(type(n))
```

```
<class 'int'>
```

```
n_str = str(n)
print(type(n_str))
```

```
<class 'str'>
```

```
s = "3.5"
print(type(s))
```

```
<class 'str'>
```

```
s_float = float(s)
print(type(s_float))
```

```
<class 'float'>
```

2.7 变量

1. 给一个值 (对象 **Object**) 赋予一个名称以供以后使用
2. 使用相同的名称来引用不断变化的值

2.7.1 变量示例

- `x = 5`
- `y = "Hello, World!"`

2.7.2 变量命名规则

- 只能是一个词，变量名中不能够有 空格以及 标点符号，习惯上用 `_` 表示空格
- 不能以数字开头
- 不能使用 Python 保留字（关键字） e.g., *False True if else import None del, etc.*
- 建议只包含 字母、数字和下划线
- Snake Case: `my_variable_name`
- Camel Case: `myVariableName`
- 变量名是区分大小写的

2.7.3 练习：判断合法的变量名？

`balance`, `current-balance`, `current balance`, `true`, `currentBalance`,
`current_balance`, `_spam`, `SPAM`, `4account`, `account4`, `100`, `total_$um`, `'guanli'`

2.7.4 注意事项

Python 的变量是动态类型的，这意味着变量的数据类型是根据赋给它的值来确定的。

Python 关键字: False await else import pass None break except in raise
True class finally is return and continue for lambda try as def from
nonlocal while assert del global not with async elif if or yield

2.7.5 变量赋值

```
num = 5  
num = 32
```

```
print(num)
```

32

```
num = num + 1  
print(num)
```

33

```
num = "Hello"  
print(num)
```

Hello

2.8 字符串格式化

```
name = " 小李"  
print(" 你好, " + name + " !")
```

你好, 小李!

2.8.1 这样会出错

```
year = 1998
print(" 小李出生于" + year + " 年!")
```

2.8.2 正确的方式

```
year = 1998
print(" 小李出生于" + str(year) + " 年!")
```

小李出生于1998年!

2.8.3 Format string 方式

```
year = 1998
name = " 小李"
print(f" 我是{name}, 出生于{year}年!")
```

我是小李，出生于1998年!

2.8.4 Format String 更多例子

```
print(f"Isabel is {28/7} years old.")
```

Isabel is 4.0 years old.

格式化小数

问题: python format string 里面如何小数取整?

```
print(f"Isabel is {28/7:.0f} years old.")
```

Isabel is 4 years old.


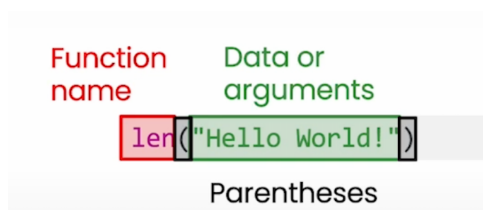
Format String 的巧妙用法

- 对齐: `f"|{name:<10}|{name:^10}|{name:>10}|"`
- 补零: `f"{number:04}"`
- 百分比: `f"{percentage:.2%}"`

2.9 函数

- 函数允许你对数据执行特定 操作，并提供（或返回 `return`）结果。


```
- len("Hello World!")  
- round(3.14159)
```



2.9.1 无返回值函数

- 有些函数不返回结果，只是执行操作。

```
- print("Hello")
```



2.9.2 自定义函数

带返回值的函数

```
def add(x, y):  
    z = x + y * 2  
    return z
```

无参数函数

```
def greet():  
    print('Hello World!')
```

带参数函数

```
def greet(name):  
    print(f'你好, {name}!')
```



```
greet('小李')
```

你好, 小李!

注意事项

- 函数也是一个对象，是一个代码块，一个过程，可以重复使用。

- 匿名函数 `lambda x: (x + 1) ** 2`
- `type(greet)` 可以查看函数类型

2.9.3 Lambda 函数（可选）

```
lambda x: (x + 1) ** 2
```

```
<function __main__.<lambda>(x)>
```

```
f = lambda x: (x + 1) ** 2
```

```
type(f)
```

```
function
```

2.10 容器数据类型（container）

类型	例子
列表 list	<code>my_list = [1, 2, 3]</code>
元组 tuple	<code>my_tuple = (1, 2, 3)</code>
集合 set	<code>my_set = {1,3,5}</code>
字典 dict	<code>my_dict = {'David': 25, 'Mark':30}</code>

2.10.1 列表 List

- 列表是一个有序的集合，可以包含不同类型的元素。
- 列表是可变的，可以通过索引进行修改。`string` 不可以。

基本操作

```
example_list = [1, 2, 3, 4, 5]
print(example_list)
```

[1, 2, 3, 4, 5]

```
print(example_list[0])
```

1

```
print(example_list[1:3])
```

[2, 3]

```
print(example_list[:2])
```

[1, 3, 5]

修改列表

```
example_list.append(1)
example_list
```

[1, 2, 3, 4, 5, 1]

```
example_list.insert(0, 111)
example_list
```

[111, 1, 2, 3, 4, 5, 1]

```
example_list[2] = 10
example_list
```

[111, 1, 10, 3, 4, 5, 1]

列表练习

```
L = [['Apple', 'Google', 'Microsoft'],  
      ['Java', 'Python', 'Ruby', 'PHP'],  
      ['Adam', 'Bart', 'Lisa']]
```

```
# 打印出 Apple:  
# 打印出 Python:  
# 打印出 Lisa:
```

解决方案:

```
print(L[0][0])  
print(L[1][1])  
print(L[2][2])
```

Apple

Python

Lisa

2.10.2 元组 Tuple

```
example_tuple = (4,5,"test",8)  
type(example_tuple)
```

tuple

```
example_tuple[0]
```

4

```
example_tuple[0] = 10
```

2.10.3 集合 Set

```
lp = [1,2,3,4,5,5,5,5,5,5,5,5]
set(lp)
```

```
{1, 2, 3, 4, 5}
```

```
set1 = {" 上证综指"," 深圳成指"," 恒生指数",
        " 日经 225 指数"," 道琼斯指数"}
type(set1)
```

```
set
```

```
set2 = {" 标普 500 指数"," 道琼斯指数"," 沪深 300 指数",
        " 日经 225 指数"," 发过 CAC40 指数"," 德国 DAX 指数"}
type(set2)
```

```
set
```

```
set1 | set2 # 并集
```

```
{'上证综指',
 '发过CAC40指数',
 '德国DAX指数',
 '恒生指数',
 '日经225指数',
 '标普500指数',
 '沪深300指数',
 '深圳成指',
 '道琼斯指数'}
```

```
print(set1 & set2)
print(set1.intersection(set2))
```

```
{'日经225指数', '道琼斯指数'}
{'日经225指数', '道琼斯指数'}
```

```
print(set1 - set2) # set1 对 set2 的差集
print(set2 - set1) # set2 对 set1 的差集
```

```
{'深圳成指', '上证综指', '恒生指数'}
{'沪深300指数', '德国DAX指数', '发过CAC40指数', '标普500指数'}
```

```
set1.add(" 德国 DAX 指数")
set1
```

```
{'上证综指', '德国DAX指数', '恒生指数', '日经225指数', '深圳成指', '道琼斯指数'}
```

```
set1.discard(" 日经 225 指数")
set1
```

```
{'上证综指', '德国DAX指数', '恒生指数', '深圳成指', '道琼斯指数'}
```

2.10.4 字典 Dict

```
{key1:value1, key2:value2, key3:value2 ,...}
```

1. 字典中的元素必须以键 (**key**) 和值 (**value**) 的形式成对出现，也就是所谓的键-值存储；
2. **key** 不可以重复，但是 **value** 可以重复；
3. **key** 不可以修改，但是 **value** 可以修改，并且可以是任意的类型。

```
dict1 = {" 指数名称": " 沪深 300",  
        " 证券代码": "000300",  
        " 交易日期": "2019-01-08",  
        " 涨跌幅": -0.0022} # 直接法创建  
print(type(dict1))
```

```
<class 'dict'>
```

```
dict2 = {} # 间接法创建  
dict2[" 指数名称"] = " 沪深 300"  
dict2[" 证券代码"] = "000300"  
dict2[" 交易日期"] = "2019-01-08"  
dict2[" 涨跌幅"] = -0.0022  
  
print(type(dict2))
```

```
<class 'dict'>
```

```
dict1.keys()
```

```
dict_keys(['指数名称', '证券代码', '交易日期', '涨跌幅'])
```

```
dict1.values()
```

```
dict_values(['沪深300', '000300', '2019-01-08', -0.0022])
```

```
dict1.items()
```

```
dict_items([('指数名称', '沪深300'), ('证券代码', '000300'), ('交易日期', '2019-01-08')])
```

```
dict1['交易日期'] = "2019-01-07"  
dict1
```

```
{'指数名称': '沪深300', '证券代码': '000300', '交易日期': '2019-01-07', '涨跌幅': -0.01}
```

2.11 流程控制

2.11.1 for 循环

常用的循环对象有：

- 容器数据类型如 list、tuple、dict、set、str 等
- range(), enumerate() 函数生成对象

```
names = ['Michael', 'Bob', 'Tracy']  
  
for name in names:  
    print(f'你好, {name}!')
```

你好, Michael!

你好, Bob!

你好, Tracy!

```
# 进行一定目的或逻辑的 for 循环  
result = 0  
for i in range(1, 101):  
    result = result + i  
result
```

5050

```
grades = {'Michael': 95,  
          'Bob': 75,  
          'Tracy': 85}  
  
for name, grade in grades.items():  
    print(f'{name}的分数是: {grade}')
```

Michael的分数是: 95

Bob的分数是: 75

Tracy的分数是: 85

2.11.2 布尔类型

```
print(True)  
print(False)  
# no error ? 没有引号
```

True

False

- 布尔类型只有两个值: True 和 False。

```
print(10 == 9)
```

False

```
print(10 < 9)
```

False

```
type(10 < 9)
```

bool


```
type(True)
```

bool

```
x = 10 == 9
```

```
print(x)
```

False

2.11.3 条件判断

- *Comparison Operators*: >, <, >=, <=, ==, !=
- *Membership Operators*: in, not in
- *Equality Operator*: and, or, not

```
"He" in "Hello"
```

True

```
1 in [1, 3, 3, 4]
```

True

```
3 >= 2 and 3 < 2
```

False

2.11.4 if 语句

```
age = 17
if age >= 18:
    print('your age is', age)
    print('adult')
```

```
age = 3
if age >= 18:
    print('your age is', age)
    print('adult')
else:
    print('your age is', age)
    print('teenager')
```

your age is 3

teenager

注意不要少写了冒号:。

```
age = 20

if 0 <= age <= 3:
    print('your age is', age)
    print('baby')
elif 3 < age < 18:
    print('your age is', age)
    print('teenager')
else:
    print('your age is', age)
    print('adult')
```

your age is 20

adult

注意：None、[]、''、0 与 False 功效几乎完全等同！

如果 condition 为 None、[]、''、0、False，dosomething 是不执行的！

2.11.5 循环控制关键字

- **break**: 终止当前循环，且跳出整个循环
- **continue**: 终止当次循环，跳出该次循环，直接执行下一次循环
- **pass** 不执行任何操作，一般用于占位
- **else**: 当 for 循环正常执行完毕（即没有通过 **break** 语句提前结束）时，**else** 块会被执行

```
r_list = [-0.0137, 0.024, 0.0061, -0.0022,
          0.0101, -0.0087, 0.0196, 0.0002, -0.0055 ]

for i in r_list:
    if i > 0.02:
        break
    print(" 收益率数据: ",i)
```

收益率数据: -0.0137

```
for i in r_list:
    if i < 0:
        continue
    print(" 非负收益率数据: ", i)
```

非负收益率数据: 0.024

非负收益率数据: 0.0061

非负收益率数据: 0.0101

非负收益率数据: 0.0196

非负收益率数据: 0.0002

```
for i in r_list:
    if i < 0:
        pass # 涨跌幅数据为负数时，不执行任何操作
    else:
        print(" 非负收益率数据: ",i)
```

非负收益率数据: 0.024
非负收益率数据: 0.0061
非负收益率数据: 0.0101
非负收益率数据: 0.0196
非负收益率数据: 0.0002

```
for i in range(5):
    if i == 6:
        print(f"Found {i}")
        break
    else:
        print("Not found")
```

Not found

2.11.6 while 循环

```
n = 1
while n <= 5:
    print(n)
    n = n + 1
print('END')
```

1
2
3

4
5
END

```
n = 0
while True:
    n = n + 1
    print(n)
    if n >= 5:
        break
```

1
2
3
4
5

2.12 模块和包

2.12.1 包 Package

- Python 有一些自带的 packages, 如 `os`, `pathlib`, `requests` 等
- 还可以通过 `pip` 安装更多的 packages
 - 在线安装: `pip install 库名`
 - 离线安装: 下载 `.whl` 文件, 然后 `pip install 库文件.whl`

```
%pip install --upgrade pip
%pip config set global.index-url
↪ https://mirrors.tuna.tsinghua.edu.cn/pypi/web/simple
```

```
%pip install dfply
```

```
import os
os.getcwd()
```

```
'/Users/xinlu/_project/AI4MPAcc-Course'
```

```
import pandas as pd
pd.DataFrame()
```

```
from os import getcwd
getcwd()
```

```
'/Users/xinlu/_project/AI4MPAcc-Course'
```

```
from os import getcwd as pwd
pwd()
```

```
'/Users/xinlu/_project/AI4MPAcc-Course'
```

2.12.2 自己的模块 **Module**

2.13 错误处理

- 如果代码中遇到 **错误 Error**，那么程序会在 **错误**所在的代码行停止。而错误后面的代码将无法执行。
- try 和 except 语句

```
a = 10
nums = [3,4,5,2,0,1,7,8]
for b in nums:
```

```
    print(a, b, a/b)
print(" 继续")
```

```
a = 10
nums = [3,4,5,2,0,1,7,8]
for b in nums:
    try:
        print(a, b, a/b)
    except:
        pass
print(" 继续")
```

```
10 3 3.3333333333333335
10 4 2.5
10 5 2.0
10 2 5.0
10 1 10.0
10 7 1.4285714285714286
10 8 1.25
继续
```

2.14 Markdown 基本语法

Markdown 是一种轻量级标记语言，用于格式化纯文本。

- Jupyter notebook Markdown 单元格
- 各种 Chat Bot 的交互界面
- 技术文档

2.14.1 标题

使用 # 表示标题，# 的数量表示标题的级别，最多支持六级标题。

```
# 一级标题
## 二级标题
### 三级标题
#### 四级标题
##### 五级标题
##### 六级标题
```

2.14.2 强调

使用 * 或 _ 包围文字表示斜体，使用 ** 或 __ 包围文字表示粗体，使用 ~~ 包围文字表示删除线。

```
* 斜体 * 或 _ 斜体 _
** 粗体 ** 或 __ 粗体 __
~~ 删除线 ~~
```

2.14.3 列表

- 无序列表 使用 -、+ 或 * 表示。
- 有序列表 使用数字加 . 表示。

```
- 项目 1
- 项目 2
  - 子项目 2.1
  - 子项目 2.2

1. 项目 1
2. 项目 2
  1. 子项目 2.1
  2. 子项目 2.2
```


2.14.4 链接

使用 [文本](链接) 创建链接，使用 [文本](链接 " 标题") 创建带有标题的链接。

```
[Google](https://www.google.com)
```

```
[Google](https://www.google.com " 访问 Google")
```

2.14.5 图片

使用 ![替代文字](图片链接) 插入图片。

```
![示例图片](https://example.com/image.jpg)
```

2.14.6 引用

使用 > 表示引用，可以嵌套使用。

```
> 这是一个引用
```

```
>> 这是一个嵌套引用
```

2.14.7 代码

- 行内代码 使用反引号 ` 包围代码。
- 代码块 使用三个反引号 ``` 或四个空格缩进代码。

```
`行内代码`
```

```
```python
def hello():
 print("Hello, World!")
```
```

2.14.8 分割线

使用三个或以上的 -、* 或 _ 表示分割线。

```
---  
  
***  
  
---
```

2.14.9 表格

使用 | 创建表格，使用 - 定义表头。

```
头 1	头 2	头 3
内容 1	内容 2	内容 3
内容 A	内容 B	内容 C
```

| 头 1 | 头 2 | 头 3 |
|------|------|------|
| 内容 1 | 内容 2 | 内容 3 |
| 内容 A | 内容 B | 内容 C |

2.14.10 公式

使用 \$ 包围公式，支持 LaTeX 语法。

inline formula $f(Y_{it}) + R_{it}g(Y_{it}) + R_{it}D_{it}c(Y_{it}) + D_{it}d(Y_{it}) + \epsilon_{it}$

block formula
$$f(Y_{it}) + R_{it}g(Y_{it}) + R_{it}D_{it}c(Y_{it}) + D_{it}d(Y_{it}) + \epsilon_{it}$$

\$\$

```
X_{i t}=\underbrace{f\left(Y_{i t}\right)+R_{i t} g\left(Y_{i t}\right)+R_{i t} D_{i t} c\left(Y_{i t}\right)+D_{i t} d\left(Y_{i t}\right)}_{=m\left(Y_{i t}, R_{i t}\right)}+\epsilon_{i t},
```

\$\$

$$X_{it} = \underbrace{f(Y_{it}) + R_{it}g(Y_{it}) + R_{it}D_{it}c(Y_{it}) + D_{it}d(Y_{it})}_{=m(Y_{it}, R_{it})} + \epsilon_{it},$$

2.14.11 Markdown Display

```
from IPython.display import display, Markdown
display(Markdown("### 测试三级标题"))
```

```
for x in range(5):
    # Print in Markdown format
    display(Markdown(f"${x}^2$ <red style='color:red'> = </red>
    **{x**2}**"))
```

2.14.12 Markdown 编辑器

- VS Code
 - [VS Code Markdown All in One](#) 插件
 - [VS Code Markdown Preview Enhanced](#) 插件
- [zettlr](#)
- Obsidian

3 python 调用 LLM

[点击下载本章节代码](#)

3.1 配置环境变量 KEY

```
%env DASHSCOPE_API_KEY="sk-xxx"
```

3.2 不同模型调用

3.2.1 zhipu AI

```
import os
from openai import OpenAI
os.environ["ZAI_API_KEY"]
client = OpenAI(api_key=os.environ["ZAI_API_KEY"],
                base_url="https://open.bigmodel.cn/api/paas/v4/")

completion = client.chat.completions.create(
    model="glm-4.5-flash",
    messages=[
        {"role": "user", "content": "Hello!"}
    ]
)

print(completion.choices[0].message.content)
```

Hello! How can I help you today? Feel free to ask anything or start a conversation!

3.2.2 deepseek

```
from openai import OpenAI
client = OpenAI(
    # 若没有配置环境变量，请用百炼 API Key 将下行替换为：api_key="sk-xxx",
    base_url="https://api.deepseek.com",
    api_key=os.environ["DEEPSEEK_API_KEY"],
)

completion = client.chat.completions.create(
    model="deepseek-chat",
    messages=[
        {"role": "user", "content": "Hello!"}
    ]
)

print(completion.choices[0].message.content)
```

Hello! How can I help you today?

3.2.3 阿里千问

```
from openai import OpenAI
client = OpenAI(
    # 若没有配置环境变量，请用百炼 API Key 将下行替换为：api_key="sk-xxx",
    api_key=os.getenv("DASHSCOPE_API_KEY"),
    base_url="https://dashscope.aliyuncs.com/compatible-mode/v1",
)
```

```
completion = client.chat.completions.create(
    model="qwen-turbo",
    messages=[
        {"role": "user", "content": "Hello!"}
    ]
)

print(completion.choices[0].message.content)
```

Hello! How can I assist you today?

3.3 模型回复结构

```
from pprint import pprint
pprint(completion.to_dict())
```

```
{'choices': [{ 'finish_reason': 'stop',
                'index': 0,
                'logprobs': None,
                'message': { 'content': 'Hello! How can I assist you today? ',
                             'role': 'assistant' } } ],
 'created': 1758093186,
 'id': 'chatcmpl-eeeb7ef2-94c5-433a-8812-65f09cd86115',
 'model': 'qwen-turbo',
 'object': 'chat.completion',
 'system_fingerprint': None,
 'usage': { 'completion_tokens': 11,
            'prompt_tokens': 14,
            'prompt_tokens_details': { 'cached_tokens': 0 },
            'total_tokens': 25 } }
```

3.4 简单问答

```
client = OpenAI(api_key=os.getenv("DASHSCOPE_API_KEY"),
                base_url="https://dashscope.aliyuncs.com/compatible-mode/v1")

messages = [{"role": "user", "content": " 财务会计和管理会计的区别是什么?"
      ↪  "}]

response = client.chat.completions.create(
    model="qwen-turbo",
    messages=messages
)
print(response.choices[0].message.content)
```

财务会计（Financial Accounting）和管理会计（Managerial Accounting）是会计学的两个重要

一、定义不同

| 项目 | 财务会计 | 管理会计 |
|----|-----------------------|---------------------|
| 定义 | 为企业外部利益相关者提供财务信息的会计系统 | 为内部管理者提供决策支持信息的会计系统 |

二、服务对象不同

| 项目 | 财务会计 | 管理会计 |
|------|------------------|---------------------|
| 服务对象 | 外部：股东、债权人、政府、公众等 | 内部：企业管理人员、部门负责人、管理层 |
| 使用者 | 非会计人员（如投资者、监管机构） | 会计人员和管理人员（专业性较强） |

三、报告内容和时间不同

| 项目 | 财务会计 | 管理会计 |
|-------|-------|-------|
| ----- | ----- | ----- |

| | | |
|------|-------------------------------|--------------|
| 报告内容 | 以历史数据为主，反映企业过去的经营成果和财务状况 | 包括历史数据、预测、预算 |
| 报告时间 | 按固定周期（如月、季、年）编制报表（如资产负债表、利润表） | 按需随时编制 |

四、信息特征不同

| 项目 | 财务会计 | 管理会计 |
|-------|-------|-------|
| ----- | ----- | ----- |

| | | |
|------|-------------|---------------------|
| 信息性质 | 历史性、总结性、综合性 | 预测性、前瞻性、细节性 |
| 信息形式 | 标准化、统一化 | 非标准化、多样化 |
| 信息范围 | 全面、综合（整个企业） | 针对性、局部性（某个部门、产品或项目） |

五、依据和规范不同

| 项目 | 财务会计 | 管理会计 |
|-------|-------|-------|
| ----- | ----- | ----- |

| | | |
|-----|--------------------------------|----------------|
| 依据 | 会计准则（如中国《企业会计准则》、国际财务报告准则IFRS） | 企业内部规定、管理会计制度 |
| 保密性 | 一般公开（如年报、财报） | 通常不公开，属于企业内部机密 |

六、目的不同

| 项目 | 财务会计 | 管理会计 |

|-----|-----|-----|

| 目的 | 向外部提供真实、公允的财务信息，供其进行投资、信贷等决策 | 为内部管理提供信息

七、举例说明

- **财务会计**:

- 编制季度利润表
- 提供年度审计报告
- 发布年度财务报表给股东和监管部门

- **管理会计**:

- 分析某产品的成本与利润
- 制定部门预算
- 进行绩效评估和成本控制

总结对比表:

| 对比项 | 财务会计 | 管理会计 |

|-----|-----|-----|

| 服务对象 | 外部 | 内部 |

| 时间性 | 历史数据 | 预测与决策 |

| 内容 | 综合性、标准化 | 局部性、灵活性 |

| 规范 | 会计准则 | 企业内部制度 |

| 报告频率 | 定期 | 按需 |

| 保密性 | 公开 | 保密 |

如果你是学生或刚接触会计知识，理解这两者的区别有助于你更好地把握会计工作的不同应用场景

3.4.1 display response markdown

```
from IPython.display import display, Markdown
display(Markdown(response.choices[0].message.content))
```

3.4.2 模型列表

<https://bailian.console.aliyun.com/?tab=model#/model-market>

3.5 自定义函数

```
def ask_qwen(prompt, model="qwen-turbo"):

    client = OpenAI(api_key=os.getenv("DASHSCOPE_API_KEY"),
                    base_url="https://dashscope.aliyuncs.com/compatible-mode/v1"
                    )

    messages = [{"role": "user", "content": prompt}]

    response = client.chat.completions.create(
        model=model,
        messages=messages,
        extra_body={"enable_thinking": False, "enable_search": True,
                    "search_options": {"search_strategy": "pro"}}
    )

    return response.choices[0].message.content
```

```
ask_qwen(" 中国 2024 年一季度的 GDP 是多少，只回答阿拉伯数字，不要其他信息，单位是亿元人民币")
```

```
'304761.8'
```

```
ask_qwen(" 中国 2023 年一季度的 GDP 是多少，只回答阿拉伯数字，不要其他信息，单位是亿元人民币")
```

```
'11713'
```

💡 思考

如何用 For Loop 获取过去 5 年的 GDP 数据?

3.6 JSON output 格式化

```
import json
def extract_json(text):
    """Extract JSON from text response"""
    try:
        # Look for JSON between backticks or just anywhere in the text
        import re
        json_match = re.search(r'```\s*json\s*(.*?)\s*```', text, re.DOTALL)
        if json_match:
            json_str = json_match.group(1)
            return json.loads(json_str)
        else:
            # Try to find JSON directly
            return json.loads(text)
    except Exception as e:
        print(f"Error extracting JSON: {e}")
        print(f"Original text: {text}")
        return None
```

```
function_string = """
```json
{"title": "First Int", "type": "integer"}
```

"""

extract_json(function_string)
```

```
{'title': 'First Int', 'type': 'integer'}
```

```
prompt = """
请生成包括书名、作者和类别的三本虚构书籍清单，\
并以 JSON 格式提供，其中包含以下键:book_id、title、author、genre:

{"books": [ ... ] }
"""

response = ask_qwen(prompt, model="qwen-turbo")
print(response)
```

```
{
  "books": [
    {
      "book_id": 1,
      "title": "星尘之梦",
      "author": "艾琳·维斯特",
      "genre": "奇幻"
    },
    {
      "book_id": 2,
      "title": "寂静回声",
```

```

        "author": "马克斯·格雷",
        "genre": "悬疑"
    },
    {
        "book_id": 3,
        "title": "时间的碎片",
        "author": "莉娅·陈",
        "genre": "科幻"
    }
]
}

```

```
extract_json(response)
```

```

{'books': [{'book_id': 1, 'title': '星尘之梦', 'author': '艾琳·维斯特', 'genre': '奇幻'},
            {'book_id': 2, 'title': '寂静回声', 'author': '马克斯·格雷', 'genre': '悬疑'},
            {'book_id': 3, 'title': '时间的碎片', 'author': '莉娅·陈', 'genre': '科幻'}]}

```

```

import pandas as pd
df = pd.DataFrame(extract_json(response)["books"])
df

```

| | book_id | title | author | genre |
|---|---------|-------|--------|-------|
| 0 | 1 | 星尘之梦 | 艾琳·维斯特 | 奇幻 |
| 1 | 2 | 寂静回声 | 马克斯·格雷 | 悬疑 |
| 2 | 3 | 时间的碎片 | 莉娅·陈 | 科幻 |

```
df.to_csv("books.csv", index=False)
```

```

import os
os.remove("books.csv")

```

3.7 财务数据 sentiment analysis

```
prompt = ""
```

```
请生成 10 个关于上市公司的财务数据的新闻标题，5 个正面，5 个负面 \
并以 JSON 格式提供，其中包含以下键:stock_code、title:
```

```
{"news": [ ... ] }
```

```
"""
```

```
response = ask_qwen(prompt)
```

```
print(response)
```

```
{
```

```
  "news": [
```

```
    {
```

```
      "stock_code": "601995.SH",
```

```
      "title": "中金公司2025年中期业绩稳健增长，归母净利润同比增长94%"
```

```
    },
```

```
    {
```

```
      "stock_code": "002635.SZ",
```

```
      "title": "TCL科技扣非净利润大增179%，显示业务盈利能力显著提升"
```

```
    },
```

```
    {
```

```
      "stock_code": "002493.SZ",
```

```
      "title": "联发股份上半年经营性现金流净额创历史新高，盈利倍增"
```

```
    },
```

```
    {
```

```
      "stock_code": "300510.SZ",
```

```
      "title": "金冠股份上半年亏损扩大，但智能电网设备需求持续增长"
```

```
    },
```

```
    {
```

```
      "stock_code": "300510.SZ",
```

```

        "title": "金冠股份第二季度亏损扩大，但储能业务发展潜力巨大"
    },
    {
        "stock_code": "002493.SZ",
        "title": "联发股份毛利率提升，主业造血能力明显增强"
    },
    {
        "stock_code": "300510.SZ",
        "title": "金冠股份上半年亏损扩大，资产规模有所下降"
    },
    {
        "stock_code": "002635.SZ",
        "title": "TCL科技上半年营收稳健增长，净利润显著提升"
    },
    {
        "stock_code": "002493.SZ",
        "title": "联发股份绿色转型加速，入选江苏省‘绿色工厂’示范名单"
    },
    {
        "stock_code": "300510.SZ",
        "title": "金冠股份上半年亏损扩大，现金流有所改善"
    }
]
}

```

```

df = pd.DataFrame(extract_json(response)["news"])
df

```

| | stock_code | title |
|---|------------|-----------------------------------|
| 0 | 601995.SH | 中金公司 2025 年中期业绩稳健增长，归母净利润同比增长 94% |
| 1 | 002635.SZ | TCL 科技扣非净利润大增 179%，显示业务盈利能力显著提升 |
| 2 | 002493.SZ | 联发股份上半年经营性现金流净额创历史新高，盈利倍增 |

| | stock_code | title |
|---|------------|----------------------------|
| 3 | 300510.SZ | 金冠股份上半年亏损扩大，但智能电网设备需求持续增长 |
| 4 | 300510.SZ | 金冠股份第二季度亏损扩大，但储能业务发展潜力巨大 |
| 5 | 002493.SZ | 联发股份毛利率提升，主业造血能力明显增强 |
| 6 | 300510.SZ | 金冠股份上半年亏损扩大，资产规模有所下降 |
| 7 | 002635.SZ | TCL 科技上半年营收稳健增长，净利润显著提升 |
| 8 | 002493.SZ | 联发股份绿色转型加速，入选江苏省‘绿色工厂’示范名单 |
| 9 | 300510.SZ | 金冠股份上半年亏损扩大，现金流有所改善 |

```
def sentiment_analysis(text):
    prompt = f"""
    请判断下面的新闻标题为 正面还是负面：
    ```{text}```
 仅回答“正面”或“负面”即可。
 """
 response = ask_qwen(prompt)
 return response
```

```
from tqdm.notebook import tqdm
tqdm.pandas()

df["sentiment"] = df["title"].progress_apply(sentiment_analysis)
df
```

0%| | 0/10 [00:00<?, ?it/s]

|   | stock_code | title                             | sentiment |
|---|------------|-----------------------------------|-----------|
| 0 | 601995.SH  | 中金公司 2025 年中期业绩稳健增长，归母净利润同比增长 94% | 正面        |
| 1 | 002635.SZ  | TCL 科技扣非净利润大增 179%，显示业务盈利能力显著提升   | 正面        |
| 2 | 002493.SZ  | 联发股份上半年经营性现金流净额创历史新高，盈利倍增         | 正面        |
| 3 | 300510.SZ  | 金冠股份上半年亏损扩大，但智能电网设备需求持续增长         | 负面        |



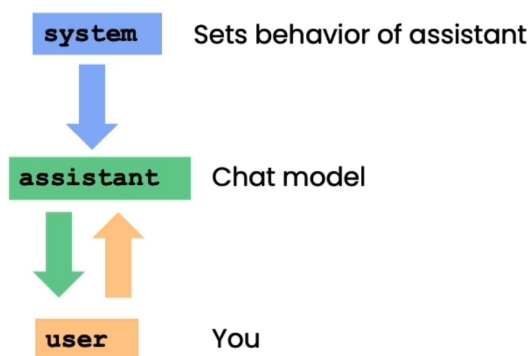
|   | stock_code | title                      | sentiment |
|---|------------|----------------------------|-----------|
| 4 | 300510.SZ  | 金冠股份第二季度亏损扩大，但储能业务发展潜力巨大   | 负面        |
| 5 | 002493.SZ  | 联发股份毛利率提升，主业造血能力明显增强       | 正面        |
| 6 | 300510.SZ  | 金冠股份上半年亏损扩大，资产规模有所下降       | 负面        |
| 7 | 002635.SZ  | TCL 科技上半年营收稳健增长，净利润显著提升    | 正面        |
| 8 | 002493.SZ  | 联发股份绿色转型加速，入选江苏省‘绿色工厂’示范名单 | 正面        |
| 9 | 300510.SZ  | 金冠股份上半年亏损扩大，现金流有所改善        | 负面        |

## 3.8 订餐系统

### 3.8.1 messages 结构

#### System, User and Assistant Messages

```
messages =
[
 {"role": "system",
 "content": "You are an assistant... "},
 {"role": "user",
 "content": "Tell me a joke "},
 {"role": "assistant",
 "content": "Why did the chicken... "},
 ...
]
```



```
qa_messages = [{"role": "system", "content": ""}
你是订餐机器人，为披萨餐厅自动收集订单信息。
你要首先问候顾客。然后等待用户回复收集订单信息。收集完信息需确认顾客是否还
↪ 需要添加其他内容。
最后需要询问是否自取或外送，如果是外送，你要询问地址。
```

最后告诉顾客订单总金额，并送上祝福。

请确保明确所有选项、附加项和尺寸，以便从菜单中识别出该项唯一的内容。

你的回应应该以简短、非常随意和友好的风格呈现。

菜单包括：

菜品：

意式辣香肠披萨（大、中、小） 12.95、10.00、7.00

芝士披萨（大、中、小） 10.95、9.25、6.50

茄子披萨（大、中、小） 11.95、9.75、6.75

薯条（大、小） 4.50、3.50

希腊沙拉 7.25

配料：

奶酪 2.00

蘑菇 1.50

香肠 3.00

加拿大熏肉 3.50

AI 酱 1.50

辣椒 1.00

饮料：

可乐（大、中、小） 3.00、2.00、1.00

雪碧（大、中、小） 3.00、2.00、1.00

瓶装水 5.00

""},

{"role": "user",

"content": " 我要一个大可乐，一个大的意大利辣香肠披萨，加半根香肠，再要一个  
↩ 扬州炒饭，直接回答总价"

}

]

```
def ask_qwen(messages, model="qwen-turbo"):

 client = OpenAI(api_key=os.getenv("DASHSCOPE_API_KEY"),
 base_url="https://dashscope.aliyuncs.com/compatible-mode/v1"
)

 response = client.chat.completions.create(
 model=model,
 messages=messages
)

 return response.choices[0].message.content
```

```
res = ask_qwen(qa_messages)
print(res)
```

你好呀！让我来帮你算一下总价：

- 大可乐：3.00
- 意大利辣香肠披萨（大）：12.95
- 半根香肠：1.50
- 扬州炒饭：这个我们没有在菜单上，是不是要点别的？比如薯条或者沙拉？

如果你确定要扬州炒饭，那我先按这个计算，总价是 **\*\*17.45\*\***。你确认一下吗？

#### 思考

我们是否可以自定义一个更好的 `print` 函数，利用 `markdown` 语法来打印结果？

## 4 pandas 数据框

[点击下载本章节代码](#)

### 4.1 Pandas 处理表格数据

参考: <https://realpython.com/pandas-dataframe/>

**pandas DataFrame** 是一种包含二维数据及其对应标签的数据结构。

**DataFrame** 类似于 Excel 或 SQL 中使用的电子表格。在很多情况下, **DataFrame** 比表格或电子表格更快、更易于使用且功能更强大。

#### 4.1.1 安装所需包

```
%pip install pandas openpyxl pyarrow dfply matplotlib seaborn --upgrade
```

#### 4.1.2 导入 pandas

```
import pandas as pd
```

#### 4.1.3 创建示例数据

让我们创建一个会计科目表作为示例:

```
创建会计科目数据
data = {
 'account_name': ['现金', '银行存款', '应收账款', '存货', '固定资产',
 ↪ '应付账款', '实收资本'],
```

```

 'account_type': ['资产', '资产', '资产', '资产', '资产', '负债', '所有者权益'],
 'balance': [50000.0, 200000.0, 150000.0, 180000.0, 300000.0,
 ↪ 100000.0, 680000.0],
 'balance_direction': ['借', '借', '借', '借', '借', '贷', '贷']
}

使用会计科目编号作为索引
account_codes = [1001, 1002, 1122, 1123, 1601, 2202, 4001]

df = pd.DataFrame(data, index = account_codes)

```

### 💡 Tip

会计背景说明: - 账户编号: 通常使用数字编码, 如 1 开头表示资产, 2 开头表示负债等 - 借贷方向: 资产类账户余额在借方, 负债和所有者权益账户余额在贷方 - 余额: 表示该科目的期末余额

## 4.2 DataFrame 结构与属性

查看 DataFrame 类型和结构:

```
type(df)
```

```
pandas.core.frame.DataFrame
```

```
df
```

**Column labels**

↓

|            | <b>name</b> | <b>city</b> | <b>age</b> | <b>py-score</b> |
|------------|-------------|-------------|------------|-----------------|
| <b>101</b> | Xavier      | Mexico City | 41         | 88.0            |
| <b>102</b> | Ann         | Toronto     | 28         | 79.0            |
| <b>103</b> | Jana        | Prague      | 33         | 81.0            |
| <b>104</b> | Yi          | Shanghai    | 34         | 80.0            |
| <b>105</b> | Robin       | Manchester  | 38         | 68.0            |
| <b>106</b> | Amal        | Cairo       | 31         | 61.0            |
| <b>107</b> | Nori        | Osaka       | 37         | 84.0            |

↑ **Row labels**

↑ **Data**

#### **i** Note

可以删掉 labels 的信息，系统会自己给一个编号。

### 4.2.1 索引 (index)

```
df.index
```

```
Index([1001, 1002, 1122, 1123, 1601, 2202, 4001], dtype='int64')
```

### 4.2.2 列名 (columns)

```
df.columns
```

```
Index(['account_name', 'account_type', 'balance', 'balance_direction'], dtype='object')
```

### 4.2.3 值 (values)

```
df.values
```

```
array([['现金', '资产', 50000.0, '借'],
 ['银行存款', '资产', 200000.0, '借'],
 ['应收账款', '资产', 150000.0, '借'],
 ['存货', '资产', 180000.0, '借'],
 ['固定资产', '资产', 300000.0, '借'],
 ['应付账款', '负债', 100000.0, '贷'],
 ['实收资本', '所有者权益', 680000.0, '贷']], dtype=object)
```

### 4.2.4 形状 (shape)

```
df.shape
```

```
(7, 4)
```

### 4.2.5 数据类型 (dtypes)

```
df.dtypes
```

```
account_name object
account_type object
balance float64
balance_direction object
dtype: object
```

### 4.2.6 基本信息 (info)

```
df.info()
```

```
<class 'pandas.core.frame.DataFrame'>
Index: 7 entries, 1001 to 4001
Data columns (total 4 columns):
Column Non-Null Count Dtype
--- -
0 account_name 7 non-null object
1 account_type 7 non-null object
2 balance 7 non-null float64
3 balance_direction 7 non-null object
dtypes: float64(1), object(3)
memory usage: 280.0+ bytes
```

## 4.3 DataFrame 行列操作

### 4.3.1 访问列

通过列名访问列数据:

```
显示账户名称列
```

```
df.account_name
```

```
将账户名称列赋值给变量
```

```
accounts = df['account_name']
```

```
accounts
```

```
1001 现金
1002 银行存款
1122 应收账款
1123 存货
1601 固定资产
```



2202     应付账款

4001     实收资本

Name: account\_name, dtype: object

查看列的类型:

```
type(df.account_name)
```

pandas.core.series.Series

访问特定位置的值:

```
访问账户编号为 1002 的账户名称
```

```
accounts[1002]
```

'银行存款'

#### Note

说明: DataFrame 的每一列都是一个 Series 对象。Series 是 pandas 的一维数组, 类似于 Excel 中的单独一列。

### 4.3.2 访问行

使用.loc 访问行:

```
访问账户编号为 1122 的科目信息
```

```
account_row = df.loc[1122]
```

```
account_row
```

account\_name                      应收账款

account\_type                        资产

balance                            150000.0

balance\_direction                  借

Name: 1122, dtype: object

访问行中的特定列:

```
获取该科目的账户类型
account_row['account_type']
```

‘资产’

查看行的类型:

```
type(account_row)
```

pandas.core.series.Series

#### Note

说明: 访问 DataFrame 的一行会返回一个 Series 对象, 其索引是原 DataFrame 的列名。

### 4.3.3 转置

原始数据:

df

|      | account_name | account_type | balance  | balance_direction |
|------|--------------|--------------|----------|-------------------|
| 1001 | 现金           | 资产           | 50000.0  | 借                 |
| 1002 | 银行存款         | 资产           | 200000.0 | 借                 |
| 1122 | 应收账款         | 资产           | 150000.0 | 借                 |
| 1123 | 存货           | 资产           | 180000.0 | 借                 |
| 1601 | 固定资产         | 资产           | 300000.0 | 借                 |
| 2202 | 应付账款         | 负债           | 100000.0 | 贷                 |
| 4001 | 实收资本         | 所有者权益        | 680000.0 | 贷                 |

转置后:

```
df.T
```

|                   | 1001    | 1002     | 1122     | 1123     | 1601     | 2202     | 4001     |
|-------------------|---------|----------|----------|----------|----------|----------|----------|
| account_name      | 现金      | 银行存款     | 应收账款     | 存货       | 固定资产     | 应付账款     | 实收资本     |
| account_type      | 资产      | 资产       | 资产       | 资产       | 资产       | 负债       | 所有者权益    |
| balance           | 50000.0 | 200000.0 | 150000.0 | 180000.0 | 300000.0 | 100000.0 | 680000.0 |
| balance_direction | 借       | 借        | 借        | 借        | 借        | 贷        | 贷        |

#### 4.3.4 查看头尾数据

查看前 n 行:

```
df.head(n=3)
```

|      | account_name | account_type | balance  | balance_direction |
|------|--------------|--------------|----------|-------------------|
| 1001 | 现金           | 资产           | 50000.0  | 借                 |
| 1002 | 银行存款         | 资产           | 200000.0 | 借                 |
| 1122 | 应收账款         | 资产           | 150000.0 | 借                 |

查看后 n 行 (默认 5 行):

```
df.tail()
```

|      | account_name | account_type | balance  | balance_direction |
|------|--------------|--------------|----------|-------------------|
| 1122 | 应收账款         | 资产           | 150000.0 | 借                 |
| 1123 | 存货           | 资产           | 180000.0 | 借                 |
| 1601 | 固定资产         | 资产           | 300000.0 | 借                 |
| 2202 | 应付账款         | 负债           | 100000.0 | 贷                 |
| 4001 | 实收资本         | 所有者权益        | 680000.0 | 贷                 |

### 4.3.5 创建 DataFrame

从字典列表创建:

```
l = [{'x': 1, 'y': 2, 'z': 100},
 {'x': 2, 'y': 4, 'z': 100},
 {'x': 3, 'y': 8, 'z': 100}]
```

```
pd.DataFrame(l)
```

|   | x | y | z   |
|---|---|---|-----|
| 0 | 1 | 2 | 100 |
| 1 | 2 | 4 | 100 |
| 2 | 3 | 8 | 100 |

从二维数组创建 - 指定列名和索引:

```
从数组构建 DataFrame
```

```
data = [['Alice', 25], ['Bob', 30], ['Charlie', 35]]
```

```
pd.DataFrame(data, columns=['Name', 'Age'], index = [1,2,9])
```

|   | Name    | Age |
|---|---------|-----|
| 1 | Alice   | 25  |
| 2 | Bob     | 30  |
| 9 | Charlie | 35  |

使用默认列名和索引:

```
pd.DataFrame(data)
```

|   | 0       | 1  |
|---|---------|----|
| 0 | Alice   | 25 |
| 1 | Bob     | 30 |
| 2 | Charlie | 35 |

## 4.4 DataFrame 导入与导出

学习目标: - 掌握从不同文件格式读取数据 - 了解常见数据导入问题的处理方法 - 学会将处理后的数据导出为专业格式

pandas 可以将各种数据格式导入为 DataFrame:

- 支持的格式: CSV, XLSX, SQL, JSON, HTML, HDF5, SAS, STATA, Parquet, SQL 等
- 参考文档: <https://pandas.pydata.org/pandas-docs/stable/reference/io.html>

### 4.4.1 读取 CSV 文件

CSV(逗号分隔值) 是会计数据最常见的格式之一:

```
基本读取
df = pd.read_csv('financial_data.csv')

指定编码 (处理中文)
df = pd.read_csv('financial_data.csv', encoding='utf-8')

指定数据类型 (提高性能)
df = pd.read_csv('financial_data.csv',
 dtype={'account_number': str, 'amount': float})

处理日期列
df = pd.read_csv('financial_data.csv',
 parse_dates=['transaction_date'])
```



Tip

会计应用: 从 ERP 系统或财务软件导出的数据通常是 CSV 格式。正确设置编码和数据类型可以避免很多后续问题。

#### 4.4.2 读取 Excel 文件

```
读取第一个工作表
```

```
df = pd.read_excel("example.xlsx", sheet_name=0)
```

```
读取特定工作表
```

```
df = pd.read_excel('financial_statements.xlsx', sheet_name='Balance
↪ Sheet')
```

```
跳过某些行 (如标题行)
```

```
df = pd.read_excel('financial_statements.xlsx', skiprows=[0, 1])
```

```
指定索引列
```

```
df = pd.read_excel('financial_statements.xlsx', index_col=0)
```

#### 4.4.3 处理大文件

对于大型财务数据文件, 可以分块读取:

```
分块读取 CSV
```

```
chunk_size = 10000
```

```
chunks = []
```

```
for chunk in pd.read_csv('large_transaction_file.csv',
↪ chunksize=chunk_size):
```

```
 # 对每个块进行处理
```

```
 chunks.append(chunk)
```

```
df = pd.concat(chunks, ignore_index=True)
```

#### 4.4.4 导出数据

导出到 Excel:

```
df.to_excel("example.xlsx", index=False)
```

```
导出到 CSV(不包含索引)
```

```
df.to_csv('output.csv', index=False, encoding='utf-8-sig')
```

```
导出到 Excel with 格式化
```

```
with pd.ExcelWriter('financial_report.xlsx', engine='openpyxl') as
```

```
 writer:
```

```
 df.to_excel(writer, sheet_name='Summary', index=False)
```

#### Warning

常见错误: 忘记设置 `index=False` 会导致导出时包含行号列, 这在财务报表中通常是不需要的。

#### 4.4.5 错误处理

```
安全地读取文件
```

```
try:
```

```
 df = pd.read_excel('financial_data.xlsx')
```

```
 print(f" 成功读取 {len(df)} 行数据")
```

```
except FileNotFoundError:
```

```
 print(" 文件未找到, 请检查文件路径")
```

```
except Exception as e:
```

```
 print(f" 读取文件时出错: {e}")
```

## 4.5 数据清洗 (Data Cleaning)

学习目标: - 识别和处理缺失值 - 检测和删除重复数据 - 转换数据类型 - 处理会计数据中的特殊格式

### ! Important

为什么数据清洗很重要? 会计数据常常来自不同系统, 可能包含缺失值、重复记录、格式不统一等问题。数据清洗是数据分析的第一步, 决定了分析结果的准确性。

### 4.5.1 检查缺失值

创建示例财务数据 (包含缺失值):

```
import numpy as np

创建包含缺失值的账目数据
accounts_data = {
 'account_number': ['1001', '1002', '1003', '1004', '1005'],
 'account_name': ['现金', '应收账款', '存货', None, '固定资产'],
 'amount': [50000, 120000, np.nan, 80000, 200000],
 'category': ['资产', '资产', '资产', '资产', None]
}

accounts_df = pd.DataFrame(accounts_data)
accounts_df
```

|   | account_number | account_name | amount   | category |
|---|----------------|--------------|----------|----------|
| 0 | 1001           | 现金           | 50000.0  | 资产       |
| 1 | 1002           | 应收账款         | 120000.0 | 资产       |
| 2 | 1003           | 存货           | NaN      | 资产       |
| 3 | 1004           | None         | 80000.0  | 资产       |
| 4 | 1005           | 固定资产         | 200000.0 | None     |

检查缺失值:



```
检查每列的缺失值数量
accounts_df.isnull().sum()
```

```
account_number 0
account_name 1
amount 1
category 1
dtype: int64
```

```
检查是否有任何缺失值
accounts_df.isnull().any()
```

```
account_number False
account_name True
amount True
category True
dtype: bool
```

```
查看包含缺失值的行
accounts_df[accounts_df.isnull().any(axis=1)]
```

|   | account_number | account_name | amount   | category |
|---|----------------|--------------|----------|----------|
| 2 | 1003           | 存货           | NaN      | 资产       |
| 3 | 1004           | None         | 80000.0  | 资产       |
| 4 | 1005           | 固定资产         | 200000.0 | None     |

## 4.5.2 处理缺失值

不同的处理方法:

```
方法 1: 删除包含缺失值的行
df_dropped = accounts_df.dropna()
print(f" 删除后剩余 {len(df_dropped)} 行")
df_dropped
```

删除后剩余 2 行

|   | account_number | account_name | amount   | category |
|---|----------------|--------------|----------|----------|
| 0 | 1001           | 现金           | 50000.0  | 资产       |
| 1 | 1002           | 应收账款         | 120000.0 | 资产       |

```
方法 2: 用特定值填充 (金额用 0 填充)
df_filled = accounts_df.copy()
df_filled['amount'] = df_filled['amount'].fillna(0)
df_filled
```

|   | account_number | account_name | amount   | category |
|---|----------------|--------------|----------|----------|
| 0 | 1001           | 现金           | 50000.0  | 资产       |
| 1 | 1002           | 应收账款         | 120000.0 | 资产       |
| 2 | 1003           | 存货           | 0.0      | 资产       |
| 3 | 1004           | None         | 80000.0  | 资产       |
| 4 | 1005           | 固定资产         | 200000.0 | None     |

```
方法 3: 用平均值填充 (适用于数值列)
df_mean = accounts_df.copy()
df_mean['amount'] =
 ↪ df_mean['amount'].fillna(accounts_df['amount'].mean())
df_mean
```

|   | account_number | account_name | amount   | category |
|---|----------------|--------------|----------|----------|
| 0 | 1001           | 现金           | 50000.0  | 资产       |
| 1 | 1002           | 应收账款         | 120000.0 | 资产       |
| 2 | 1003           | 存货           | 112500.0 | 资产       |
| 3 | 1004           | None         | 80000.0  | 资产       |
| 4 | 1005           | 固定资产         | 200000.0 | None     |

```
方法 4: 用前一个值填充 (forward fill)
df_ffill = accounts_df.copy()
df_ffill = df_ffill.fillna(method='ffill')
df_ffill
```

|   | account_number | account_name | amount   | category |
|---|----------------|--------------|----------|----------|
| 0 | 1001           | 现金           | 50000.0  | 资产       |
| 1 | 1002           | 应收账款         | 120000.0 | 资产       |
| 2 | 1003           | 存货           | 120000.0 | 资产       |
| 3 | 1004           | 存货           | 80000.0  | 资产       |
| 4 | 1005           | 固定资产         | 200000.0 | 资产       |

#### Tip

**会计应用:** 对于财务金额, 通常用 0 填充缺失值。对于分类数据 (如账户类别), 可能需要用“未分类”或最频繁类别填充。

### 4.5.3 检测重复数据

创建包含重复记录的交易数据:

```
创建包含重复的交易数据
transactions = pd.DataFrame({
 'transaction_id': ['T001', 'T002', 'T003', 'T002', 'T004'],
 'date': ['2024-01-01', '2024-01-02', '2024-01-03', '2024-01-02',
 ↵ '2024-01-04'],
```

```

 'amount': [1000, 2000, 1500, 2000, 3000],
 'description': ['销售收入', '采购支出', '销售收入', '采购支出', '销售
↵ 收入']
})
transactions

```

|   | transaction_id | date       | amount | description |
|---|----------------|------------|--------|-------------|
| 0 | T001           | 2024-01-01 | 1000   | 销售收入        |
| 1 | T002           | 2024-01-02 | 2000   | 采购支出        |
| 2 | T003           | 2024-01-03 | 1500   | 销售收入        |
| 3 | T002           | 2024-01-02 | 2000   | 采购支出        |
| 4 | T004           | 2024-01-04 | 3000   | 销售收入        |

检测重复:

```

检查完全重复的行
transactions.duplicated()

```

```

0 False
1 False
2 False
3 True
4 False
dtype: bool

```

```

查看重复的行
transactions[transactions.duplicated(keep=False)]

```

|   | transaction_id | date       | amount | description |
|---|----------------|------------|--------|-------------|
| 1 | T002           | 2024-01-02 | 2000   | 采购支出        |
| 3 | T002           | 2024-01-02 | 2000   | 采购支出        |

```
基于特定列检查重复 (交易 ID 应该是唯一的)
transactions.duplicated(subset=['transaction_id'])
```

```
0 False
1 False
2 False
3 True
4 False
dtype: bool
```

删除重复:

```
删除重复行, 保留第一次出现的
transactions_clean =
 ↪ transactions.drop_duplicates(subset=['transaction_id'], keep='first')
transactions_clean
```

|   | transaction_id | date       | amount | description |
|---|----------------|------------|--------|-------------|
| 0 | T001           | 2024-01-01 | 1000   | 销售收入        |
| 1 | T002           | 2024-01-02 | 2000   | 采购支出        |
| 2 | T003           | 2024-01-03 | 1500   | 销售收入        |
| 4 | T004           | 2024-01-04 | 3000   | 销售收入        |

#### Warning

**常见错误:** 删除重复数据前, 要确认哪些字段组合应该是唯一的。有时看似重复的记录可能是合法的 (如相同客户的多次交易)。

### 4.5.4 数据类型转换

创建需要类型转换的数据:

```
创建混合类型的财务数据
```

```
messy_data = pd.DataFrame({
 'account': ['1001', '1002', '1003', '1004'],
 'revenue': ['$1,200', '$2,500', '$1,800', '$3,200'],
 'cost': ['(500)', '1200', '(800)', '1500'],
 'quantity': ['100', '200', '150', '250']
})
messy_data
```

|   | account | revenue | cost  | quantity |
|---|---------|---------|-------|----------|
| 0 | 1001    | \$1,200 | (500) | 100      |
| 1 | 1002    | \$2,500 | 1200  | 200      |
| 2 | 1003    | \$1,800 | (800) | 150      |
| 3 | 1004    | \$3,200 | 1500  | 250      |

```
查看当前数据类型
```

```
messy_data.dtypes
```

```
account object
revenue object
cost object
quantity object
dtype: object
```

处理货币符号和逗号:

```
清理 revenue 列 (移除 $ 和逗号)
```

```
messy_data['revenue_clean'] = messy_data['revenue'].str.replace('$',
 ↪ '').str.replace(',', '').astype(float)
messy_data
```

|   | account | revenue | cost  | quantity | revenue_clean |
|---|---------|---------|-------|----------|---------------|
| 0 | 1001    | \$1,200 | (500) | 100      | 1200.0        |
| 1 | 1002    | \$2,500 | 1200  | 200      | 2500.0        |
| 2 | 1003    | \$1,800 | (800) | 150      | 1800.0        |
| 3 | 1004    | \$3,200 | 1500  | 250      | 3200.0        |

处理括号表示的负数 (会计中常用):

```
处理括号表示的负数
def parse_accounting_number(value):
 value = str(value).strip()
 if '(' in value:
 # 移除括号并转为负数
 return -float(value.replace('(', '').replace(')', ''))
 else:
 return float(value)

messy_data['cost_clean'] =
 ↪ messy_data['cost'].apply(parse_accounting_number)
messy_data[['cost', 'cost_clean']]
```

|   | cost  | cost_clean |
|---|-------|------------|
| 0 | (500) | -500.0     |
| 1 | 1200  | 1200.0     |
| 2 | (800) | -800.0     |
| 3 | 1500  | 1500.0     |

转换为数值类型:

```
转换 quantity 为整数
messy_data['quantity'] = pd.to_numeric(messy_data['quantity'],
 ↪ errors='coerce')
```

```
messy_data.dtypes
```

```
account object
revenue object
cost object
quantity int64
revenue_clean float64
cost_clean float64
dtype: object
```

#### 💡 Tip

会计应用: - 货币金额常包含货币符号 (\$, ¥) 和千位分隔符 - 负数可能用括号表示, 如 (1,000) 表示 -1000 - 账户编号应保持为字符串类型, 避免前导零丢失

### 4.5.5 数据验证

创建需要验证的账目数据:

```
创建试算平衡表数据
trial_balance = pd.DataFrame({
 'account': ['现金', '应收账款', '应付账款', '资本'],
 'debit': [10000, 5000, 0, 0],
 'credit': [0, 0, 3000, 12000]
})
trial_balance
```

|   | account | debit | credit |
|---|---------|-------|--------|
| 0 | 现金      | 10000 | 0      |
| 1 | 应收账款    | 5000  | 0      |
| 2 | 应付账款    | 0     | 3000   |
| 3 | 资本      | 0     | 12000  |

验证借贷平衡:



```

计算借贷总额
total_debit = trial_balance['debit'].sum()
total_credit = trial_balance['credit'].sum()

print(f" 借方总额: ¥{total_debit:,.2f}")
print(f" 贷方总额: ¥{total_credit:,.2f}")

验证是否平衡
if total_debit == total_credit:
 print(" 借贷平衡")
else:
 print(f" 不平衡, 差额: ¥{abs(total_debit - total_credit):,.2f}")

```

借方总额: ¥15,000.00

贷方总额: ¥15,000.00

借贷平衡

检查异常值:

```

创建包含异常值的销售数据
sales_data = pd.DataFrame({
 'product': ['A', 'B', 'C', 'D', 'E'],
 'units_sold': [100, 150, 200, 1000000, 180], # D 产品的数量明显异常
 'unit_price': [10, 15, 12, 11, 13]
})

使用 describe() 查看统计信息
sales_data['units_sold'].describe()

```

```

count 5.000000
mean 200126.000000
std 447143.160945
min 100.000000

```

```

25% 150.000000
50% 180.000000
75% 200.000000
max 1000000.000000
Name: units_sold, dtype: float64

```

```

识别异常值 (使用 IQR 方法)
Q1 = sales_data['units_sold'].quantile(0.25)
Q3 = sales_data['units_sold'].quantile(0.75)
IQR = Q3 - Q1

定义异常值范围
lower_bound = Q1 - 1.5 * IQR
upper_bound = Q3 + 1.5 * IQR

找出异常值
outliers = sales_data[(sales_data['units_sold'] < lower_bound) |
 (sales_data['units_sold'] > upper_bound)]

outliers

```

|   | product | units_sold | unit_price |
|---|---------|------------|------------|
| 3 | D       | 1000000    | 11         |

### Note

练习: 1. 创建一个包含缺失值的应收账款数据集 2. 检查并处理缺失的金额和客户名称  
3. 验证没有重复的发票号 4. 确保所有金额都是正数

## 4.6 DataFrame 筛选与条件过滤

学习目标: - 掌握多种数据筛选方法 - 学会条件过滤 - 应用于财务数据查询

### 4.6.1 切片操作

像 list 和 string 一样切片行数据:

```
前 3 行数据
df[:3]
```

|      | account_name | account_type | balance  | balance_direction |
|------|--------------|--------------|----------|-------------------|
| 1001 | 现金           | 资产           | 50000.0  | 借                 |
| 1002 | 银行存款         | 资产           | 200000.0 | 借                 |
| 1122 | 应收账款         | 资产           | 150000.0 | 借                 |

通过 Label(索引) 切片:

```
筛选账户编号 1001 到 1123 的科目
df.loc[1001:1123]
```

|      | account_name | account_type | balance  | balance_direction |
|------|--------------|--------------|----------|-------------------|
| 1001 | 现金           | 资产           | 50000.0  | 借                 |
| 1002 | 银行存款         | 资产           | 200000.0 | 借                 |
| 1122 | 应收账款         | 资产           | 150000.0 | 借                 |
| 1123 | 存货           | 资产           | 180000.0 | 借                 |

同时筛选行和列:

```
只查看特定科目的名称和余额
df.loc[1001:1123, ['account_name', 'balance']]
```

|      | account_name | balance  |
|------|--------------|----------|
| 1001 | 现金           | 50000.0  |
| 1002 | 银行存款         | 200000.0 |
| 1122 | 应收账款         | 150000.0 |

|      | account_name | balance  |
|------|--------------|----------|
| 1123 | 存货           | 180000.0 |

通过位置 (position) 筛选:

```
前 3 行, 选择第 1,3,2,4 列 (按位置)
df.iloc[:3, [0,2,1,3]]
```

|      | account_name | balance  | account_type | balance_direction |
|------|--------------|----------|--------------|-------------------|
| 1001 | 现金           | 50000.0  | 资产           | 借                 |
| 1002 | 银行存款         | 200000.0 | 资产           | 借                 |
| 1122 | 应收账款         | 150000.0 | 资产           | 借                 |

访问单个元素:

```
访问第一行第二列的值
df.iat[0, 1]
```

‘资产’

## 4.6.2 条件筛选

筛选余额大于 150000 的科目:

```
筛选高额余额账户
high_balance_accounts = df[df['balance'] > 150000]
high_balance_accounts
```

|      | account_name | account_type | balance  | balance_direction |
|------|--------------|--------------|----------|-------------------|
| 1002 | 银行存款         | 资产           | 200000.0 | 借                 |
| 1123 | 存货           | 资产           | 180000.0 | 借                 |

|      | account_name | account_type | balance  | balance_direction |
|------|--------------|--------------|----------|-------------------|
| 1601 | 固定资产         | 资产           | 300000.0 | 借                 |
| 4001 | 实收资本         | 所有者权益        | 680000.0 | 贷                 |

筛选资产类科目:

```
筛选所有资产类账户
asset_accounts = df[df['account_type'] == '资产']
asset_accounts
```

|      | account_name | account_type | balance  | balance_direction |
|------|--------------|--------------|----------|-------------------|
| 1001 | 现金           | 资产           | 50000.0  | 借                 |
| 1002 | 银行存款         | 资产           | 200000.0 | 借                 |
| 1122 | 应收账款         | 资产           | 150000.0 | 借                 |
| 1123 | 存货           | 资产           | 180000.0 | 借                 |
| 1601 | 固定资产         | 资产           | 300000.0 | 借                 |

多条件筛选 (使用 & 和 |):

```
筛选余额大于 100000 且为资产类的科目
df[(df['balance'] > 100000) & (df['account_type'] == '资产')]
```

|      | account_name | account_type | balance  | balance_direction |
|------|--------------|--------------|----------|-------------------|
| 1002 | 银行存款         | 资产           | 200000.0 | 借                 |
| 1122 | 应收账款         | 资产           | 150000.0 | 借                 |
| 1123 | 存货           | 资产           | 180000.0 | 借                 |
| 1601 | 固定资产         | 资产           | 300000.0 | 借                 |

```
筛选负债类或所有者权益类科目
df[(df['account_type'] == '负债') | (df['account_type'] == '所有者权益')]
```

|      | account_name | account_type | balance  | balance_direction |
|------|--------------|--------------|----------|-------------------|
| 2202 | 应付账款         | 负债           | 100000.0 | 贷                 |
| 4001 | 实收资本         | 所有者权益        | 680000.0 | 贷                 |

#### ⚠ Warning

注意: - 使用 & 表示“且”(AND) - 使用 | 表示“或”(OR) - 每个条件必须用括号括起来 - 不能使用 Python 的 and 和 or 关键字

### 4.6.3 使用 isin 筛选

筛选特定账户:

```
筛选现金和银行存款账户
df[df['account_name'].isin(['现金', '银行存款'])]
```

|      | account_name | account_type | balance  | balance_direction |
|------|--------------|--------------|----------|-------------------|
| 1001 | 现金           | 资产           | 50000.0  | 借                 |
| 1002 | 银行存款         | 资产           | 200000.0 | 借                 |

排除特定账户 (使用 ~ 取反):

```
筛选除现金外的所有账户
df[~df['account_name'].isin(['现金'])]
```

|      | account_name | account_type | balance  | balance_direction |
|------|--------------|--------------|----------|-------------------|
| 1002 | 银行存款         | 资产           | 200000.0 | 借                 |
| 1122 | 应收账款         | 资产           | 150000.0 | 借                 |
| 1123 | 存货           | 资产           | 180000.0 | 借                 |
| 1601 | 固定资产         | 资产           | 300000.0 | 借                 |
| 2202 | 应付账款         | 负债           | 100000.0 | 贷                 |
| 4001 | 实收资本         | 所有者权益        | 680000.0 | 贷                 |

## 4.6.4 query() 方法

更简洁的筛选方式:

```
使用 query 方法筛选
df.query('balance > 150000')
```

|      | account_name | account_type | balance  | balance_direction |
|------|--------------|--------------|----------|-------------------|
| 1002 | 银行存款         | 资产           | 200000.0 | 借                 |
| 1123 | 存货           | 资产           | 180000.0 | 借                 |
| 1601 | 固定资产         | 资产           | 300000.0 | 借                 |
| 4001 | 实收资本         | 所有者权益        | 680000.0 | 贷                 |

```
复杂条件查询
df.query('account_type == " 资产" and balance > 100000')
```

|      | account_name | account_type | balance  | balance_direction |
|------|--------------|--------------|----------|-------------------|
| 1002 | 银行存款         | 资产           | 200000.0 | 借                 |
| 1122 | 应收账款         | 资产           | 150000.0 | 借                 |
| 1123 | 存货           | 资产           | 180000.0 | 借                 |
| 1601 | 固定资产         | 资产           | 300000.0 | 借                 |

### Tip

会计应用: 条件筛选常用于: - 筛选特定类别的科目 (资产、负债等) - 查找大额交易或余额 - 识别异常账户 - 生成特定范围的财务报表

## 4.7 数据操作

### 4.7.1 赋值

首先创建副本:

```
df2 = df.copy()
```

```
df2
```

|      | account_name | account_type | balance  | balance_direction |
|------|--------------|--------------|----------|-------------------|
| 1001 | 现金           | 资产           | 50000.0  | 借                 |
| 1002 | 银行存款         | 资产           | 200000.0 | 借                 |
| 1122 | 应收账款         | 资产           | 150000.0 | 借                 |
| 1123 | 存货           | 资产           | 180000.0 | 借                 |
| 1601 | 固定资产         | 资产           | 300000.0 | 借                 |
| 2202 | 应付账款         | 负债           | 100000.0 | 贷                 |
| 4001 | 实收资本         | 所有者权益        | 680000.0 | 贷                 |

修改单个值和批量赋值:

```
修改单个值
```

```
df2.iat[0, 0] = " 库存现金"
```

```
批量修改特定行的某列值
```

```
df2.loc[1001:1123, 'balance'] = [55000, 210000, 160000, 190000]
```

```
创建新列 (余额的万元单位)
```

```
df2['balance_ 万元'] = df2['balance'] / 10000
```

```
df2
```

|      | account_name | account_type | balance  | balance_direction | balance_ 万元 |
|------|--------------|--------------|----------|-------------------|-------------|
| 1001 | 库存现金         | 资产           | 55000.0  | 借                 | 5.5         |
| 1002 | 银行存款         | 资产           | 210000.0 | 借                 | 21.0        |
| 1122 | 应收账款         | 资产           | 160000.0 | 借                 | 16.0        |
| 1123 | 存货           | 资产           | 190000.0 | 借                 | 19.0        |
| 1601 | 固定资产         | 资产           | 300000.0 | 借                 | 30.0        |
| 2202 | 应付账款         | 负债           | 100000.0 | 贷                 | 10.0        |



|      | account_name | account_type | balance  | balance_direction | balance_ 万元 |
|------|--------------|--------------|----------|-------------------|-------------|
| 4001 | 实收资本         | 所有者权益        | 680000.0 | 贷                 | 68.0        |

### 4.7.2 排序

按索引排序:

```
按账户编号（索引）排序
df.sort_index()
```

|      | account_name | account_type | balance  | balance_direction |
|------|--------------|--------------|----------|-------------------|
| 1001 | 现金           | 资产           | 50000.0  | 借                 |
| 1002 | 银行存款         | 资产           | 200000.0 | 借                 |
| 1122 | 应收账款         | 资产           | 150000.0 | 借                 |
| 1123 | 存货           | 资产           | 180000.0 | 借                 |
| 1601 | 固定资产         | 资产           | 300000.0 | 借                 |
| 2202 | 应付账款         | 负债           | 100000.0 | 贷                 |
| 4001 | 实收资本         | 所有者权益        | 680000.0 | 贷                 |

### 4.7.3 按值排序

```
按余额排序
df.sort_values('balance', ascending=False)
```

|      | account_name | account_type | balance  | balance_direction |
|------|--------------|--------------|----------|-------------------|
| 4001 | 实收资本         | 所有者权益        | 680000.0 | 贷                 |
| 1601 | 固定资产         | 资产           | 300000.0 | 借                 |
| 1002 | 银行存款         | 资产           | 200000.0 | 借                 |
| 1123 | 存货           | 资产           | 180000.0 | 借                 |
| 1122 | 应收账款         | 资产           | 150000.0 | 借                 |

|      | account_name | account_type | balance  | balance_direction |
|------|--------------|--------------|----------|-------------------|
| 2202 | 应付账款         | 负债           | 100000.0 | 贷                 |
| 1001 | 现金           | 资产           | 50000.0  | 借                 |

#### 4.7.4 重命名

批量重命名列名:

使用列表推导式:

```
df2 = df.copy()

df2.columns = [x.upper() for x in df.columns]
df2.head(2)
```

|      | ACCOUNT_NAME | ACCOUNT_TYPE | BALANCE  | BALANCE_DIRECTION |
|------|--------------|--------------|----------|-------------------|
| 1001 | 现金           | 资产           | 50000.0  | 借                 |
| 1002 | 银行存款         | 资产           | 200000.0 | 借                 |

#### 4.7.5 选择性重命名

使用 rename 方法:

```
df2 = df.copy()
df2 = df2.rename(columns={"account_name": "科目名称", "balance": "余额"},
 index={1001: "现金科目"})
df2.head(2)
```

|      | 科目名称 | account_type | 余额       | balance_direction |
|------|------|--------------|----------|-------------------|
| 现金科目 | 现金   | 资产           | 50000.0  | 借                 |
| 1002 | 银行存款 | 资产           | 200000.0 | 借                 |

### 4.7.6 删除行/列

删除行:

```
删除特定账户编号的行
df2 = df.drop(index=[1001, 1123])
df2
```

|      | account_name | account_type | balance  | balance_direction |
|------|--------------|--------------|----------|-------------------|
| 1002 | 银行存款         | 资产           | 200000.0 | 借                 |
| 1122 | 应收账款         | 资产           | 150000.0 | 借                 |
| 1601 | 固定资产         | 资产           | 300000.0 | 借                 |
| 2202 | 应付账款         | 负债           | 100000.0 | 贷                 |
| 4001 | 实收资本         | 所有者权益        | 680000.0 | 贷                 |

### 4.7.7 删除列

```
删除特定列
df2 = df.drop(columns=['balance_direction', 'account_type'])
df2
```

|      | account_name | balance  |
|------|--------------|----------|
| 1001 | 现金           | 50000.0  |
| 1002 | 银行存款         | 200000.0 |
| 1122 | 应收账款         | 150000.0 |
| 1123 | 存货           | 180000.0 |
| 1601 | 固定资产         | 300000.0 |
| 2202 | 应付账款         | 100000.0 |
| 4001 | 实收资本         | 680000.0 |

## 4.8 统计计算与自定义函数

### 4.8.1 统计量

均值:

```
计算余额的平均值
df['balance'].mean()
```

```
np.float64(237142.85714285713)
```

### 4.8.2 标准差

```
计算余额的标准差
df['balance'].std()
```

```
210611.3550052391
```

### 4.8.3 描述性统计

```
余额的描述性统计
df['balance'].describe()
```

```
count 7.000000
mean 237142.857143
std 210611.355005
min 50000.000000
25% 125000.000000
50% 180000.000000
75% 250000.000000
max 680000.000000
Name: balance, dtype: float64
```

## 4.8.4 财务计算

学习目标: - 掌握累计计算 (running totals) - 学会计算百分比变化 - 了解移动平均和滚动计算 - 应用财务比率分析

### 累计求和 (Running Totals)

创建月度收入数据:

```
创建月度收入数据
monthly_revenue = pd.DataFrame({
 'month': ['2024-01', '2024-02', '2024-03', '2024-04', '2024-05',
 ↪ '2024-06'],
 'revenue': [100000, 120000, 115000, 135000, 140000, 150000],
 'cost': [60000, 70000, 68000, 80000, 82000, 88000]
})
monthly_revenue
```

|   | month   | revenue | cost  |
|---|---------|---------|-------|
| 0 | 2024-01 | 100000  | 60000 |
| 1 | 2024-02 | 120000  | 70000 |
| 2 | 2024-03 | 115000  | 68000 |
| 3 | 2024-04 | 135000  | 80000 |
| 4 | 2024-05 | 140000  | 82000 |
| 5 | 2024-06 | 150000  | 88000 |

计算累计收入 (年初至今 YTD):

```
计算累计收入
monthly_revenue['累计收入'] = monthly_revenue['revenue'].cumsum()
monthly_revenue
```

|   | month   | revenue | cost  | 累计收入   |
|---|---------|---------|-------|--------|
| 0 | 2024-01 | 100000  | 60000 | 100000 |
| 1 | 2024-02 | 120000  | 70000 | 220000 |
| 2 | 2024-03 | 115000  | 68000 | 335000 |
| 3 | 2024-04 | 135000  | 80000 | 470000 |
| 4 | 2024-05 | 140000  | 82000 | 610000 |
| 5 | 2024-06 | 150000  | 88000 | 760000 |

计算累计利润:

```
先计算每月利润
monthly_revenue['profit'] = monthly_revenue['revenue'] -
 ↪ monthly_revenue['cost']
再计算累计利润
monthly_revenue['累计利润'] = monthly_revenue['profit'].cumsum()
monthly_revenue[['month', 'profit', '累计利润']]
```

|   | month   | profit | 累计利润   |
|---|---------|--------|--------|
| 0 | 2024-01 | 40000  | 40000  |
| 1 | 2024-02 | 50000  | 90000  |
| 2 | 2024-03 | 47000  | 137000 |
| 3 | 2024-04 | 55000  | 192000 |
| 4 | 2024-05 | 58000  | 250000 |
| 5 | 2024-06 | 62000  | 312000 |

#### 💡 Tip

会计应用: 累计求和常用于: - 年初至今 (YTD) 收入/支出 - 现金流量表中的期末余额 - 累计折旧计算

#### 百分比计算

计算环比增长率 (Month-over-Month):

```
计算环比增长率
monthly_revenue['环比增长率'] = monthly_revenue['revenue'].pct_change() *
 ↪ 100
monthly_revenue[['month', 'revenue', '环比增长率']]
```

|   | month   | revenue | 环比增长率     |
|---|---------|---------|-----------|
| 0 | 2024-01 | 100000  | NaN       |
| 1 | 2024-02 | 120000  | 20.000000 |
| 2 | 2024-03 | 115000  | -4.166667 |
| 3 | 2024-04 | 135000  | 17.391304 |
| 4 | 2024-05 | 140000  | 3.703704  |
| 5 | 2024-06 | 150000  | 7.142857  |

计算同比增长率 (需要上年同期数据):

```
创建两年数据
two_years_data = pd.DataFrame({
 'month': ['2023-01', '2023-02', '2023-03', '2024-01', '2024-02',
 ↪ '2024-03'],
 'revenue': [80000, 90000, 85000, 100000, 120000, 115000]
})

计算同比增长率 (与 3 个月前比较, 假设季度数据)
实际应用中通常是 12 个月
two_years_data['同比增长率'] =
 ↪ two_years_data['revenue'].pct_change(periods=3) * 100
two_years_data
```

|   | month   | revenue | 同比增长率 |
|---|---------|---------|-------|
| 0 | 2023-01 | 80000   | NaN   |
| 1 | 2023-02 | 90000   | NaN   |

|   | month   | revenue | 同比增长率     |
|---|---------|---------|-----------|
| 2 | 2023-03 | 85000   | NaN       |
| 3 | 2024-01 | 100000  | 25.000000 |
| 4 | 2024-02 | 120000  | 33.333333 |
| 5 | 2024-03 | 115000  | 35.294118 |

计算占比 (Percentage of Total):

```
创建部门收入数据
dept_revenue = pd.DataFrame({
 'department': ['销售部', '服务部', '咨询部', '培训部'],
 'revenue': [500000, 300000, 150000, 50000]
})

计算各部门收入占比
total_revenue = dept_revenue['revenue'].sum()
dept_revenue['收入占比%'] = (dept_revenue['revenue'] / total_revenue *
 ↪ 100).round(2)
dept_revenue
```

|   | department | revenue | 收入占比% |
|---|------------|---------|-------|
| 0 | 销售部        | 500000  | 50.0  |
| 1 | 服务部        | 300000  | 30.0  |
| 2 | 咨询部        | 150000  | 15.0  |
| 3 | 培训部        | 50000   | 5.0   |

**移动平均 (Moving Average)**

计算 3 个月移动平均:

```
创建更长时间序列
sales_data = pd.DataFrame({
```



```

'month': pd.date_range('2024-01', periods=12, freq='MS'),
'sales': [100, 110, 105, 120, 115, 125, 130, 135, 128, 140, 145, 150]
})

计算 3 个月移动平均
sales_data['MA_3'] = sales_data['sales'].rolling(window=3).mean()
sales_data[['month', 'sales', 'MA_3']]

```

|    | month      | sales | MA_3       |
|----|------------|-------|------------|
| 0  | 2024-01-01 | 100   | NaN        |
| 1  | 2024-02-01 | 110   | NaN        |
| 2  | 2024-03-01 | 105   | 105.000000 |
| 3  | 2024-04-01 | 120   | 111.666667 |
| 4  | 2024-05-01 | 115   | 113.333333 |
| 5  | 2024-06-01 | 125   | 120.000000 |
| 6  | 2024-07-01 | 130   | 123.333333 |
| 7  | 2024-08-01 | 135   | 130.000000 |
| 8  | 2024-09-01 | 128   | 131.000000 |
| 9  | 2024-10-01 | 140   | 134.333333 |
| 10 | 2024-11-01 | 145   | 137.666667 |
| 11 | 2024-12-01 | 150   | 145.000000 |

#### 💡 Tip

会计应用: 移动平均可以: - 平滑季节性波动 - 识别长期趋势 - 预测未来表现

## 4.8.5 财务比率计算

创建财务报表数据:

```

创建资产负债表和利润表数据
financial_data = pd.DataFrame({
 'period': ['Q1', 'Q2', 'Q3', 'Q4'],

```

```

 'current_assets': [500000, 520000, 480000, 550000],
 'current_liabilities': [300000, 310000, 290000, 320000],
 'total_assets': [1000000, 1050000, 1020000, 1100000],
 'total_liabilities': [600000, 620000, 610000, 650000],
 'revenue': [400000, 450000, 420000, 480000],
 'net_income': [50000, 60000, 55000, 70000]
})
financial_data

```

|   | period | current_assets | current_liabilities | total_assets | total_liabilities | revenue | net_income |
|---|--------|----------------|---------------------|--------------|-------------------|---------|------------|
| 0 | Q1     | 500000         | 300000              | 1000000      | 600000            | 400000  | 50000      |
| 1 | Q2     | 520000         | 310000              | 1050000      | 620000            | 450000  | 60000      |
| 2 | Q3     | 480000         | 290000              | 1020000      | 610000            | 420000  | 55000      |
| 3 | Q4     | 550000         | 320000              | 1100000      | 650000            | 480000  | 70000      |

计算流动比率 (Current Ratio):

```

流动比率 = 流动资产 / 流动负债
financial_data['流动比率'] = (financial_data['current_assets'] /

 ↪ financial_data['current_liabilities']).round(2)
financial_data[['period', '流动比率']]

```

|   | period | 流动比率 |
|---|--------|------|
| 0 | Q1     | 1.67 |
| 1 | Q2     | 1.68 |
| 2 | Q3     | 1.66 |
| 3 | Q4     | 1.72 |

计算资产负债率 (Debt-to-Asset Ratio):

```
资产负债率 = 总负债 / 总资产
financial_data['资产负债率%'] = (financial_data['total_liabilities'] /
 financial_data['total_assets'] *
 ↪ 100).round(2)
financial_data[['period', '资产负债率%']]
```

|   | period | 资产负债率% |
|---|--------|--------|
| 0 | Q1     | 60.00  |
| 1 | Q2     | 59.05  |
| 2 | Q3     | 59.80  |
| 3 | Q4     | 59.09  |

计算净利润率 (Net Profit Margin):

```
净利润率 = 净利润 / 营业收入
financial_data['净利润率%'] = (financial_data['net_income'] /
 financial_data['revenue'] * 100).round(2)
financial_data[['period', 'revenue', 'net_income', '净利润率%']]
```

|   | period | revenue | net_income | 净利润率% |
|---|--------|---------|------------|-------|
| 0 | Q1     | 400000  | 50000      | 12.50 |
| 1 | Q2     | 450000  | 60000      | 13.33 |
| 2 | Q3     | 420000  | 55000      | 13.10 |
| 3 | Q4     | 480000  | 70000      | 14.58 |

现金流量计算

创建现金流量数据:

```
创建现金流量数据
cash_flow = pd.DataFrame({
 'date': pd.date_range('2024-01-01', periods=10, freq='D'),
```

```

 'cash_in': [50000, 0, 30000, 45000, 0, 60000, 0, 40000, 55000, 0],
 'cash_out': [20000, 15000, 25000, 10000, 30000, 20000, 15000, 25000,
 ↪ 20000, 18000]
})

计算每日净现金流
cash_flow['net_cash_flow'] = cash_flow['cash_in'] - cash_flow['cash_out']

计算现金余额（假设期初余额为 100000）
opening_balance = 100000
cash_flow['cash_balance'] = opening_balance +
 ↪ cash_flow['net_cash_flow'].cumsum()

cash_flow

```

|   | date       | cash_in | cash_out | net_cash_flow | cash_balance |
|---|------------|---------|----------|---------------|--------------|
| 0 | 2024-01-01 | 50000   | 20000    | 30000         | 130000       |
| 1 | 2024-01-02 | 0       | 15000    | -15000        | 115000       |
| 2 | 2024-01-03 | 30000   | 25000    | 5000          | 120000       |
| 3 | 2024-01-04 | 45000   | 10000    | 35000         | 155000       |
| 4 | 2024-01-05 | 0       | 30000    | -30000        | 125000       |
| 5 | 2024-01-06 | 60000   | 20000    | 40000         | 165000       |
| 6 | 2024-01-07 | 0       | 15000    | -15000        | 150000       |
| 7 | 2024-01-08 | 40000   | 25000    | 15000         | 165000       |
| 8 | 2024-01-09 | 55000   | 20000    | 35000         | 200000       |
| 9 | 2024-01-10 | 0       | 18000    | -18000        | 182000       |

### Note

练习: 1. 创建一个 12 个月的销售数据集 2. 计算每月的环比增长率 3. 计算 6 个月移动平均 4. 找出销售额低于移动平均的月份

## 4.9 实用工具函数

### 4.9.1 自定义函数

定义函数并应用到 DataFrame:

```
定义一个函数将余额转换为万元并四舍五入
def to_wan_yuan(x):
 return round(x / 10000, 2)

应用到余额列
df['balance'].transform(to_wan_yuan)
```

```
1001 5.0
1002 20.0
1122 15.0
1123 18.0
1601 30.0
2202 10.0
4001 68.0
```

Name: balance, dtype: float64

### 4.9.2 字符串操作

转换为小写:

```
将账户类型转换为小写
df['account_type'].str.lower()
```

```
1001 资产
1002 资产
1122 资产
1123 资产
1601 资产
```

```
2202 负债
4001 所有者权益
Name: account_type, dtype: object
```

### 4.9.3 获取字符串长度

```
获取账户名称的长度
df['account_name'].str.len()
```

```
1001 2
1002 4
1122 4
1123 2
1601 4
2202 4
4001 4
Name: account_name, dtype: int64
```

### 4.9.4 判断是否包含特定字符

```
判断账户名称是否包含" 账款"
df['account_name'].str.contains('账款')
```

```
1001 False
1002 False
1122 True
1123 False
1601 False
2202 True
4001 False
Name: account_name, dtype: bool
```

### 4.9.5 字符串索引

```
获取账户名称的第一个字
df['account_name'].str[0]
```

```
1001 现
1002 银
1122 应
1123 存
1601 固
2202 应
4001 实
```

```
Name: account_name, dtype: object
```

### 4.9.6 随机抽样

抽取指定数量的样本:

```
df.sample(2)
```

|      | account_name | account_type | balance  | balance_direction |
|------|--------------|--------------|----------|-------------------|
| 1002 | 银行存款         | 资产           | 200000.0 | 借                 |
| 1123 | 存货           | 资产           | 180000.0 | 借                 |

### 4.9.7 按比例抽样

```
df.sample(frac = 0.4)
```


|      | account_name | account_type | balance  | balance_direction |
|------|--------------|--------------|----------|-------------------|
| 1601 | 固定资产         | 资产           | 300000.0 | 借                 |
| 4001 | 实收资本         | 所有者权益        | 680000.0 | 贷                 |

|      | account_name | account_type | balance | balance_direction |
|------|--------------|--------------|---------|-------------------|
| 1001 | 现金           | 资产           | 50000.0 | 借                 |

## 4.10 数据合并

### 4.10.1 concat 合并

用标签对齐合并数据 (index / columns)



创建示例数据:

```
df1 = pd.DataFrame(
 {'A': ['A0', 'A1', 'A2', 'A3'],
 'B': ['B0', 'B1', 'B2', 'B3'],
 'C': ['C0', 'C1', 'C2', 'C3'],
 'D': ['D0', 'D1', 'D2', 'D3']})

df2 = pd.DataFrame(
 {'A': ['A4', 'A5', 'A6', 'A7'],
 'B': ['B4', 'B5', 'B6', 'B7'],
 'C': ['C4', 'C5', 'C6', 'C7'],
 'D': ['D4', 'D5', 'D6', 'D7']},
```



```
index=[4, 5, 6, 7])
```

纵向合并 (axis=0):

```
pd.concat([df1, df2], axis= 0, sort=False)
```

|   | A  | B  | C  | D  |
|---|----|----|----|----|
| 0 | A0 | B0 | C0 | D0 |
| 1 | A1 | B1 | C1 | D1 |
| 2 | A2 | B2 | C2 | D2 |
| 3 | A3 | B3 | C3 | D3 |
| 4 | A4 | B4 | C4 | D4 |
| 5 | A5 | B5 | C5 | D5 |
| 6 | A6 | B6 | C6 | D6 |
| 7 | A7 | B7 | C7 | D7 |

横向合并 (axis=1) - 创建第三个 DataFrame:

```
df3 = pd.DataFrame(
 {'B': ['B2', 'B3', 'B6', 'B7'],
 'D': ['D2', 'D3', 'D6', 'D7'],
 'F': ['F2', 'F3', 'F6', 'F7']},
 index=[2, 3, 6, 7])
df3
```

|   | B  | D  | F  |
|---|----|----|----|
| 2 | B2 | D2 | F2 |
| 3 | B3 | D3 | F3 |
| 6 | B6 | D6 | F6 |
| 7 | B7 | D7 | F7 |

横向合并:

```
pd.concat([df1, df3], axis= 1, sort=False)
```


|   | A   | B   | C   | D   | B   | D   | F   |
|---|-----|-----|-----|-----|-----|-----|-----|
| 0 | A0  | B0  | C0  | D0  | NaN | NaN | NaN |
| 1 | A1  | B1  | C1  | D1  | NaN | NaN | NaN |
| 2 | A2  | B2  | C2  | D2  | B2  | D2  | F2  |
| 3 | A3  | B3  | C3  | D3  | B3  | D3  | F3  |
| 6 | NaN | NaN | NaN | NaN | B6  | D6  | F6  |
| 7 | NaN | NaN | NaN | NaN | B7  | D7  | F7  |

## 4.10.2 merge 合并

用 values 合并数据, 参考文档: [pandas.merge\(\)](#)

准备数据:

```
df1['n1'] = df1.A.str[-1]
df3['n3'] = df3.B.str[-1]
```



执行 merge 操作:

```
df1.merge(df3, left_on='n1', right_on='n3', how='inner')
```

|   | A  | B_x | C  | D_x | n1 | B_y | D_y | F  | n3 |
|---|----|-----|----|-----|----|-----|-----|----|----|
| 0 | A2 | B2  | C2 | D2  | 2  | B2  | D2  | F2 | 2  |
| 1 | A3 | B3  | C3 | D3  | 3  | B3  | D3  | F3 | 3  |

## 4.11 时间日期处理

创建日期数据:

```
data = {
 'date': ['2020-08-25', '2021-07-26',
 '2022-06-27', '2023-05-28', '2024-04-29'],
 'value': [10, 15, 7, 25, 30]
}

df = pd.DataFrame(data)
Convert the 'date' column to datetime format
df['date'] = pd.to_datetime(df['date'])
df.dtypes
```

```
date datetime64[ns]
value int64
dtype: object
```

提取年份:

```
df.date.dt.year
```

```
0 2020
1 2021
```

```
2 2022
3 2023
4 2024
```

```
Name: date, dtype: int32
```

提取月份:

```
df.date.dt.month
```

```
0 8
1 7
2 6
3 5
4 4
```

```
Name: date, dtype: int32
```

提取周数:

```
df.date.dt.isocalendar().week
```

```
0 35
1 30
2 26
3 21
4 18
```

```
Name: week, dtype: UInt32
```

提取日:

```
df.date.dt.day
```

```
0 25
1 26
2 27
```

3 28

4 29

Name: date, dtype: int32

星期几:

```
df.date.dt.day_of_week
Monday=0, Sunday=6
df.date.dt.day_name()
```

0 1

1 0

2 0

3 6

4 0

Name: date, dtype: int32

一年中的第几天:

```
df.date.dt.day_of_year
```

0 238

1 207

2 178

3 148

4 120

Name: date, dtype: int32


## 4.12 数据可视化

启用 matplotlib 内联显示:

```
%matplotlib inline
```


直方图:

```
from dfply import diamonds
diamonds.price.hist()
```




散点图:

```
from dfply import diamonds
diamonds.plot.scatter('carat', 'price')
```



seaborn 散点图:

```
import seaborn as sns
sns.scatterplot(x="carat", y="price", hue="cut", data=diamonds)
```



## 4.13 分组与聚合 (Grouping & Aggregation)

学习目标: - 掌握按类别分组汇总数据 - 学会多维度聚合 - 创建会计汇总报表 - 理解透视表在财务分析中的应用

### 4.13.1 基本分组

创建交易明细数据:

```
创建会计分录数据
ledger_data = pd.DataFrame({
 'date': ['2024-01-05', '2024-01-05', '2024-01-06', '2024-01-06',
 ↪ '2024-01-07', '2024-01-07'],
 'account': ['现金', '应收账款', '现金', '应收账款', '现金', '销售收
 ↪ 入'],
 'category': ['资产', '资产', '资产', '资产', '资产', '收入'],
```

```

 'debit': [10000, 5000, 8000, 3000, 6000, 0],
 'credit': [0, 0, 0, 0, 0, 6000]
})
ledger_data

```

|   | date       | account | category | debit | credit |
|---|------------|---------|----------|-------|--------|
| 0 | 2024-01-05 | 现金      | 资产       | 10000 | 0      |
| 1 | 2024-01-05 | 应收账款    | 资产       | 5000  | 0      |
| 2 | 2024-01-06 | 现金      | 资产       | 8000  | 0      |
| 3 | 2024-01-06 | 应收账款    | 资产       | 3000  | 0      |
| 4 | 2024-01-07 | 现金      | 资产       | 6000  | 0      |
| 5 | 2024-01-07 | 销售收入    | 收入       | 0     | 6000   |

按账户分组求和:

```

按账户汇总借贷金额
ledger_data.groupby('account').agg({
 'debit': 'sum',
 'credit': 'sum'
}).reset_index()

```

|   | account | debit | credit |
|---|---------|-------|--------|
| 0 | 应收账款    | 8000  | 0      |
| 1 | 现金      | 24000 | 0      |
| 2 | 销售收入    | 0     | 6000   |

按类别分组:

```

按账户类别汇总
ledger_data.groupby('category').agg({
 'debit': 'sum',

```



```

 'credit': 'sum'
 }).reset_index()

```

|   | category | debit | credit |
|---|----------|-------|--------|
| 0 | 收入       | 0     | 6000   |
| 1 | 资产       | 32000 | 0      |

### 4.13.2 多维度聚合

创建更复杂的销售数据:

```

创建销售明细数据
sales_detail = pd.DataFrame({
 'date': pd.to_datetime(['2024-01-15', '2024-01-16', '2024-01-15',
 ↪ '2024-01-16',
 '2024-02-15', '2024-02-16', '2024-02-15',
 ↪ '2024-02-16']),
 'region': ['华东', '华东', '华南', '华南', '华东', '华东', '华南',
 ↪ '华南'],
 'product': ['A 产品', 'B 产品', 'A 产品', 'B 产品', 'A 产品', 'B 产
 ↪ 品', 'A 产品', 'B 产品'],
 'quantity': [100, 150, 120, 80, 110, 160, 130, 90],
 'unit_price': [100, 150, 100, 150, 100, 150, 100, 150]
})

计算销售金额
sales_detail['amount'] = sales_detail['quantity'] *
 ↪ sales_detail['unit_price']
sales_detail

```

|   | date       | region | product | quantity | unit_price | amount |
|---|------------|--------|---------|----------|------------|--------|
| 0 | 2024-01-15 | 华东     | A 产品    | 100      | 100        | 10000  |
| 1 | 2024-01-16 | 华东     | B 产品    | 150      | 150        | 22500  |
| 2 | 2024-01-15 | 华南     | A 产品    | 120      | 100        | 12000  |
| 3 | 2024-01-16 | 华南     | B 产品    | 80       | 150        | 12000  |
| 4 | 2024-02-15 | 华东     | A 产品    | 110      | 100        | 11000  |
| 5 | 2024-02-16 | 华东     | B 产品    | 160      | 150        | 24000  |
| 6 | 2024-02-15 | 华南     | A 产品    | 130      | 100        | 13000  |
| 7 | 2024-02-16 | 华南     | B 产品    | 90       | 150        | 13500  |

多列聚合:

```
按地区和产品分组，计算多个统计量
sales_summary = sales_detail.groupby(['region', 'product']).agg({
 'quantity': 'sum',
 'amount': ['sum', 'mean', 'count']
}).round(2)
sales_summary
```

|        |      | 9       |   |
|--------|------|---------|---|
|        |      | s       |   |
| region |      | product |   |
| 华东     | A 产品 | 2       | 9 |
|        | B 产品 | 3       | 3 |
| 华南     | A 产品 | 2       | 2 |
|        | B 产品 | 1       | 1 |

自定义聚合函数:

```
按地区汇总，使用自定义聚合
regional_summary = sales_detail.groupby('region').agg({
 'amount': ['sum', 'mean', 'max', 'min'],
```

```

 'quantity': 'sum'
 })
regional_summary.columns = ['总金额', '平均金额', '最大单笔', '最小单笔',
 ↪ '总数量']
regional_summary

```

|        | 总金额   | 平均金额    | 最大单笔  | 最小单笔  | 总数量 |
|--------|-------|---------|-------|-------|-----|
| region |       |         |       |       |     |
| 华东     | 67500 | 16875.0 | 24000 | 10000 | 520 |
| 华南     | 50500 | 12625.0 | 13500 | 12000 | 420 |

#### Tip

**会计应用：**分组聚合常用于：- 按科目汇总账目 - 按部门/项目汇总费用 - 按期间汇总收入成本 - 生成试算平衡表

### 4.13.3 创建汇总表（带小计和合计）

```

创建费用明细数据
expense_data = pd.DataFrame({
 'department': ['销售部', '销售部', '财务部', '财务部', '人力部', '人力
 ↪ 部'],
 'category': ['差旅费', '办公费', '差旅费', '办公费', '差旅费', '办公
 ↪ 费'],
 'amount': [5000, 2000, 3000, 1500, 2000, 1000]
})

按部门和类别分组
expense_summary = expense_data.groupby(['department',
 ↪ 'category'])['amount'].sum()
print(" 明细汇总:")
print(expense_summary)

```

```
print("\n部门小计:")
print(expense_summary.groupby('department').sum())
print(f"\n总计: ¥{expense_data['amount'].sum():.2f}")
```

明细汇总:

| department | category |      |
|------------|----------|------|
| 人力部        | 办公费      | 1000 |
|            | 差旅费      | 2000 |
| 财务部        | 办公费      | 1500 |
|            | 差旅费      | 3000 |
| 销售部        | 办公费      | 2000 |
|            | 差旅费      | 5000 |

Name: amount, dtype: int64

部门小计:

| department |      |
|------------|------|
| 人力部        | 3000 |
| 财务部        | 4500 |
| 销售部        | 7000 |

Name: amount, dtype: int64

总计: ¥14,500.00

#### 4.13.4 条件聚合

```
创建应收账款账龄数据
receivables = pd.DataFrame({
 'customer': ['客户 A', '客户 B', '客户 C', '客户 D', '客户 E'],
 'invoice_date': pd.to_datetime(['2024-01-01', '2024-02-15',
 ↪ '2024-03-10',
 '2024-01-20', '2024-02-28']),
 'amount': [50000, 30000, 40000, 25000, 35000],
```

```

 'paid': [True, False, False, True, False]
})

计算账龄（假设今天是 2024-04-01）
current_date = pd.to_datetime('2024-04-01')
receivables['days_outstanding'] = (current_date -
 ↪ receivables['invoice_date']).dt.days

receivables

```

|   | customer | invoice_date | amount | paid  | days_outstanding |
|---|----------|--------------|--------|-------|------------------|
| 0 | 客户 A     | 2024-01-01   | 50000  | True  | 91               |
| 1 | 客户 B     | 2024-02-15   | 30000  | False | 46               |
| 2 | 客户 C     | 2024-03-10   | 40000  | False | 22               |
| 3 | 客户 D     | 2024-01-20   | 25000  | True  | 72               |
| 4 | 客户 E     | 2024-02-28   | 35000  | False | 33               |

按付款状态分组:

```

按付款状态汇总
payment_summary = receivables.groupby('paid').agg({
 'amount': ['sum', 'count'],
 'days_outstanding': 'mean'
})

payment_summary.columns = ['总金额', '笔数', '平均账龄']
payment_summary

```

|       | 总金额    | 笔数 | 平均账龄      |
|-------|--------|----|-----------|
| paid  |        |    |           |
| False | 105000 | 3  | 33.666667 |
| True  | 75000  | 2  | 81.500000 |

创建账龄分析:

```
创建账龄区间
receivables['aging_bucket'] = pd.cut(receivables['days_outstanding'],
 bins=[0, 30, 60, 90, float('inf')],
 labels=['0-30 天', '31-60 天',
 '61-90 天', '90 天以上'])

按账龄区间汇总
aging_analysis =
 receivables.groupby('aging_bucket')['amount'].agg(['sum', 'count'])
aging_analysis.columns = ['金额', '笔数']
aging_analysis
```

|              | 金额    | 笔数 |
|--------------|-------|----|
| aging_bucket |       |    |
| 0-30 天       | 40000 | 1  |
| 31-60 天      | 65000 | 2  |
| 61-90 天      | 25000 | 1  |
| 90 天以上       | 50000 | 1  |

#### Note

练习: 1. 创建一个包含多个月销售数据的 DataFrame 2. 按月份和产品分组, 计算销售总额 3. 找出每月销售最高的产品 4. 计算每个产品的月平均销售额

### 4.13.5 Excel 风格的对比

会计师常用的 Excel 功能在 pandas 中的对应操作:

| Excel 功能 | Pandas 方法         | 说明   |
|----------|-------------------|------|
| SUMIF    | groupby().sum()   | 条件求和 |
| COUNTIF  | groupby().count() | 条件计数 |

| Excel 功能    | Pandas 方法         | 说明    |
|-------------|-------------------|-------|
| AVERAGEIF   | groupby().mean()  | 条件平均  |
| Subtotal    | groupby() + agg() | 分类小计  |
| Pivot Table | pivot_table()     | 数据透视表 |



Tip

从 **Excel** 到 **Pandas**: 如果你熟悉 Excel 的数据透视表,pandas 的 `pivot_table()` 和 `groupby()` 可以实现相同甚至更强大的功能。

### 4.13.6 数据透视表 (Pivot Tables)

学习目标: - 掌握创建数据透视表 - 学会多维度数据分析 - 创建财务交叉报表 - 生成专业的财务分析报告

#### `pivot()` 基础

创建销售数据:

```
创建简单的销售数据
simple_sales = pd.DataFrame({
 'date': ['2024-01', '2024-01', '2024-02', '2024-02'],
 'region': ['华东', '华南', '华东', '华南'],
 'sales': [200000, 150000, 220000, 180000]
})
simple_sales
```

|   | date    | region | sales  |
|---|---------|--------|--------|
| 0 | 2024-01 | 华东     | 200000 |
| 1 | 2024-01 | 华南     | 150000 |
| 2 | 2024-02 | 华东     | 220000 |
| 3 | 2024-02 | 华南     | 180000 |

创建数据透视表:

```
将数据重塑为表格形式
pivot_df = simple_sales.pivot(
 index='date',
 columns='region',
 values='sales')
pivot_df
```

| region  | 华东     | 华南     |
|---------|--------|--------|
| date    |        |        |
| 2024-01 | 200000 | 150000 |
| 2024-02 | 220000 | 180000 |

- **pivot()**: 通过将一列的唯一值转换为新列来重塑数据。适用于没有重复索引的情况。
- **pivot\_table()**: 用于对数据进行分组、汇总和聚合，可以根据数据的不同维度计算聚合值。可以处理重复值。

### **pivot\_table()** 高级应用

创建更复杂的财务数据:

```
创建包含重复值的月度财务数据
financial_trans = pd.DataFrame({
 'month': ['1 月', '1 月', '1 月', '2 月', '2 月', '2 月', '3 月', '3
 ↪ 月', '3 月'] * 2,
 'category': ['收入', '成本', '费用'] * 6,
 'department': ['销售部']*9 + ['服务部']*9,
 'amount': [500000, 300000, 80000, 520000, 310000, 85000, 480000,
 ↪ 290000, 75000,
 300000, 180000, 50000, 310000, 185000, 52000, 290000,
 ↪ 175000, 48000]
})
financial_trans.head(10)
```



|   | month | category | department | amount |
|---|-------|----------|------------|--------|
| 0 | 1 月   | 收入       | 销售部        | 500000 |
| 1 | 1 月   | 成本       | 销售部        | 300000 |
| 2 | 1 月   | 费用       | 销售部        | 80000  |
| 3 | 2 月   | 收入       | 销售部        | 520000 |
| 4 | 2 月   | 成本       | 销售部        | 310000 |
| 5 | 2 月   | 费用       | 销售部        | 85000  |
| 6 | 3 月   | 收入       | 销售部        | 480000 |
| 7 | 3 月   | 成本       | 销售部        | 290000 |
| 8 | 3 月   | 费用       | 销售部        | 75000  |
| 9 | 1 月   | 收入       | 服务部        | 300000 |

创建部门-类别透视表:

```
创建透视表，按部门和类别汇总
dept_pivot = pd.pivot_table(financial_trans,
 values='amount',
 index='department',
 columns='category',
 aggfunc='sum',
 fill_value=0)

dept_pivot
```

| category   | 成本     | 收入      | 费用     |
|------------|--------|---------|--------|
| department |        |         |        |
| 服务部        | 540000 | 900000  | 150000 |
| 销售部        | 900000 | 1500000 | 240000 |

添加行列汇总:

```
添加小计和合计
dept_pivot_total = pd.pivot_table(financial_trans,
 values='amount',
 index='department',
 columns='category',
 aggfunc='sum',
 fill_value=0,
 margins=True, # 添加汇总行和列
 margins_name='总计')

dept_pivot_total
```

| category   | 成本      | 收入      | 费用     | 总计      |
|------------|---------|---------|--------|---------|
| department |         |         |        |         |
| 服务部        | 540000  | 900000  | 150000 | 1590000 |
| 销售部        | 900000  | 1500000 | 240000 | 2640000 |
| 总计         | 1440000 | 2400000 | 390000 | 4230000 |

计算利润:

```
创建一个包含计算列的透视表副本
profit_analysis = dept_pivot.copy()
profit_analysis['利润'] = profit_analysis['收入'] - profit_analysis['成本'] - profit_analysis['费用']
profit_analysis['利润率%'] = (profit_analysis['利润'] /
 profit_analysis['收入'] * 100).round(2)
profit_analysis
```

| category   | 成本     | 收入      | 费用     | 利润     | 利润率%  |
|------------|--------|---------|--------|--------|-------|
| department |        |         |        |        |       |
| 服务部        | 540000 | 900000  | 150000 | 210000 | 23.33 |
| 销售部        | 900000 | 1500000 | 240000 | 360000 | 24.00 |

💡 Tip

会计应用: 数据透视表在财务分析中常用于: - 多维度收入分析 (按产品、地区、时间) - 成本费用分析 (按部门、类别、期间) - 预算 vs 实际对比 - 盈利能力分析

多级透视表

创建更详细的数据:

```
创建季度-月度-产品销售数据
detailed_sales = pd.DataFrame({
 'quarter': ['Q1', 'Q1', 'Q1', 'Q2', 'Q2', 'Q2'] * 4,
 'month': ['1 月', '2 月', '3 月', '4 月', '5 月', '6 月'] * 4,
 'product': ['产品 A']*6 + ['产品 B']*6 + ['产品 C']*6 + ['产品 D']*6,
 'revenue': [100, 110, 105, 120, 115, 125,
 80, 85, 82, 90, 88, 95,
 60, 65, 62, 70, 68, 72,
 50, 55, 52, 60, 58, 62]
})

创建多级索引的透视表
multi_pivot = pd.pivot_table(detailed_sales,
 values='revenue',
 index=['quarter', 'product'],
 columns='month',
 aggfunc='sum',
 fill_value=0)

multi_pivot
```

| quarter | month   |   |   |
|---------|---------|---|---|
|         | product |   |   |
| Q1      | 产品 A    | 1 | 1 |
|         | 产品 B    | 8 | 8 |

| quarter | month | product |   |
|---------|-------|---------|---|
|         |       |         |   |
| Q2      |       | 产品 C    | 6 |
|         |       | 产品 D    | 5 |
|         |       | 产品 A    | 0 |
|         |       | 产品 B    | 0 |
|         |       | 产品 C    | 0 |
|         |       | 产品 D    | 0 |

## 交叉表 (Cross-tabulation)

交叉表用于统计频次:

```
创建交易批准数据
approval_data = pd.DataFrame({
 'department': ['销售部', '采购部', '销售部', '财务部', '采购部',
 '销售部', '财务部', '采购部', '销售部', '财务部'],
 'status': ['已批准', '已批准', '待审批', '已批准', '已拒绝',
 '已批准', '待审批', '已批准', '已拒绝', '已批准'],
 'amount': [50000, 30000, 45000, 25000, 20000,
 55000, 28000, 35000, 40000, 22000]
})

创建交叉表统计各状态的笔数
status_crosstab = pd.crosstab(approval_data['department'],
 approval_data['status'],
 margins=True,
 margins_name='总计')

status_crosstab
```

| status     | 已批准 | 已拒绝 | 待审批 | 总计 |
|------------|-----|-----|-----|----|
| department |     |     |     |    |
| 财务部        | 2   | 0   | 1   | 3  |
| 采购部        | 2   | 1   | 0   | 3  |
| 销售部        | 2   | 1   | 1   | 4  |
| 总计         | 6   | 2   | 2   | 10 |

交叉表 with 汇总金额:

```
统计各状态的总金额
amount_crosstab = pd.crosstab(approval_data['department'],
 approval_data['status'],
 values=approval_data['amount'],
 aggfunc='sum',
 margins=True,
 margins_name='总计')

amount_crosstab.fillna(0)
```

| status     | 已批准      | 已拒绝     | 待审批     | 总计     |
|------------|----------|---------|---------|--------|
| department |          |         |         |        |
| 财务部        | 47000.0  | 0.0     | 28000.0 | 75000  |
| 采购部        | 65000.0  | 20000.0 | 0.0     | 85000  |
| 销售部        | 105000.0 | 40000.0 | 45000.0 | 190000 |
| 总计         | 217000.0 | 60000.0 | 73000.0 | 350000 |

### Note

练习: 1. 创建一个包含多个产品线、多个地区、多个月份的销售数据 2. 使用 `pivot_table` 创建地区 × 产品的销售金额透视表 3. 添加 `margins` 参数显示小计 4. 计算每个地区各产品的销售占比

## stack 和 unstack

stack 操作 (列转行):

```
pivot_df.stack()
```

```
date region
2024-01 华东 200000
 华南 150000
2024-02 华东 220000
 华南 180000
dtype: int64
```

**unstack** 操作 (行转列):

```
pivot_df.stack().unstack()
```

| region  | 华东     | 华南     |
|---------|--------|--------|
| date    |        |        |
| 2024-01 | 200000 | 150000 |
| 2024-02 | 220000 | 180000 |

- **unstack()**: 将最内层的行索引转换为列。
- **stack()**: 将最内层的列索引转换为行索引, 创建一个具有多重索引的 **Series**。

## 4.14 综合案例: 销售收入分析

**案例背景:** 某零售公司需要分析 2024 年第一季度的销售情况, 包括不同产品线、不同地区的销售表现, 以及应收账款的管理情况。

### 4.14.1 步骤 1: 准备数据

```
创建销售交易数据
sales_transactions = pd.DataFrame({
 'transaction_id': ['T001', 'T002', 'T003', 'T004', 'T005', 'T006',
↵ 'T007', 'T008',
```

```

 'T009', 'T010', 'T011', 'T012', 'T013', 'T014',
 ↪ 'T015'],
'date': pd.to_datetime(['2024-01-05', '2024-01-08', '2024-01-12',
 ↪ '2024-01-15', '2024-01-20',
 '2024-02-03', '2024-02-07', '2024-02-14',
 ↪ '2024-02-18', '2024-02-25',
 '2024-03-05', '2024-03-10', '2024-03-15',
 ↪ '2024-03-20', '2024-03-28']),
'customer': ['客户 A', '客户 B', '客户 A', '客户 C', '客户 B',
 '客户 A', '客户 D', '客户 C', '客户 B', '客户 E',
 '客户 A', '客户 D', '客户 C', '客户 E', '客户 B'],
'product_line': ['电子产品', '家居用品', '电子产品', '服装', '家居用
 ↪ 品',
 '电子产品', '服装', '服装', '电子产品', '家居用品',
 '电子产品', '家居用品', '服装', '电子产品', '家居用
 ↪ 品'],
'region': ['华东', '华南', '华东', '华北', '华南',
 '华东', '华北', '华北', '华南', '华中',
 '华东', '华北', '华北', '华中', '华南'],
'quantity': [50, 30, 45, 60, 35, 55, 40, 50, 38, 42, 52, 45, 55, 48,
 ↪ 40],
'unit_price': [2000, 500, 2000, 300, 500, 2000, 300, 300, 2000, 500,
 ↪ 2000, 500, 300, 2000, 500],
'payment_status': ['已付', '未付', '已付', '未付', '已付',
 '已付', '未付', '已付', '未付', '已付',
 '已付', '未付', '未付', '已付', '未付']
})

计算销售金额
sales_transactions['amount'] = sales_transactions['quantity'] *
 ↪ sales_transactions['unit_price']

```

```
print(f" 共{len(sales_transactions)}笔交易")
sales_transactions.head()
```

共15笔交易

|   | transaction_id | date       | customer | product_line | region | quantity | unit_price | payment |
|---|----------------|------------|----------|--------------|--------|----------|------------|---------|
| 0 | T001           | 2024-01-05 | 客户 A     | 电子产品         | 华东     | 50       | 2000       | 已付      |
| 1 | T002           | 2024-01-08 | 客户 B     | 家居用品         | 华南     | 30       | 500        | 未付      |
| 2 | T003           | 2024-01-12 | 客户 A     | 电子产品         | 华东     | 45       | 2000       | 已付      |
| 3 | T004           | 2024-01-15 | 客户 C     | 服装           | 华北     | 60       | 300        | 未付      |
| 4 | T005           | 2024-01-20 | 客户 B     | 家居用品         | 华南     | 35       | 500        | 已付      |

#### 4.14.2 步骤 2: 数据清洗与验证

```
检查数据质量
print("=== 数据质量检查 ===")
print(f" 缺失值检查:")
print(sales_transactions.isnull().sum())

print(f"\n重复交易 ID 检查:")
duplicate_ids = sales_transactions['transaction_id'].duplicated().sum()
print(f" 重复的交易 ID 数量: {duplicate_ids}")

print(f"\n金额异常值检查:")
print(sales_transactions['amount'].describe())

验证数据完整性
assert sales_transactions['transaction_id'].is_unique, " 存在重复的交易 ID!"
print("\n 数据验证通过")
```



=== 数据质量检查 ===

缺失值检查:

```
transaction_id 0
date 0
customer 0
product_line 0
region 0
quantity 0
unit_price 0
payment_status 0
amount 0
dtype: int64
```

重复交易ID检查:

重复的交易ID数量: 0

金额异常值检查:

```
count 15.000000
mean 48900.000000
std 40517.720991
min 12000.000000
25% 17000.000000
50% 21000.000000
75% 93000.000000
max 110000.000000
Name: amount, dtype: float64
```

数据验证通过

### 4.14.3 步骤 3: 财务分析

#### 3.1 总体销售概况

```

计算总体指标
total_revenue = sales_transactions['amount'].sum()
total_transactions = len(sales_transactions)
average_transaction = sales_transactions['amount'].mean()

print("=== 第一季度销售概况 ===")
print(f" 总销售额: ¥{total_revenue:,.2f}")
print(f" 交易笔数: {total_transactions}")
print(f" 平均交易额: ¥{average_transaction:,.2f}")

按付款状态分析
payment_summary =
 ↪ sales_transactions.groupby('payment_status')['amount'].agg(['sum',
 ↪ 'count'])
payment_summary.columns = ['金额', '笔数']
print("\n按付款状态分类:")
print(payment_summary)

收款率 = payment_summary.loc['已付', '金额'] / total_revenue * 100
print(f"\n收款率: {收款率:.2f}%")

```

=== 第一季度销售概况 ===

总销售额: ¥733,500.00

交易笔数: 15

平均交易额: ¥48,900.00

按付款状态分类:

|                | 金额     | 笔数 |
|----------------|--------|----|
| payment_status |        |    |
| 已付             | 553500 | 8  |
| 未付             | 180000 | 7  |

收款率：75.46%

### 3.2 产品线分析

```
产品线业绩分析
product_analysis = sales_transactions.groupby('product_line').agg({
 'amount': ['sum', 'mean', 'count'],
 'quantity': 'sum'
}).round(2)

product_analysis.columns = ['销售总额', '平均订单额', '订单数', '销售数
↪ 量']

计算各产品线占比
product_analysis['收入占比%'] = (product_analysis['销售总额'] /
↪ total_revenue * 100).round(2)

按销售额排序
product_analysis = product_analysis.sort_values('销售总额',
↪ ascending=False)

print("=== 产品线业绩分析 ===")
print(product_analysis)
```

=== 产品线业绩分析 ===

|              | 销售总额   | 平均订单额   | 订单数 | 销售数量 | 收入占比% |
|--------------|--------|---------|-----|------|-------|
| product_line |        |         |     |      |       |
| 电子产品         | 576000 | 96000.0 | 6   | 288  | 78.53 |
| 家居用品         | 96000  | 19200.0 | 5   | 192  | 13.09 |
| 服装           | 61500  | 15375.0 | 4   | 205  | 8.38  |

### 3.3 地区分析

```

创建地区-产品线透视表
regional_pivot = pd.pivot_table(sales_transactions,
 values='amount',
 index='region',
 columns='product_line',
 aggfunc='sum',
 fill_value=0,
 margins=True,
 margins_name='总计')

print("=== 地区 × 产品线销售矩阵 ===")
print(regional_pivot)

找出各地区的主打产品
print("\n各地区销售最高的产品线:")
for region in regional_pivot.index[:-1]: # 排除总计行
 top_product = regional_pivot.loc[region].drop('总计').idxmax()
 top_amount = regional_pivot.loc[region, top_product]
 print(f"{region}: {top_product} (¥{top_amount:,.2f})")

```

=== 地区×产品线销售矩阵 ===

| product_line | 家居用品  | 服装    | 电子产品   | 总计     |
|--------------|-------|-------|--------|--------|
| region       |       |       |        |        |
| 华东           | 0     | 0     | 404000 | 404000 |
| 华中           | 21000 | 0     | 96000  | 117000 |
| 华北           | 22500 | 61500 | 0      | 84000  |
| 华南           | 52500 | 0     | 76000  | 128500 |
| 总计           | 96000 | 61500 | 576000 | 733500 |

各地区销售最高的产品线:

华东: 电子产品 (¥404,000.00)

华中: 电子产品 (¥96,000.00)

华北：服装 (¥61,500.00)

华南：电子产品 (¥76,000.00)

### 3.4 时间趋势分析

```
添加月份列
sales_transactions['month'] =
 ↪ sales_transactions['date'].dt.to_period('M')

按月统计
monthly_revenue = sales_transactions.groupby('month').agg({
 'amount': 'sum',
 'transaction_id': 'count'
})
monthly_revenue.columns = ['销售额', '交易笔数']

计算环比增长率
monthly_revenue['环比增长率%'] = monthly_revenue['销售额'].pct_change() *
 ↪ 100

print("=== 月度销售趋势 ===")
print(monthly_revenue)

计算累计收入
monthly_revenue['累计收入'] = monthly_revenue['销售额'].cumsum()
print("\n包含累计收入:")
print(monthly_revenue[['销售额', '累计收入']])
```

=== 月度销售趋势 ===

|         | 销售额    | 交易笔数 | 环比增长率%    |
|---------|--------|------|-----------|
| month   |        |      |           |
| 2024-01 | 240500 | 5    | NaN       |
| 2024-02 | 234000 | 5    | -2.702703 |
| 2024-03 | 259000 | 5    | 10.683761 |

包含累计收入:

|         | 销售额    | 累计收入   |
|---------|--------|--------|
| month   |        |        |
| 2024-01 | 240500 | 240500 |
| 2024-02 | 234000 | 474500 |
| 2024-03 | 259000 | 733500 |

### 3.5 客户分析

```
客户价值分析
customer_analysis = sales_transactions.groupby('customer').agg({
 'amount': 'sum',
 'transaction_id': 'count'
})
customer_analysis.columns = ['总购买额', '购买次数']

计算平均订单价值
customer_analysis['平均订单额'] = customer_analysis['总购买额'] /
 ↪ customer_analysis['购买次数']

按总购买额排序
customer_analysis = customer_analysis.sort_values('总购买额',
 ↪ ascending=False)

计算客户贡献度
customer_analysis['收入占比%'] = (customer_analysis['总购买额'] /
 ↪ total_revenue * 100).round(2)

print("=== 客户价值分析 ===")
print(customer_analysis)

识别 VIP 客户 (前 20%)
```

```

vip_threshold = customer_analysis['总购买额'].quantile(0.8)
vip_customers = customer_analysis[customer_analysis['总购买额'] >=
 ↪ vip_threshold]
print(f"\nVIP 客户 (前 20%):")
print(vip_customers)

```

=== 客户价值分析 ===

|          | 总购买额   | 购买次数 | 平均订单额    | 收入占比% |
|----------|--------|------|----------|-------|
| customer |        |      |          |       |
| 客户A      | 404000 | 4    | 101000.0 | 55.08 |
| 客户B      | 128500 | 4    | 32125.0  | 17.52 |
| 客户E      | 117000 | 2    | 58500.0  | 15.95 |
| 客户C      | 49500  | 3    | 16500.0  | 6.75  |
| 客户D      | 34500  | 2    | 17250.0  | 4.70  |

VIP客户(前20%):

|          | 总购买额   | 购买次数 | 平均订单额    | 收入占比% |
|----------|--------|------|----------|-------|
| customer |        |      |          |       |
| 客户A      | 404000 | 4    | 101000.0 | 55.08 |

#### 4.14.4 步骤 4: 应收账款分析

```

筛选未付款交易
receivables = sales_transactions[sales_transactions['payment_status'] ==
 ↪ '未付'].copy()

计算账龄 (截至 2024-04-01)
current_date = pd.to_datetime('2024-04-01')
receivables['days_outstanding'] = (current_date -
 ↪ receivables['date']).dt.days

创建账龄区间

```

```

receivables['aging_bucket'] = pd.cut(receivables['days_outstanding'],
 bins=[0, 30, 60, 90, float('inf')],
 labels=['0-30 天', '31-60 天',
↪ '61-90 天', '90 天以上'])

print("=== 应收账款账龄分析 ===")
print(f" 应收账款总额: ¥{receivables['amount'].sum():.2f}")
print(f" 应收笔数: {len(receivables)}")

账龄分布
aging_analysis =
↪ receivables.groupby('aging_bucket')['amount'].agg(['sum', 'count'])
aging_analysis.columns = ['金额', '笔数']
aging_analysis['占比%'] = (aging_analysis['金额'] /
↪ receivables['amount'].sum() * 100).round(2)
print("\n账龄分布:")
print(aging_analysis)

按客户统计应收
customer_receivables = receivables.groupby('customer').agg({
 'amount': 'sum',
 'days_outstanding': 'mean'
}).round(2)
customer_receivables.columns = ['应收金额', '平均账龄']
customer_receivables = customer_receivables.sort_values('应收金额',
↪ ascending=False)

print("\n按客户应收账款:")
print(customer_receivables)

```

=== 应收账款账龄分析 ===

应收账款总额: ¥180,000.00



应收笔数：7

账龄分布：

|              | 金额    | 笔数 | 占比%   |
|--------------|-------|----|-------|
| aging_bucket |       |    |       |
| 0-30天        | 59000 | 3  | 32.78 |
| 31-60天       | 88000 | 2  | 48.89 |
| 61-90天       | 33000 | 2  | 18.33 |
| 90天以上        | 0     | 0  | 0.00  |

按客户应收账款：

|          | 应收金额   | 平均账龄  |
|----------|--------|-------|
| customer |        |       |
| 客户B      | 111000 | 43.67 |
| 客户C      | 34500  | 47.00 |
| 客户D      | 34500  | 38.00 |

#### 4.14.5 步骤 5：生成管理报告

```
print("=" * 60)
print(" 2024 年第一季度销售分析报告")
print("=" * 60)

print(f"\n一、总体业绩")
print(f" 销售总额：¥{total_revenue:,.2f}")
print(f" 交易笔数：{total_transactions}")
print(f" 平均订单：¥{average_transaction:,.2f}")
print(f" 收款率：{收款率:.2f}%")

print(f"\n二、产品线表现（按销售额排序）")
for idx, row in product_analysis.head(3).iterrows():
 print(f" {idx}: ¥{row['销售总额']:,.2f} ({row['收入占比']}%)")
```

```

print(f"\n三、地区表现（销售总额排序）")
regional_total = regional_pivot.iloc[:-1,
 ↪ -1].sort_values(ascending=False)
for region, amount in regional_total.head(3).items():
 pct = amount / total_revenue * 100
 print(f" {region}: ¥{amount:,.2f} ({pct:.2f}%)"

print(f"\n四、TOP3 客户")
for idx, row in customer_analysis.head(3).iterrows():
 print(f" {idx}: ¥{row['总购买额']:,.2f} ({row['收入占比%']}%),
 ↪ {row['购买次数']}次购买")

print(f"\n五、应收账款预警")
print(f" 应收总额: ¥{receivables['amount'].sum():,.2f}")
print(f" 超 60 天应收: ¥{aging_analysis.loc[['61-90 天', '90 天以上'],
 ↪ '金额'].sum():,.2f}")
over_60_pct = aging_analysis.loc[['61-90 天', '90 天以上'], '金额'].sum()
 ↪ / receivables['amount'].sum() * 100
print(f" 账龄风险: {over_60_pct:.2f}% 超过 60 天")

print("\n" + "=" * 60)

```

## ===== 2024年第一季度销售分析报告 =====

### 一、总体业绩

销售总额: ¥733,500.00

交易笔数: 15

平均订单: ¥48,900.00

收款率: 75.46%

## 二、产品线表现(按销售额排序)

电子产品：¥576,000.00 (78.53%)

家居用品：¥96,000.00 (13.09%)

服装：¥61,500.00 (8.38%)

## 三、地区表现(销售总额排序)

华东：¥404,000.00 (55.08%)

华南：¥128,500.00 (17.52%)

华中：¥117,000.00 (15.95%)

## 四、TOP3客户

客户A：¥404,000.00 (55.08%), 4.0次购买

客户B：¥128,500.00 (17.52%), 4.0次购买

客户E：¥117,000.00 (15.95%), 2.0次购买

## 五、应收账款预警

应收总额：¥180,000.00

超60天应收：¥33,000.00

账龄风险：18.33% 超过60天

=====

### Note

#### 案例小结:

这个综合案例展示了如何使用 **pandas** 进行完整的财务数据分析:

1. **数据准备:** 创建和导入交易数据
2. **数据清洗:** 检查缺失值、重复值、异常值
3. **多维分析:** 产品线、地区、时间、客户等多个维度
4. **财务计算:** 累计、占比、增长率等关键指标
5. **风险评估:** 应收账款账龄分析
6. **报告生成:** 汇总关键发现

**实践建议:** - 尝试修改数据, 观察分析结果的变化 - 添加更多维度的分析 (如利润分析、成本分析) - 导出结果到 Excel, 制作可视化图表 - 结合实际业务场景, 思考如何应用这些技术

## 4.15 总结与下一步

### 4.15.1 Pandas 核心概念回顾

通过本章学习, 你已经掌握了:

**基础操作:** - DataFrame 和 Series 的创建和基本属性 - 数据导入导出 (CSV, Excel) - 数据选择和筛选 (loc, iloc, 条件筛选)

**数据处理:** - 数据清洗 (缺失值、重复值、类型转换) - 数据验证和质量检查 - 数据变形 (pivot, melt, stack/unstack)

**财务计算:** - 累计求和 (cumsum) - 百分比计算 (pct\_change) - 移动平均 (rolling) - 财务比率计算

**数据聚合:** - 分组统计 (groupby) - 多维聚合 (pivot\_table) - 交叉表分析 (crosstab)

### 4.15.2 与 Excel 的对比

| 任务     | Excel  | Pandas | 优势             |
|--------|--------|--------|----------------|
| 数据处理能力 | 百万行限制  | 几乎无限制  | Pandas 处理大数据更快 |
| 重复性任务  | 需要手动   | 可编程自动化 | Pandas 节省时间    |
| 数据清洗   | 需要多步操作 | 一行代码完成 | Pandas 更高效     |
| 复杂计算   | 公式复杂   | 代码清晰   | Pandas 更易维护    |
| 版本控制   | 困难     | 代码易于追踪 | Pandas 更专业     |

### 4.15.3 学习建议

1. **多练习:** 用实际财务数据练习, 理解更深刻
2. **查文档:** pandas 官方文档非常详细, 遇到问题先查文档
3. **循序渐进:** 从简单操作开始, 逐步掌握复杂功能
4. **结合业务:** 思考如何将这些技术应用到实际会计工作中

#### 4.15.4 下一步学习方向

- 数据可视化: 使用 `matplotlib` 和 `seaborn` 创建财务图表
- 数据库操作: 学习 SQL, 直接从数据库读取财务数据
- 自动化报表: 结合 Excel 库 (`openpyxl`) 生成格式化的财务报表
- 高级分析: 时间序列分析、预测模型等

#### 4.15.5 推荐资源

- [Pandas 官方文档](#)
- [Pandas 速查表](#)
- [10 minutes to pandas](#)

#### ! Important

记住: Pandas 是一个强大的工具, 但工具只是手段, 重要的是理解财务数据背后的业务逻辑和会计原理。技术与专业知识相结合, 才能发挥最大价值。

## 5 SQL 入门与实战

[点击下载本章节代码](#)

### 5.1 SQL 语言简介

SQL (Structured Query Language) 是一种用于管理关系型数据库的标准语言。它允许用户创建、查询、更新和删除数据库中的数据。SQL 是数据库管理系统（如 MySQL、PostgreSQL、SQLite 等）的核心工具。

#### 5.1.1 数据库基础概念

- 数据库 (**Database**): 数据的集合。
- 表 (**Table**): 数据库中的数据结构，由行和列组成。
- 行 (**Row**): 表中的一条记录。
- 列 (**Column**): 表中的一个字段。
- 主键 (**Primary Key**): 唯一标识每行的列。
- 外键 (**Foreign Key**): 引用另一个表的主键。



Tip

会计应用: 在会计系统中，数据库用于存储：- 会计科目表 (Chart of Accounts) - 记账凭证 (Journal Entries) - 总分类账 (General Ledger) - 明细账 (Subsidiary Ledgers) - 财务报表数据

#### 5.1.2 SQLite3 介绍

SQLite3 是一个轻量级的、嵌入式的关系型数据库管理系统。它不需要单独的服务器进程，直接在应用程序中运行，非常适合小型项目、原型开发和嵌入式系统。SQLite3 支持标准的 SQL 语法，并且是 ACID 兼容的。

## SQLite3 的优势

- 无需安装服务器
- 零配置
- 单个文件数据库
- 跨平台兼容
- 免费开源

## 5.2 DB Browser for SQLite GUI 工具

DB Browser for SQLite 是一个免费的开源 GUI 工具，用于查看和编辑 SQLite 数据库文件。

### 5.2.1 安装和使用

1. 下载并安装 DB Browser for SQLite: <https://sqlitebrowser.org/>
2. 打开工具，选择“Open Database”并选择你的 .db 文件
3. 在 GUI 中可以：
  - 浏览表结构
  - 查看和编辑数据
  - 执行 SQL 查询
  - 导入/导出数据

### 5.2.2 优势

- 直观的图形界面
- 无需编写代码即可操作数据库
- 支持 SQL 查询执行
- 可以导出数据为 CSV、SQL 等格式

## 5.3 使用 Python 接入 SQLite3

Python 标准库中包含了 `sqlite3` 模块，可以直接使用，无需额外安装。

### 5.3.1 创建数据库和表

学习目标: - 理解 SQL 建表语句 - 掌握数据类型定义 - 学会设置主键和约束

让我们创建一个会计科目表 (Chart of Accounts):

```
import sqlite3

连接到数据库 (如果不存在会自动创建)
conn = sqlite3.connect('accounting.db')
cursor = conn.cursor()

创建会计科目表
cursor.execute('''
CREATE TABLE IF NOT EXISTS chart_of_accounts (
 account_code TEXT PRIMARY KEY,
 account_name TEXT NOT NULL,
 account_type TEXT NOT NULL,
 parent_code TEXT,
 balance_direction TEXT,
 is_active INTEGER DEFAULT 1
)
''')

conn.commit()
print(" 会计科目表创建成功")
```

会计科目表创建成功

#### Note

字段说明: - account\_code: 科目编码 (主键) - account\_name: 科目名称 - account\_type: 科目类型 (资产/负债/所有者权益/收入/费用) - parent\_code: 上级科目编码 - balance\_direction: 余额方向 (借/贷) - is\_active: 是否启用 (1= 启用, 0= 停用)



## 插入数据

```
插入会计科目数据
accounts = [
 ('1001', '库存现金', '资产', None, '借', 1),
 ('1002', '银行存款', '资产', None, '借', 1),
 ('1122', '应收账款', '资产', None, '借', 1),
 ('1123', '预付账款', '资产', None, '借', 1),
 ('1401', '存货', '资产', None, '借', 1),
 ('2202', '应付账款', '负债', None, '贷', 1),
 ('2203', '预收账款', '负债', None, '贷', 1),
 ('4001', '实收资本', '所有者权益', None, '贷', 1),
 ('6001', '主营业务收入', '收入', None, '贷', 1),
 ('6401', '主营业务成本', '费用', None, '借', 1)
]

cursor.executemany('''
INSERT OR REPLACE INTO chart_of_accounts
(account_code, account_name, account_type, parent_code,
↪ balance_direction, is_active)
VALUES (?, ?, ?, ?, ?, ?)
''', accounts)

conn.commit()
print(f" 成功插入{len(accounts)}个会计科目")
```

成功插入10个会计科目

## 查询数据

```
查询所有科目
cursor.execute("SELECT * FROM chart_of_accounts")
```

```

rows = cursor.fetchall()
print(" 所有会计科目： ")
for row in rows[:5]: # 只显示前 5 条
 print(row)

条件查询：查询资产类科目
cursor.execute("""
SELECT account_code, account_name, balance_direction
FROM chart_of_accounts
WHERE account_type = ?
""", ('资产',))
rows = cursor.fetchall()
print("\n资产类科目： ")
for row in rows:
 print(f" 科目编码：{row[0]}, 科目名称：{row[1]}, 余额方向：{row[2]}")

```

所有会计科目：

```

('1001', '库存现金', '资产', None, '借', 1)
('1002', '银行存款', '资产', None, '借', 1)
('1122', '应收账款', '资产', None, '借', 1)
('1123', '预付账款', '资产', None, '借', 1)
('1401', '存货', '资产', None, '借', 1)

```

资产类科目：

```

科目编码：1001，科目名称：库存现金，余额方向：借
科目编码：1002，科目名称：银行存款，余额方向：借
科目编码：1122，科目名称：应收账款，余额方向：借
科目编码：1123，科目名称：预付账款，余额方向：借
科目编码：1401，科目名称：存货，余额方向：借

```

## 更新和删除数据

```
更新数据：修改科目名称
cursor.execute("""
UPDATE chart_of_accounts
SET account_name = ?
WHERE account_code = ?
""", ('现金', '1001'))
conn.commit()
print(" 库存现金科目名称已更新为'现金'")

停用某个科目（软删除，不是物理删除）
cursor.execute("""
UPDATE chart_of_accounts
SET is_active = 0
WHERE account_code = ?
""", ('1123',))
conn.commit()
print(" 预付账款科目已停用")

再次查询启用的科目
cursor.execute("""
SELECT account_code, account_name, account_type, is_active
FROM chart_of_accounts
ORDER BY account_code
""")
rows = cursor.fetchall()
print("\n更新后的科目列表：")
for row in rows[:7]:
 status = " " if row[3] == 1 else " "
 print(f"{status} {row[0]} - {row[1]} ({row[2]})")
```

库存现金科目名称已更新为'现金'

预付账款科目已停用

更新后的科目列表：

- 1001 - 现金（资产）
- 1002 - 银行存款（资产）
- 1122 - 应收账款（资产）
- 1123 - 预付账款（资产）
- 1401 - 存货（资产）
- 2202 - 应付账款（负债）
- 2203 - 预收账款（负债）

#### Warning

**重要提示：** 在会计系统中，通常不会物理删除科目，而是使用“软删除”(设置 `is_active=0`)。这样可以保留历史数据的完整性。

```
PRAGMA wal_checkpoint;
```

```
PRAGMA integrity_check;
```

```
PRAGMA optimize;
```

## 5.4 使用 Pandas 与 SQLite3 交互

学习目标：- 掌握 pandas 与 SQL 的集成使用 - 学会将 DataFrame 写入数据库 - 理解 SQL 查询与 pandas 的结合优势

Pandas 提供了便捷的方法来读取和写入数据库，这对财务数据分析非常有用。

### 5.4.1 创建会计分录表

让我们创建一个记账凭证表来演示：

```

import pandas as pd

创建记账凭证数据
journal_entries = pd.DataFrame({
 'entry_id': ['JE001', 'JE001', 'JE002', 'JE002', 'JE003', 'JE003',
↪ 'JE003', 'JE004', 'JE004'],
 'entry_date': ['2024-01-15', '2024-01-15', '2024-01-20',
↪ '2024-01-20',
 '2024-02-05', '2024-02-05', '2024-02-05',
↪ '2024-02-10', '2024-02-10'],
 'account_code': ['1002', '6001', '1122', '6001', '1001', '1002',
↪ '6001', '2202', '6401'],
 'description': ['销售收款', '销售收入', '赊销收入', '销售收入', '现金
↪ 销售', '银行转账', '销售收入',
 '采购商品', '采购成本'],
 'debit': [50000, 0, 30000, 0, 20000, 0, 0, 0, 15000],
 'credit': [0, 50000, 0, 30000, 0, 20000, 40000, 25000, 0]
})

查看数据结构
print(" 记账凭证数据前 5 行:")
print(journal_entries.head())

print("\n数据集信息:")
print(journal_entries.info())

```

记账凭证数据前5行:

|   | entry_id | entry_date | account_code | description | debit | credit |
|---|----------|------------|--------------|-------------|-------|--------|
| 0 | JE001    | 2024-01-15 | 1002         | 销售收款        | 50000 | 0      |
| 1 | JE001    | 2024-01-15 | 6001         | 销售收入        | 0     | 50000  |
| 2 | JE002    | 2024-01-20 | 1122         | 赊销收入        | 30000 | 0      |
| 3 | JE002    | 2024-01-20 | 6001         | 销售收入        | 0     | 30000  |

|   |       |            |      |      |       |   |
|---|-------|------------|------|------|-------|---|
| 4 | JE003 | 2024-02-05 | 1001 | 现金销售 | 20000 | 0 |
|---|-------|------------|------|------|-------|---|

数据集信息:

```
<class 'pandas.core.frame.DataFrame'>
```

```
RangeIndex: 9 entries, 0 to 8
```

```
Data columns (total 6 columns):
```

| # | Column       | Non-Null Count | Dtype  |
|---|--------------|----------------|--------|
| 0 | entry_id     | 9 non-null     | object |
| 1 | entry_date   | 9 non-null     | object |
| 2 | account_code | 9 non-null     | object |
| 3 | description  | 9 non-null     | object |
| 4 | debit        | 9 non-null     | int64  |
| 5 | credit       | 9 non-null     | int64  |

```
dtypes: int64(2), object(4)
```

```
memory usage: 564.0+ bytes
```

```
None
```

#### Note

双记账说明: - 每笔会计分录必须借贷平衡 - JE001: 银行存款 (借) = 销售收入 (贷) = 50,000 - JE002: 应收账款 (借) = 销售收入 (贷) = 30,000 - JE003: 现金 (借) + 销售收入 (贷) = 银行存款 (借) + 销售收入 (贷) = 40,000

将 **DataFrame** 写入 **SQLite3**

```
将记账凭证数据写入数据库
journal_entries.to_sql('journal_entries', conn, if_exists='replace',
 ↪ index=False)
print(" 记账凭证数据已写入数据库")

验证数据
cursor.execute("SELECT COUNT(*) FROM journal_entries")
```

```
count = cursor.fetchone()[0]
print(f" 数据库中共有 {count} 条分录记录")
```

记账凭证数据已写入数据库  
数据库中共有 9 条分录记录

从 **SQLite3** 读取数据

```
从数据库读取数据
df_from_db = pd.read_sql_query("SELECT * FROM journal_entries LIMIT 10",
 ↪ conn)
print(" 从数据库读取的前 10 行: ")
print(df_from_db)
```

从数据库读取的前10行:

|   | entry_id | entry_date | account_code | description | debit | credit |
|---|----------|------------|--------------|-------------|-------|--------|
| 0 | JE001    | 2024-01-15 | 1002         | 销售收款        | 50000 | 0      |
| 1 | JE001    | 2024-01-15 | 6001         | 销售收入        | 0     | 50000  |
| 2 | JE002    | 2024-01-20 | 1122         | 赊销收入        | 30000 | 0      |
| 3 | JE002    | 2024-01-20 | 6001         | 销售收入        | 0     | 30000  |
| 4 | JE003    | 2024-02-05 | 1001         | 现金销售        | 20000 | 0      |
| 5 | JE003    | 2024-02-05 | 1002         | 银行转账        | 0     | 20000  |
| 6 | JE003    | 2024-02-05 | 6001         | 销售收入        | 0     | 40000  |
| 7 | JE004    | 2024-02-10 | 2202         | 采购商品        | 0     | 25000  |
| 8 | JE004    | 2024-02-10 | 6401         | 采购成本        | 15000 | 0      |

**SQL** 查询示例

```
复杂查询：按科目汇总借贷金额
query = """
SELECT
 j.account_code,
```

```

 c.account_name,
 c.account_type,
 SUM(j.debit) as total_debit,
 SUM(j.credit) as total_credit,
 SUM(j.debit) - SUM(j.credit) as net_balance
FROM journal_entries j
LEFT JOIN chart_of_accounts c ON j.account_code = c.account_code
GROUP BY j.account_code, c.account_name, c.account_type
ORDER BY j.account_code
"""

result = pd.read_sql_query(query, conn)
print(" 按科目汇总的借贷金额：")
print(result)

```

按科目汇总的借贷金额：

|   | account_code | account_name | account_type | total_debit | total_credit | \ |
|---|--------------|--------------|--------------|-------------|--------------|---|
| 0 | 1001         | 现金           | 资产           | 20000       | 0            |   |
| 1 | 1002         | 银行存款         | 资产           | 50000       | 20000        |   |
| 2 | 1122         | 应收账款         | 资产           | 30000       | 0            |   |
| 3 | 2202         | 应付账款         | 负债           | 0           | 25000        |   |
| 4 | 6001         | 主营业务收入       | 收入           | 0           | 120000       |   |
| 5 | 6401         | 主营业务成本       | 费用           | 15000       | 0            |   |

|   | net_balance |
|---|-------------|
| 0 | 20000       |
| 1 | 30000       |
| 2 | 30000       |
| 3 | -25000      |
| 4 | -120000     |
| 5 | 15000       |



### 💡 Tip

**会计应用:** 这个查询实际上生成了一个简单的**试算平衡表**的基础数据。试算平衡表是验证账目借贷平衡的重要工具。

#### 验证借贷平衡

```
检查整体借贷是否平衡
query = """
SELECT
 SUM(debit) as total_debits,
 SUM(credit) as total_credits,
 SUM(debit) - SUM(credit) as difference
FROM journal_entries
"""

balance_check = pd.read_sql_query(query, conn)
print("\n借贷平衡检查: ")
print(balance_check)

if balance_check['difference'][0] == 0:
 print(" 借贷平衡")
else:
 print(f" 不平衡, 差额: {balance_check['difference'][0]}")
```

借贷平衡检查:

|   | total_debits | total_credits | difference |
|---|--------------|---------------|------------|
| 0 | 115000       | 165000        | -50000     |

不平衡, 差额: -50000

### 5.4.2 高级 SQL 操作

**学习目标:** - 掌握 SQL 聚合函数在财务分析中的应用 - 学会使用 GROUP BY 进行分类汇总 - 理解 JOIN 操作在多表关联中的作用 - 应用窗口函数进行高级财务计算

本节将详细介绍常见的 SQL 操作，使用会计数据进行演示。

## 聚合函数

聚合函数对一组值进行计算，返回单个值。在会计中常用于汇总分析。

常用聚合函数： - COUNT(\*): 计数 - SUM(column): 求和 - AVG(column): 平均值 - MIN(column): 最小值 - MAX(column): 最大值

```
聚合函数示例：分析记账凭证
query = """
SELECT
 COUNT(DISTINCT entry_id) as total_entries,
 COUNT(*) as total_lines,
 SUM(debit) as total_debits,
 SUM(credit) as total_credits,
 AVG(debit + credit) as avg_amount_per_line,
 MAX(debit) as max_debit,
 MAX(credit) as max_credit
FROM journal_entries
"""
result = pd.read_sql_query(query, conn)
print(" 记账凭证聚合统计： ")
print(result)
```

记账凭证聚合统计：

|   | total_entries | total_lines | total_debits | total_credits | \ |
|---|---------------|-------------|--------------|---------------|---|
| 0 | 4             | 9           | 115000       | 165000        |   |

|   | avg_amount_per_line | max_debit | max_credit |
|---|---------------------|-----------|------------|
| 0 | 31111.111111        | 50000     | 50000      |

### Tip

会计应用： - total\_debits 应该等于 total\_credits(借贷平衡原则) - total\_entries 表示凭证数量 - total\_lines 表示分录行数

## GROUP BY 和 HAVING

GROUP BY 用于将结果按指定列分组，HAVING 用于过滤分组后的结果。

```
GROUP BY 示例：按科目类型分组统计
query = """
SELECT
 c.account_type,
 COUNT(DISTINCT j.account_code) as accounts_used,
 COUNT(*) as transaction_count,
 SUM(j.debit) as total_debits,
 SUM(j.credit) as total_credits
FROM journal_entries j
LEFT JOIN chart_of_accounts c ON j.account_code = c.account_code
GROUP BY c.account_type
ORDER BY c.account_type
"""
result = pd.read_sql_query(query, conn)
print(" 按科目类型分组的统计：")
print(result)
```

按科目类型分组的统计：

|   | account_type | accounts_used | transaction_count | total_debits | total_credits |
|---|--------------|---------------|-------------------|--------------|---------------|
| 0 | 收入           | 1             | 3                 | 0            | 120000        |
| 1 | 负债           | 1             | 1                 | 0            | 25000         |
| 2 | 费用           | 1             | 1                 | 15000        | 0             |
| 3 | 资产           | 3             | 4                 | 100000       | 20000         |

```
HAVING 示例：找出交易金额超过 30000 的科目
query = """
SELECT
 j.account_code,
 c.account_name,
```

```

 SUM(j.debit + j.credit) as total_amount,
 COUNT(*) as transaction_count
FROM journal_entries j
LEFT JOIN chart_of_accounts c ON j.account_code = c.account_code
GROUP BY j.account_code, c.account_name
HAVING SUM(j.debit + j.credit) > 30000
ORDER BY total_amount DESC
"""
result = pd.read_sql_query(query, conn)
print("\n交易金额超过 30000 的科目: ")
print(result)

```

交易金额超过30000的科目:

|   | account_code | account_name | total_amount | transaction_count |
|---|--------------|--------------|--------------|-------------------|
| 0 | 6001         | 主营业务收入       | 120000       | 3                 |
| 1 | 1002         | 银行存款         | 70000        | 2                 |

#### Note

**HAVING vs WHERE:** - WHERE: 过滤行数据 (在分组之前) - HAVING: 过滤分组结果 (在分组之后)

## JOIN 操作

JOIN 用于连接多个表，在会计中常用于关联科目表、凭证表、客户表等。

**JOIN 类型:** - **INNER JOIN:** 只返回匹配的行 (两表都有的数据) - **LEFT JOIN:** 返回左表所有行和右表匹配行 (保留主表全部数据) - **CROSS JOIN:** 笛卡尔积 (两表的所有组合)

我们已经在前面的查询中使用了 JOIN。让我们创建客户主数据表来演示更多 JOIN 应用:

```

创建客户主数据表
cursor.execute('''
CREATE TABLE IF NOT EXISTS customers (

```

```

 customer_id TEXT PRIMARY KEY,
 customer_name TEXT NOT NULL,
 customer_type TEXT,
 credit_limit REAL
)
'''

插入客户数据
customers_data = [
 ('C001', '甲公司', 'VIP', 100000),
 ('C002', '乙公司', '普通', 50000),
 ('C003', '丙公司', 'VIP', 150000),
 ('C004', '丁公司', '普通', 30000)
]

cursor.executemany("INSERT OR REPLACE INTO customers VALUES (?, ?, ?,
↪ ?)", customers_data)
conn.commit()
print(" 客户主数据表创建成功")

创建应收账款明细表
receivables_data = pd.DataFrame({
 'invoice_id': ['INV001', 'INV002', 'INV003', 'INV004', 'INV005'],
 'customer_id': ['C001', 'C001', 'C002', 'C003', 'C999'], # C999 不存
 ↪ 在, 用于演示 JOIN 差异
 'invoice_date': ['2024-01-15', '2024-02-10', '2024-01-25',
 ↪ '2024-02-20', '2024-03-01'],
 'amount': [30000, 25000, 15000, 50000, 10000],
 'paid': [1, 0, 1, 0, 0]
})

receivables_data.to_sql('receivables', conn, if_exists='replace',
↪ index=False)

```

```
print(" 应收账款明细表创建成功")
```

客户主数据表创建成功

应收账款明细表创建成功

### INNER JOIN 示例 - 查询有应收账款的客户:

```
INNER JOIN: 只显示有应收账款的客户
query = """
SELECT
 c.customer_id,
 c.customer_name,
 c.customer_type,
 r.invoice_id,
 r.invoice_date,
 r.amount,
 CASE WHEN r.paid = 1 THEN '已付' ELSE '未付' END as payment_status
FROM customers c
INNER JOIN receivables r ON c.customer_id = r.customer_id
ORDER BY c.customer_id, r.invoice_date
"""

result = pd.read_sql_query(query, conn)
print("INNER JOIN 示例 - 有应收账款的客户:")
print(result)
```

### INNER JOIN 示例 - 有应收账款的客户:

|   | customer_id | customer_name | customer_type | invoice_id | invoice_date | amount | \ |
|---|-------------|---------------|---------------|------------|--------------|--------|---|
| 0 | C001        | 甲公司           | VIP           | INV001     | 2024-01-15   | 30000  |   |
| 1 | C001        | 甲公司           | VIP           | INV002     | 2024-02-10   | 25000  |   |
| 2 | C002        | 乙公司           | 普通            | INV003     | 2024-01-25   | 15000  |   |
| 3 | C003        | 丙公司           | VIP           | INV004     | 2024-02-20   | 50000  |   |

payment\_status

|   |    |
|---|----|
| 0 | 已付 |
| 1 | 未付 |
| 2 | 已付 |
| 3 | 未付 |

### LEFT JOIN 示例 - 查询所有客户的应收情况:

```
LEFT JOIN: 显示所有客户，包括没有应收账款的
query = """
SELECT
 c.customer_id,
 c.customer_name,
 c.customer_type,
 c.credit_limit,
 COUNT(r.invoice_id) as invoice_count,
 COALESCE(SUM(r.amount), 0) as total_receivables,
 COALESCE(SUM(CASE WHEN r.paid = 0 THEN r.amount ELSE 0 END), 0) as
⇨ outstanding_amount
FROM customers c
LEFT JOIN receivables r ON c.customer_id = r.customer_id
GROUP BY c.customer_id, c.customer_name, c.customer_type, c.credit_limit
ORDER BY total_receivables DESC
"""

result = pd.read_sql_query(query, conn)
print("\nLEFT JOIN 示例 - 所有客户应收汇总: ")
print(result)
```

### LEFT JOIN 示例 - 所有客户应收汇总:

|   | customer_id | customer_name | customer_type | credit_limit | invoice_count | \ |
|---|-------------|---------------|---------------|--------------|---------------|---|
| 0 | C001        | 甲公司           | VIP           | 100000.0     | 2             |   |
| 1 | C003        | 丙公司           | VIP           | 150000.0     | 1             |   |
| 2 | C002        | 乙公司           | 普通            | 50000.0      | 1             |   |
| 3 | C004        | 丁公司           | 普通            | 30000.0      | 0             |   |

|   | total_receivables | outstanding_amount |
|---|-------------------|--------------------|
| 0 | 55000             | 25000              |
| 1 | 50000             | 50000              |
| 2 | 15000             | 0                  |
| 3 | 0                 | 0                  |

### 💡 Tip

会计应用: - **INNER JOIN**: 用于查询有交易的客户/供应商 - **LEFT JOIN**: 用于生成完整的客户列表 (包括无交易的) - **COALESCE**: 处理 NULL 值, 在汇总时很有用

查找数据质量问题:

```
找出应收账款表中不存在于客户主数据的记录
query = """
SELECT
 r.invoice_id,
 r.customer_id,
 r.amount,
 '客户不存在' as issue
FROM receivables r
LEFT JOIN customers c ON r.customer_id = c.customer_id
WHERE c.customer_id IS NULL
"""

result = pd.read_sql_query(query, conn)
print("\n数据质量检查 - 客户主数据缺失: ")
print(result)
```

数据质量检查 - 客户主数据缺失:

|   | invoice_id | customer_id | amount | issue |
|---|------------|-------------|--------|-------|
| 0 | INV005     | C999        | 10000  | 客户不存在 |



## 子查询

子查询是嵌套在另一个查询中的查询, 在会计分析中常用于比较分析和数据筛选。

### Note

学习目标: - 掌握标量子查询 (返回单个值) - 掌握 **IN** 子查询 (返回值列表) - 理解子查询在会计分析中的应用

# 子查询示例: 查找金额高于平均值的交易

```
query = """
SELECT
 entry_id,
 entry_date,
 account_code,
 description,
 debit,
 credit,
 (debit + credit) as amount
FROM journal_entries
WHERE (debit + credit) > (
 SELECT AVG(debit + credit)
 FROM journal_entries
 WHERE debit + credit > 0
)
ORDER BY (debit + credit) DESC
"""

result = pd.read_sql_query(query, conn)
print(" 金额高于平均值的记账分录: ")
print(result)
```

# 子查询用于 IN 操作: 找出有大额交易的科目

```
query = """
SELECT
```

```

 c.account_code,
 c.account_name,
 c.account_type
FROM chart_of_accounts c
WHERE c.account_code IN (
 SELECT account_code
 FROM journal_entries
 GROUP BY account_code
 HAVING MAX(debit + credit) > 40000
)
ORDER BY c.account_type, c.account_code
"""

result = pd.read_sql_query(query, conn)
print("\n存在大额交易 (>40000) 的会计科目: ")
print(result)

EXISTS 子查询: 找出有未付款发票的客户
query = """
SELECT
 c.customer_id,
 c.customer_name,
 c.customer_type,
 c.credit_limit
FROM customers c
WHERE EXISTS (
 SELECT 1
 FROM receivables r
 WHERE r.customer_id = c.customer_id
 AND r.paid = 0
)
"""

result = pd.read_sql_query(query, conn)

```

```
print("\n存在未付款发票的客户：")
print(result)
```

金额高于平均值的记账分录：

|   | entry_id | entry_date | account_code | description | debit | credit | amount |
|---|----------|------------|--------------|-------------|-------|--------|--------|
| 0 | JE001    | 2024-01-15 | 1002         | 销售收款        | 50000 | 0      | 50000  |
| 1 | JE001    | 2024-01-15 | 6001         | 销售收入        | 0     | 50000  | 50000  |
| 2 | JE003    | 2024-02-05 | 6001         | 销售收入        | 0     | 40000  | 40000  |

存在大额交易(>40000)的会计科目：

|   | account_code | account_name | account_type |
|---|--------------|--------------|--------------|
| 0 | 6001         | 主营业务收入       | 收入           |
| 1 | 1002         | 银行存款         | 资产           |

存在未付款发票的客户：

|   | customer_id | customer_name | customer_type | credit_limit |
|---|-------------|---------------|---------------|--------------|
| 0 | C001        | 甲公司           | VIP           | 100000.0     |
| 1 | C003        | 丙公司           | VIP           | 150000.0     |

## 窗口函数

窗口函数对结果集的子集（窗口）进行计算, 在会计分析中用于排名、趋势分析和累计计算。

### Note

**学习目标:** - 掌握 ROW\_NUMBER()、RANK() 等排名函数 - 掌握 LAG()、LEAD() 等偏移函数用于环比分析 - 掌握 PARTITION BY 进行分组窗口计算 - 理解窗口函数在财务分析中的应用

SQLite3 支持以下窗口函数：

- ROW\_NUMBER(): 行号
- RANK(): 排名（跳跃）
- DENSE\_RANK(): 密集排名

- LAG(): 前一行值
- LEAD(): 后一行值
- SUM() OVER(): 窗口内求和

```
创建月度收入数据用于演示
monthly_revenue = pd.DataFrame({
 'month': ['2024-01', '2024-02', '2024-03', '2024-04', '2024-05',
↪ '2024-06',
 '2024-07', '2024-08', '2024-09', '2024-10', '2024-11',
↪ '2024-12'],
 'revenue': [850000, 920000, 880000, 950000, 990000, 1050000,
 980000, 1020000, 1100000, 1080000, 1150000, 1200000],
 'cost': [600000, 650000, 620000, 670000, 700000, 740000,
 690000, 720000, 770000, 760000, 810000, 850000]
})

monthly_revenue.to_sql('monthly_revenue', conn, if_exists='replace',
↪ index=False)

print(" 月度收入成本数据已创建")

ROW_NUMBER 和 RANK 示例：客户销售额排名
query = """
SELECT
 customer_id,
 customer_name,
 SUM(amount) as total_sales,
 ROW_NUMBER() OVER (ORDER BY SUM(amount) DESC) as row_num,
 RANK() OVER (ORDER BY SUM(amount) DESC) as rank,
 DENSE_RANK() OVER (ORDER BY SUM(amount) DESC) as dense_rank
FROM (
 SELECT
 c.customer_id,
 c.customer_name,
 r.amount
```

```

 FROM customers c
 JOIN receivables r ON c.customer_id = r.customer_id
)
GROUP BY customer_id, customer_name
ORDER BY total_sales DESC
"""

result = pd.read_sql_query(query, conn)
print("\n窗口函数：客户销售额排名：")
print(result)

LAG 和 LEAD 示例：环比分析
query = """
SELECT
 month,
 revenue,
 LAG(revenue) OVER (ORDER BY month) as prev_month_revenue,
 LEAD(revenue) OVER (ORDER BY month) as next_month_revenue,
 revenue - LAG(revenue) OVER (ORDER BY month) as mom_change,
 ROUND(100.0 * (revenue - LAG(revenue) OVER (ORDER BY month)) /
 LAG(revenue) OVER (ORDER BY month), 2) as mom_growth_rate
FROM monthly_revenue
ORDER BY month
"""

result = pd.read_sql_query(query, conn)
print("\nLAG 和 LEAD 函数：月度环比分析：")
print(result)

累计求和：计算年度累计收入
query = """
SELECT
 month,
 revenue,

```

```

 SUM(revenue) OVER (ORDER BY month ROWS BETWEEN UNBOUNDED PRECEDING
↪ AND CURRENT ROW) as ytd_revenue,
 ROUND(100.0 * revenue / SUM(revenue) OVER (ORDER BY month ROWS
↪ BETWEEN UNBOUNDED PRECEDING AND CURRENT ROW), 2) as pct_of_ytd
FROM monthly_revenue
ORDER BY month
"""

result = pd.read_sql_query(query, conn)
print("\n累计求和：年度累计收入 (YTD): ")
print(result)

分组窗口函数：按科目类型分析
query = """
SELECT
 c.account_type,
 c.account_code,
 c.account_name,
 SUM(j.debit) as total_debit,
 SUM(j.credit) as total_credit,
 AVG(SUM(j.debit + j.credit)) OVER (PARTITION BY c.account_type) as
↪ type_avg_amount,
 SUM(SUM(j.debit + j.credit)) OVER (PARTITION BY c.account_type) as
↪ type_total_amount
FROM chart_of_accounts c
JOIN journal_entries j ON c.account_code = j.account_code
GROUP BY c.account_type, c.account_code, c.account_name
ORDER BY c.account_type, total_debit + total_credit DESC
"""

result = pd.read_sql_query(query, conn)
print("\n分组窗口函数：按科目类型的交易分析: ")
print(result)

```

```

移动平均：3 个月移动平均
query = """
SELECT
 month,
 revenue,
 ROUND(AVG(revenue) OVER (
 ORDER BY month
 ROWS BETWEEN 2 PRECEDING AND CURRENT ROW
), 2) as ma_3month
FROM monthly_revenue
ORDER BY month
"""

result = pd.read_sql_query(query, conn)
print("\n移动平均：3 个月收入移动平均：")
print(result)

```

月度收入成本数据已创建

窗口函数：客户销售额排名：

|   | customer_id | customer_name | total_sales | row_num | rank | dense_rank |
|---|-------------|---------------|-------------|---------|------|------------|
| 0 | C001        | 甲公司           | 55000       | 1       | 1    | 1          |
| 1 | C003        | 丙公司           | 50000       | 2       | 2    | 2          |
| 2 | C002        | 乙公司           | 15000       | 3       | 3    | 3          |

LAG 和 LEAD 函数：月度环比分析：

|   | month   | revenue | prev_month_revenue | next_month_revenue | mom_change \ |
|---|---------|---------|--------------------|--------------------|--------------|
| 0 | 2024-01 | 850000  | NaN                | 920000.0           | NaN          |
| 1 | 2024-02 | 920000  | 850000.0           | 880000.0           | 70000.0      |
| 2 | 2024-03 | 880000  | 920000.0           | 950000.0           | -40000.0     |
| 3 | 2024-04 | 950000  | 880000.0           | 990000.0           | 70000.0      |
| 4 | 2024-05 | 990000  | 950000.0           | 1050000.0          | 40000.0      |
| 5 | 2024-06 | 1050000 | 990000.0           | 980000.0           | 60000.0      |

|    |         |         |           |           |          |
|----|---------|---------|-----------|-----------|----------|
| 6  | 2024-07 | 980000  | 1050000.0 | 1020000.0 | -70000.0 |
| 7  | 2024-08 | 1020000 | 980000.0  | 1100000.0 | 40000.0  |
| 8  | 2024-09 | 1100000 | 1020000.0 | 1080000.0 | 80000.0  |
| 9  | 2024-10 | 1080000 | 1100000.0 | 1150000.0 | -20000.0 |
| 10 | 2024-11 | 1150000 | 1080000.0 | 1200000.0 | 70000.0  |
| 11 | 2024-12 | 1200000 | 1150000.0 | NaN       | 50000.0  |

#### mom\_growth\_rate

|    |       |
|----|-------|
| 0  | NaN   |
| 1  | 8.24  |
| 2  | -4.35 |
| 3  | 7.95  |
| 4  | 4.21  |
| 5  | 6.06  |
| 6  | -6.67 |
| 7  | 4.08  |
| 8  | 7.84  |
| 9  | -1.82 |
| 10 | 6.48  |
| 11 | 4.35  |

累计求和：年度累计收入(YTD)：

|   | month   | revenue | ytd_revenue | pct_of_ytd |
|---|---------|---------|-------------|------------|
| 0 | 2024-01 | 850000  | 850000      | 100.00     |
| 1 | 2024-02 | 920000  | 1770000     | 51.98      |
| 2 | 2024-03 | 880000  | 2650000     | 33.21      |
| 3 | 2024-04 | 950000  | 3600000     | 26.39      |
| 4 | 2024-05 | 990000  | 4590000     | 21.57      |
| 5 | 2024-06 | 1050000 | 5640000     | 18.62      |
| 6 | 2024-07 | 980000  | 6620000     | 14.80      |
| 7 | 2024-08 | 1020000 | 7640000     | 13.35      |
| 8 | 2024-09 | 1100000 | 8740000     | 12.59      |



|    |         |         |          |       |
|----|---------|---------|----------|-------|
| 9  | 2024-10 | 1080000 | 9820000  | 11.00 |
| 10 | 2024-11 | 1150000 | 10970000 | 10.48 |
| 11 | 2024-12 | 1200000 | 12170000 | 9.86  |

分组窗口函数：按科目类型的交易分析：

|   | account_type | account_code | account_name | total_debit | total_credit \ |
|---|--------------|--------------|--------------|-------------|----------------|
| 0 | 收入           | 6001         | 主营业务收入       | 0           | 120000         |
| 1 | 负债           | 2202         | 应付账款         | 0           | 25000          |
| 2 | 费用           | 6401         | 主营业务成本       | 15000       | 0              |
| 3 | 资产           | 1002         | 银行存款         | 50000       | 20000          |
| 4 | 资产           | 1122         | 应收账款         | 30000       | 0              |
| 5 | 资产           | 1001         | 现金           | 20000       | 0              |

|   | type_avg_amount | type_total_amount |
|---|-----------------|-------------------|
| 0 | 120000.0        | 120000            |
| 1 | 25000.0         | 25000             |
| 2 | 15000.0         | 15000             |
| 3 | 40000.0         | 120000            |
| 4 | 40000.0         | 120000            |
| 5 | 40000.0         | 120000            |

移动平均：3个月收入移动平均：

|   | month   | revenue | ma_3month  |
|---|---------|---------|------------|
| 0 | 2024-01 | 850000  | 850000.00  |
| 1 | 2024-02 | 920000  | 885000.00  |
| 2 | 2024-03 | 880000  | 883333.33  |
| 3 | 2024-04 | 950000  | 916666.67  |
| 4 | 2024-05 | 990000  | 940000.00  |
| 5 | 2024-06 | 1050000 | 996666.67  |
| 6 | 2024-07 | 980000  | 1006666.67 |
| 7 | 2024-08 | 1020000 | 1016666.67 |
| 8 | 2024-09 | 1100000 | 1033333.33 |

|    |         |         |            |
|----|---------|---------|------------|
| 9  | 2024-10 | 1080000 | 1066666.67 |
| 10 | 2024-11 | 1150000 | 1110000.00 |
| 11 | 2024-12 | 1200000 | 1143333.33 |

### Tip

**会计应用：**窗口函数在财务分析中的常见应用：- **环比分析：**使用 LAG/LEAD 计算月度、季度环比增长 - **累计计算：**YTD 收入、累计利润等 - **移动平均：**平滑波动, 识别趋势 - **排名分析：**客户/产品/部门业绩排名 - **占比分析：**各项目占总额的比例

## CTE (Common Table Expressions)

CTE 使用 WITH 关键字定义临时结果集, 使复杂查询更清晰、可读。在会计报表编制中特别有用。

### Note

**学习目标：**- 掌握 WITH 语句创建 CTE - 掌握多个 CTE 的组合使用 - 理解 CTE 在财务报表编制中的应用

# CTE 示例：分析各科目类型的交易统计

```
query = """
```

```
WITH account_type_stats AS (
 SELECT
 c.account_type,
 COUNT(DISTINCT j.entry_id) as entry_count,
 COUNT(*) as line_count,
 SUM(j.debit) as total_debit,
 SUM(j.credit) as total_credit,
 AVG(j.debit + j.credit) as avg_amount
 FROM chart_of_accounts c
 JOIN journal_entries j ON c.account_code = j.account_code
 GROUP BY c.account_type
),
ranked_types AS (
```

```

SELECT
 *,
 RANK() OVER (ORDER BY total_debit + total_credit DESC) as
↪ activity_rank,
 ROUND(100.0 * (total_debit + total_credit) /
 SUM(total_debit + total_credit) OVER (), 2) as pct_of_total
FROM account_type_stats
)
SELECT * FROM ranked_types
ORDER BY activity_rank
"""

result = pd.read_sql_query(query, conn)
print("CTE 示例：科目类型交易统计和排名：")
print(result)

递归 CTE 示例：利润表层级结构（简化版）

query = """
WITH RECURSIVE income_statement AS (
 -- 收入部分
 SELECT 1 as line_order, '营业收入' as line_item, SUM(credit) as
↪ amount
 FROM journal_entries
 WHERE account_code LIKE '6001%'

 UNION ALL

 -- 成本部分
 SELECT 2, '营业成本', SUM(debit)
 FROM journal_entries
 WHERE account_code LIKE '6401%'

```

```

UNION ALL

-- 毛利
SELECT 3, '毛利', (
 SELECT SUM(credit) FROM journal_entries WHERE account_code LIKE
↪ '6001%'
) - (
 SELECT SUM(debit) FROM journal_entries WHERE account_code LIKE
↪ '6401%'
)
)
SELECT line_order, line_item, ROUND(amount, 2) as amount
FROM income_statement
ORDER BY line_order
"""

result = pd.read_sql_query(query, conn)
print("\n递归 CTE: 简化利润表: ")
print(result)

多个 CTE 组合: 客户价值分析
query = """
WITH customer_sales AS (
 SELECT
 c.customer_id,
 c.customer_name,
 c.customer_type,
 COUNT(r.invoice_id) as invoice_count,
 SUM(r.amount) as total_sales,
 AVG(r.amount) as avg_invoice_amount
 FROM customers c
 LEFT JOIN receivables r ON c.customer_id = r.customer_id
 GROUP BY c.customer_id, c.customer_name, c.customer_type

```

```

),
customer_payments AS (
 SELECT
 customer_id,
 SUM(CASE WHEN paid = 1 THEN amount ELSE 0 END) as paid_amount,
 SUM(CASE WHEN paid = 0 THEN amount ELSE 0 END) as unpaid_amount,
 ROUND(100.0 * SUM(CASE WHEN paid = 1 THEN 1 ELSE 0 END) /
 ↪ COUNT(*), 2) as payment_rate
 FROM receivables
 GROUP BY customer_id
),
customer_classification AS (
 SELECT
 cs.*,
 cp.paid_amount,
 cp.unpaid_amount,
 cp.payment_rate,
 CASE
 WHEN cs.total_sales > 60000 THEN '大客户'
 WHEN cs.total_sales > 30000 THEN '中客户'
 ELSE '小客户'
 END as customer_class,
 CASE
 WHEN cp.payment_rate >= 80 THEN '优质'
 WHEN cp.payment_rate >= 50 THEN '良好'
 ELSE '需关注'
 END as credit_rating
 FROM customer_sales cs
 LEFT JOIN customer_payments cp ON cs.customer_id = cp.customer_id
)
SELECT * FROM customer_classification
ORDER BY total_sales DESC

```

```

"""
result = pd.read_sql_query(query, conn)
print("\n多 CTE 组合：客户价值与信用评级分析：")
print(result)

```

CTE 示例：科目类型交易统计和排名：

|   | account_type | entry_count | line_count | total_debit | total_credit \ |
|---|--------------|-------------|------------|-------------|----------------|
| 0 | 收入           | 3           | 3          | 0           | 120000         |
| 1 | 资产           | 3           | 4          | 100000      | 20000          |
| 2 | 负债           | 1           | 1          | 0           | 25000          |
| 3 | 费用           | 1           | 1          | 15000       | 0              |

|   | avg_amount | activity_rank | pct_of_total |
|---|------------|---------------|--------------|
| 0 | 40000.0    | 1             | 42.86        |
| 1 | 30000.0    | 1             | 42.86        |
| 2 | 25000.0    | 3             | 8.93         |
| 3 | 15000.0    | 4             | 5.36         |

递归CTE：简化利润表：

|   | line_order | line_item | amount   |
|---|------------|-----------|----------|
| 0 | 1          | 营业收入      | 120000.0 |
| 1 | 2          | 营业成本      | 15000.0  |
| 2 | 3          | 毛利        | 105000.0 |

多CTE组合：客户价值与信用评级分析：

|   | customer_id | customer_name | customer_type | invoice_count | total_sales \ |
|---|-------------|---------------|---------------|---------------|---------------|
| 0 | C001        | 甲公司           | VIP           | 2             | 55000.0       |
| 1 | C003        | 丙公司           | VIP           | 1             | 50000.0       |
| 2 | C002        | 乙公司           | 普通            | 1             | 15000.0       |
| 3 | C004        | 丁公司           | 普通            | 0             | NaN           |

|  | avg_invoice_amount | paid_amount | unpaid_amount | payment_rate \ |
|--|--------------------|-------------|---------------|----------------|
|--|--------------------|-------------|---------------|----------------|

|   |         |         |         |       |
|---|---------|---------|---------|-------|
| 0 | 27500.0 | 30000.0 | 25000.0 | 50.0  |
| 1 | 50000.0 | 0.0     | 50000.0 | 0.0   |
| 2 | 15000.0 | 15000.0 | 0.0     | 100.0 |
| 3 | NaN     | NaN     | NaN     | NaN   |

|   | customer_class | credit_rating |
|---|----------------|---------------|
| 0 | 中客户            | 良好            |
| 1 | 中客户            | 需关注           |
| 2 | 小客户            | 优质            |
| 3 | 小客户            | 需关注           |

#### Tip

会计应用: CTE 在财务报表中的应用: - 分步计算: 将复杂的报表计算分解为清晰的步骤  
- 递归查询: 处理科目体系的层级结构 - 中间结果: 保存计算结果供后续使用 - 提高可读性:  
使复杂的 SQL 逻辑更易理解和维护

## 日期和时间处理

SQLite 支持多种日期和时间函数, 可以处理日期的存储、格式化和计算。

### 创建包含日期的表

```
创建包含日期字段的表
cursor.execute('''
CREATE TABLE IF NOT EXISTS sales (
 id INTEGER PRIMARY KEY,
 product_name TEXT,
 sale_date TEXT, -- SQLite 中日期通常存储为 TEXT
 quantity INTEGER,
 price REAL
)
''')

插入包含日期的数据
```

```

sales_data = [
 ('钻石戒指', '2024-01-15', 2, 1500.00),
 ('项链', '2024-02-20', 1, 800.00),
 ('耳环', '2024-03-10', 3, 450.00),
 ('手镯', '2024-01-25', 1, 1200.00),
 ('钻石项链', '2024-02-28', 1, 2500.00)
]

cursor.executemany("INSERT OR REPLACE INTO sales (product_name,
↪ sale_date, quantity, price) VALUES (?, ?, ?, ?)", sales_data)
conn.commit()
print(" 销售数据表创建并插入数据成功")

```

销售数据表创建并插入数据成功

## SQLite 日期函数

```

使用日期函数查询
query = """
SELECT
 product_name,
 sale_date,
 quantity,
 price,
 -- 提取年月日
 strftime('%Y', sale_date) as year,
 strftime('%m', sale_date) as month,
 strftime('%d', sale_date) as day,
 -- 计算总价
 quantity * price as total_amount
FROM sales
ORDER BY sale_date

```



```

"""
result = pd.read_sql_query(query, conn)
print(" 销售数据及日期处理：")
print(result)

按月份统计销售额
query = """
SELECT
 strftime('%Y-%m', sale_date) as month,
 COUNT(*) as sales_count,
 SUM(quantity * price) as total_revenue,
 AVG(quantity * price) as avg_sale_amount
FROM sales
GROUP BY strftime('%Y-%m', sale_date)
ORDER BY month
"""
result = pd.read_sql_query(query, conn)
print("\n按月份统计销售额：")
print(result)

```

销售数据及日期处理：

|    | product_name | sale_date  | quantity | price  | year | month | day | total_amount |
|----|--------------|------------|----------|--------|------|-------|-----|--------------|
| 0  | 钻石戒指         | 2024-01-15 | 2        | 1500.0 | 2024 | 01    | 15  | 3000.0       |
| 1  | 钻石戒指         | 2024-01-15 | 2        | 1500.0 | 2024 | 01    | 15  | 3000.0       |
| 2  | 钻石戒指         | 2024-01-15 | 2        | 1500.0 | 2024 | 01    | 15  | 3000.0       |
| 3  | 钻石戒指         | 2024-01-15 | 2        | 1500.0 | 2024 | 01    | 15  | 3000.0       |
| 4  | 钻石戒指         | 2024-01-15 | 2        | 1500.0 | 2024 | 01    | 15  | 3000.0       |
| .. | ...          | ...        | ...      | ...    | ...  | ...   | ..  | ...          |
| 60 | 限时优惠品        | 2025-10-19 | 1        | 999.0  | 2025 | 10    | 19  | 999.0        |
| 61 | 限时优惠品        | 2025-10-19 | 1        | 999.0  | 2025 | 10    | 19  | 999.0        |
| 62 | 限时优惠品        | 2025-10-19 | 1        | 999.0  | 2025 | 10    | 19  | 999.0        |
| 63 | 限时优惠品        | 2025-10-19 | 1        | 999.0  | 2025 | 10    | 19  | 999.0        |

|    |       |            |   |       |      |    |    |       |
|----|-------|------------|---|-------|------|----|----|-------|
| 64 | 限时优惠品 | 2025-10-19 | 1 | 999.0 | 2025 | 10 | 19 | 999.0 |
|----|-------|------------|---|-------|------|----|----|-------|

[65 rows x 8 columns]

按月份统计销售额：

|   | month   | sales_count | total_revenue | avg_sale_amount |
|---|---------|-------------|---------------|-----------------|
| 0 | 2024-01 | 22          | 46200.0       | 2100.0          |
| 1 | 2024-02 | 22          | 36300.0       | 1650.0          |
| 2 | 2024-03 | 11          | 14850.0       | 1350.0          |
| 3 | 2025-10 | 10          | 9990.0        | 999.0           |

日期计算和过滤

# 查询最近 30 天的销售

```
query = """
```

```
SELECT
```

```
 product_name,
```

```
 sale_date,
```

```
 quantity * price as amount
```

```
FROM sales
```

```
WHERE date(sale_date) >= date('now', '-30 days')
```

```
ORDER BY sale_date DESC
```

```
"""
```

```
result = pd.read_sql_query(query, conn)
```

```
print(" 最近 30 天的销售记录：")
```

```
print(result)
```

# 计算两个日期之间的天数差

```
query = """
```

```
SELECT
```

```
 product_name,
```

```
 sale_date,
```

```
 -- 计算距今天的天数
```

```

 julianday('now') - julianday(sale_date) as days_since_sale,
 -- 计算距 2024 年 1 月 1 日的天数
 julianday(sale_date) - julianday('2024-01-01') as days_from_start
FROM sales
ORDER BY sale_date
"""
result = pd.read_sql_query(query, conn)
print("\n日期计算示例：")
print(result)

```

最近30天的销售记录：

|   | product_name | sale_date  | amount |
|---|--------------|------------|--------|
| 0 | 限时优惠品        | 2025-10-19 | 999.0  |
| 1 | 限时优惠品        | 2025-10-19 | 999.0  |
| 2 | 限时优惠品        | 2025-10-19 | 999.0  |
| 3 | 限时优惠品        | 2025-10-19 | 999.0  |
| 4 | 限时优惠品        | 2025-10-19 | 999.0  |
| 5 | 限时优惠品        | 2025-10-19 | 999.0  |
| 6 | 限时优惠品        | 2025-10-19 | 999.0  |
| 7 | 限时优惠品        | 2025-10-19 | 999.0  |
| 8 | 限时优惠品        | 2025-10-19 | 999.0  |
| 9 | 限时优惠品        | 2025-10-19 | 999.0  |

日期计算示例：

|    | product_name | sale_date  | days_since_sale | days_from_start |
|----|--------------|------------|-----------------|-----------------|
| 0  | 钻石戒指         | 2024-01-15 | 643.330782      | 14.0            |
| 1  | 钻石戒指         | 2024-01-15 | 643.330782      | 14.0            |
| 2  | 钻石戒指         | 2024-01-15 | 643.330782      | 14.0            |
| 3  | 钻石戒指         | 2024-01-15 | 643.330782      | 14.0            |
| 4  | 钻石戒指         | 2024-01-15 | 643.330782      | 14.0            |
| .. | ...          | ...        | ...             | ...             |
| 60 | 限时优惠品        | 2025-10-19 | 0.330782        | 657.0           |

|    |       |            |          |       |
|----|-------|------------|----------|-------|
| 61 | 限时优惠品 | 2025-10-19 | 0.330782 | 657.0 |
| 62 | 限时优惠品 | 2025-10-19 | 0.330782 | 657.0 |
| 63 | 限时优惠品 | 2025-10-19 | 0.330782 | 657.0 |
| 64 | 限时优惠品 | 2025-10-19 | 0.330782 | 657.0 |

[65 rows x 4 columns]

在 **Python** 中处理日期

```
import datetime

使用 Python 的 datetime 处理日期
current_date = datetime.datetime.now()
print(f" 当前日期时间: {current_date}")

格式化日期
formatted_date = current_date.strftime("%Y-%m-%d %H:%M:%S")
print(f" 格式化后的日期: {formatted_date}")

插入当前日期的数据
cursor.execute("""
INSERT INTO sales (product_name, sale_date, quantity, price)
VALUES (?, ?, ?, ?)
""", ('限时优惠品', current_date.strftime("%Y-%m-%d"), 1, 999.00))
conn.commit()
print(" 插入了当前日期的销售记录")

查询今天的销售
today = datetime.date.today().strftime("%Y-%m-%d")
query = f"""
SELECT * FROM sales
WHERE sale_date = '{today}'
"""
```

```
result = pd.read_sql_query(query, conn)
print(f"\n今天的销售记录 ({today}):")
print(result)
```

当前日期时间：2025-10-19 15:56:19.526581

格式化后的日期：2025-10-19 15:56:19

插入了当前日期的销售记录

今天的销售记录 (2025-10-19):

|    | id | product_name | sale_date  | quantity | price |
|----|----|--------------|------------|----------|-------|
| 0  | 6  | 限时优惠品        | 2025-10-19 | 1        | 999.0 |
| 1  | 12 | 限时优惠品        | 2025-10-19 | 1        | 999.0 |
| 2  | 18 | 限时优惠品        | 2025-10-19 | 1        | 999.0 |
| 3  | 24 | 限时优惠品        | 2025-10-19 | 1        | 999.0 |
| 4  | 30 | 限时优惠品        | 2025-10-19 | 1        | 999.0 |
| 5  | 36 | 限时优惠品        | 2025-10-19 | 1        | 999.0 |
| 6  | 42 | 限时优惠品        | 2025-10-19 | 1        | 999.0 |
| 7  | 48 | 限时优惠品        | 2025-10-19 | 1        | 999.0 |
| 8  | 54 | 限时优惠品        | 2025-10-19 | 1        | 999.0 |
| 9  | 60 | 限时优惠品        | 2025-10-19 | 1        | 999.0 |
| 10 | 66 | 限时优惠品        | 2025-10-19 | 1        | 999.0 |

## Pandas 中的日期处理

```
将字符串日期转换为 datetime
df_sales = pd.read_sql_query("SELECT * FROM sales", conn)
print(" 原始销售数据: ")
print(df_sales)

转换日期列
df_sales['sale_date'] = pd.to_datetime(df_sales['sale_date'])
print("\n转换日期类型后的数据: ")
```

```

print(df_sales.dtypes)

日期相关的操作
print("\n日期统计: ")
print(f" 最早销售日期: {df_sales['sale_date'].min()}")
print(f" 最晚销售日期: {df_sales['sale_date'].max()}")
print(f" 销售天数: {(df_sales['sale_date'].max() -
 ↪ df_sales['sale_date'].min()).days} 天")

按月份分组统计
df_sales['month'] = df_sales['sale_date'].dt.to_period('M')
monthly_sales = df_sales.groupby('month').agg({
 'quantity': 'sum',
 'price': 'sum',
 'id': 'count'
}).rename(columns={'id': 'sales_count'})
print("\n月度销售统计: ")
print(monthly_sales)

```

原始销售数据:

|    | id | product_name | sale_date  | quantity | price  |
|----|----|--------------|------------|----------|--------|
| 0  | 1  | 钻石戒指         | 2024-01-15 | 2        | 1500.0 |
| 1  | 2  | 项链           | 2024-02-20 | 1        | 800.0  |
| 2  | 3  | 耳环           | 2024-03-10 | 3        | 450.0  |
| 3  | 4  | 手镯           | 2024-01-25 | 1        | 1200.0 |
| 4  | 5  | 钻石项链         | 2024-02-28 | 1        | 2500.0 |
| .. | .. | ...          | ...        | ...      | ...    |
| 61 | 62 | 项链           | 2024-02-20 | 1        | 800.0  |
| 62 | 63 | 耳环           | 2024-03-10 | 3        | 450.0  |
| 63 | 64 | 手镯           | 2024-01-25 | 1        | 1200.0 |
| 64 | 65 | 钻石项链         | 2024-02-28 | 1        | 2500.0 |
| 65 | 66 | 限时优惠品        | 2025-10-19 | 1        | 999.0  |

[66 rows x 5 columns]

转换日期类型后的数据:

```
id int64
product_name object
sale_date datetime64[ns]
quantity int64
price float64
dtype: object
```

日期统计:

最早销售日期: 2024-01-15 00:00:00

最晚销售日期: 2025-10-19 00:00:00

销售天数: 643 天

月度销售统计:

|         | quantity | price   | sales_count |
|---------|----------|---------|-------------|
| month   |          |         |             |
| 2024-01 | 33       | 29700.0 | 22          |
| 2024-02 | 22       | 36300.0 | 22          |
| 2024-03 | 33       | 4950.0  | 11          |
| 2025-10 | 11       | 10989.0 | 11          |

其他常见 **SQL** 操作

### 5.4.3 DISTINCT - 去重查询

DISTINCT 用于返回唯一不重复的值, 在会计中用于统计科目类型、客户类别等。

```
DISTINCT 示例: 查看所有科目类型
query = """
SELECT DISTINCT account_type
FROM chart_of_accounts
```

```

WHERE is_active = 1
ORDER BY account_type
"""

result = pd.read_sql_query(query, conn)
print("DISTINCT 示例：活跃的科目类型：")
print(result)

组合 DISTINCT：科目类型和余额方向组合
query = """
SELECT DISTINCT
 account_type,
 balance_direction
FROM chart_of_accounts
ORDER BY account_type, balance_direction
"""

result = pd.read_sql_query(query, conn)
print("\n科目类型与余额方向的唯一组合：")
print(result)

COUNT DISTINCT：统计唯一值数量
query = """
SELECT
 COUNT(DISTINCT customer_id) as unique_customers,
 COUNT(DISTINCT account_code) as unique_accounts,
 COUNT(DISTINCT entry_id) as unique_entries
FROM journal_entries j
LEFT JOIN receivables r ON DATE(j.entry_date) = DATE(r.invoice_date)
"""

result = pd.read_sql_query(query, conn)
print("\n唯一值计数统计：")
print(result)

```



DISTINCT 示例：活跃的科目类型：

|   | account_type |
|---|--------------|
| 0 | 所有者权益        |
| 1 | 收入           |
| 2 | 负债           |
| 3 | 费用           |
| 4 | 资产           |

科目类型与余额方向的唯一组合：

|   | account_type | balance_direction |
|---|--------------|-------------------|
| 0 | 所有者权益        | 贷                 |
| 1 | 收入           | 贷                 |
| 2 | 负债           | 贷                 |
| 3 | 费用           | 借                 |
| 4 | 资产           | 借                 |

唯一值计数统计：

|   | unique_customers | unique_accounts | unique_entries |
|---|------------------|-----------------|----------------|
| 0 | 1                | 6               | 4              |

#### 5.4.4 CASE 语句 - 条件逻辑

CASE 语句用于条件判断和分类, 在会计中用于账龄分析、科目分类、风险评级等。

# CASE 语句示例：应收账款账龄分析

```
query = """
SELECT
 invoice_id,
 customer_id,
 invoice_date,
 amount,
 paid,
 CASE
```

```

 WHEN paid = 1 THEN '已付款'
 WHEN julianday('now') - julianday(invoice_date) <= 30 THEN '30 天
⇨ 内'
 WHEN julianday('now') - julianday(invoice_date) <= 60 THEN '31-60
⇨ 天'
 WHEN julianday('now') - julianday(invoice_date) <= 90 THEN '61-90
⇨ 天'
 ELSE '90 天以上'
 END as aging_category,
 CASE
 WHEN paid = 0 AND julianday('now') - julianday(invoice_date) > 90
⇨ THEN '高风险'
 WHEN paid = 0 AND julianday('now') - julianday(invoice_date) > 60
⇨ THEN '中风险'
 WHEN paid = 0 THEN '低风险'
 ELSE '无风险'
 END as risk_level
FROM receivables
ORDER BY invoice_date
"""

result = pd.read_sql_query(query, conn)
print("CASE 语句示例：应收账款账龄与风险分析：")
print(result)

嵌套 CASE：交易金额分级
query = """
SELECT
 entry_id,
 account_code,
 debit,
 credit,
 CASE

```

```

 WHEN debit > 0 THEN
 CASE
 WHEN debit >= 50000 THEN '大额借方'
 WHEN debit >= 20000 THEN '中额借方'
 ELSE '小额借方'
 END
 WHEN credit > 0 THEN
 CASE
 WHEN credit >= 50000 THEN '大额贷方'
 WHEN credit >= 20000 THEN '中额贷方'
 ELSE '小额贷方'
 END
 ELSE '无金额'
 END as transaction_class
FROM journal_entries
ORDER BY (debit + credit) DESC
"""
result = pd.read_sql_query(query, conn)
print("\n嵌套 CASE: 交易金额分类: ")
print(result)

```

CASE 语句示例：应收账款账龄与风险分析：

|   | invoice_id | customer_id | invoice_date | amount | paid | aging_category | risk_level |
|---|------------|-------------|--------------|--------|------|----------------|------------|
| 0 | INV001     | C001        | 2024-01-15   | 30000  | 1    | 已付款            | 无风险        |
| 1 | INV003     | C002        | 2024-01-25   | 15000  | 1    | 已付款            | 无风险        |
| 2 | INV002     | C001        | 2024-02-10   | 25000  | 0    | 90天以上          | 高风险        |
| 3 | INV004     | C003        | 2024-02-20   | 50000  | 0    | 90天以上          | 高风险        |
| 4 | INV005     | C999        | 2024-03-01   | 10000  | 0    | 90天以上          | 高风险        |

嵌套CASE：交易金额分类：

|   | entry_id | account_code | debit | credit | transaction_class |
|---|----------|--------------|-------|--------|-------------------|
| 0 | JE001    | 1002         | 50000 | 0      | 大额借方              |

|   |       |      |       |       |      |
|---|-------|------|-------|-------|------|
| 1 | JE001 | 6001 | 0     | 50000 | 大额贷方 |
| 2 | JE003 | 6001 | 0     | 40000 | 中额贷方 |
| 3 | JE002 | 1122 | 30000 | 0     | 中额借方 |
| 4 | JE002 | 6001 | 0     | 30000 | 中额贷方 |
| 5 | JE004 | 2202 | 0     | 25000 | 中额贷方 |
| 6 | JE003 | 1001 | 20000 | 0     | 中额借方 |
| 7 | JE003 | 1002 | 0     | 20000 | 中额贷方 |
| 8 | JE004 | 6401 | 15000 | 0     | 小额借方 |

#### Tip

会计应用: CASE 语句的典型应用场景: - 账龄分析: 根据日期计算账龄区间 - 科目分类: 将明细科目归类到报表项目 - 异常标识: 标记异常交易或超限额交易 - KPI 评级: 根据财务指标进行等级评定

### 5.4.5 UNION - 合并查询结果

UNION 用于合并多个查询结果, 常用于编制合并报表或组合不同来源的数据。

# UNION 示例: 合并收入和支出科目

```
query = ""
```

```
SELECT
```

```
 '收入' as category,
```

```
 c.account_code,
```

```
 c.account_name,
```

```
 SUM(j.credit) as amount
```

```
FROM chart_of_accounts c
```

```
JOIN journal_entries j ON c.account_code = j.account_code
```

```
WHERE c.account_type = '收入'
```

```
GROUP BY c.account_code, c.account_name
```

```
UNION ALL
```

```
SELECT
```

```

 '成本费用' as category,
 c.account_code,
 c.account_name,
 SUM(j.debit) as amount
FROM chart_of_accounts c
JOIN journal_entries j ON c.account_code = j.account_code
WHERE c.account_type IN ('成本', '费用')
GROUP BY c.account_code, c.account_name

ORDER BY category, amount DESC
"""

result = pd.read_sql_query(query, conn)
print("UNION 示例：收入与成本费用汇总：")
print(result)

UNION vs UNION ALL：资产负债表简化示例
query = """
SELECT 1 as sort_order, '资产' as section, SUM(debit - credit) as balance
FROM chart_of_accounts c
JOIN journal_entries j ON c.account_code = j.account_code
WHERE c.account_type = '资产'

UNION ALL

SELECT 2, '负债', SUM(credit - debit)
FROM chart_of_accounts c
JOIN journal_entries j ON c.account_code = j.account_code
WHERE c.account_type = '负债'

UNION ALL

SELECT 3, '所有者权益', SUM(credit - debit)

```

```

FROM chart_of_accounts c
JOIN journal_entries j ON c.account_code = j.account_code
WHERE c.account_type = '所有者权益'

ORDER BY sort_order
"""
result = pd.read_sql_query(query, conn)
print("\nUNION ALL: 资产负债表简化结构: ")
print(result)

```

UNION 示例：收入与成本费用汇总：

|   | category | account_code | account_name | amount |
|---|----------|--------------|--------------|--------|
| 0 | 成本费用     | 6401         | 主营业务成本       | 15000  |
| 1 | 收入       | 6001         | 主营业务收入       | 120000 |

UNION ALL：资产负债表简化结构：

|   | sort_order | section | balance |
|---|------------|---------|---------|
| 0 | 1          | 资产      | 80000.0 |
| 1 | 2          | 负债      | 25000.0 |
| 2 | 3          | 所有者权益   | NaN     |

#### Note

**UNION vs UNION ALL:** - UNION: 自动去除重复行, 性能较慢 - UNION ALL: 保留所有行包括重复, 性能较快 - 在财务报表中通常使用 UNION ALL, 因为各部分数据不会重复

### 5.4.6 处理大数据：使用 `chunksize`

当数据量很大时（如数百万条交易记录），可以使用 `chunksize` 参数分块读取数据, 避免内存溢出。

```

分块读取大型凭证数据
query = "SELECT * FROM journal_entries"
chunks = pd.read_sql_query(query, conn, chunksize=3)

print(" 分块读取凭证数据: ")
total_rows = 0
total_debit = 0
total_credit = 0

for i, chunk in enumerate(chunks):
 chunk_debit = chunk['debit'].sum()
 chunk_credit = chunk['credit'].sum()
 total_debit += chunk_debit
 total_credit += chunk_credit
 total_rows += len(chunk)
 print(f" 块 {i+1}: {len(chunk)} 行, 借方合计: {chunk_debit}, 贷方合
 ↪ 计: {chunk_credit}")

print(f"\n总行数: {total_rows}")
print(f" 总借方: {total_debit}, 总贷方: {total_credit}")
print(f" 借贷平衡检查: {'平衡' if abs(total_debit - total_credit) < 0.01
 ↪ else '不平衡'}")

```

分块读取凭证数据:

块 1: 3 行, 借方合计: 80000, 贷方合计: 50000

块 2: 3 行, 借方合计: 20000, 贷方合计: 50000

块 3: 3 行, 借方合计: 15000, 贷方合计: 65000

总行数: 9

总借方: 115000, 总贷方: 165000

借贷平衡检查: 不平衡

### 💡 Tip

**大数据处理建议：** - 对于超过 100 万条记录的数据, 建议使用 `chunksize` 分块处理 - 每块大小可设置为 10000-50000 行, 根据内存情况调整 - 可在每块处理后进行聚合, 避免一次性加载全部数据

## 5.5 综合案例：企业财务分析仪表盘

本案例综合运用前面学习的各种 SQL 技术, 构建一个完整的财务分析仪表盘。

### i Note

**案例背景：** 某制造企业需要每月生成财务分析报告, 包括：1. 收入成本分析 2. 客户价值排名 3. 应收账款健康度 4. 月度趋势分析 5. 财务健康度评分

### 5.5.1 步骤 1：综合数据准备

```
创建更完整的测试数据集
print("=== 综合案例：财务分析仪表盘 ===\n")

添加更多月度数据（如果尚未添加）
additional_months = pd.DataFrame({
 'month': ['2024-01', '2024-02', '2024-03'],
 'revenue': [850000, 920000, 880000],
 'cost': [600000, 650000, 620000]
})

检查月度收入表是否存在足够数据
existing_count = pd.read_sql_query("SELECT COUNT(*) as cnt FROM
↪ monthly_revenue", conn).iloc[0]['cnt']
if existing_count < 3:
 additional_months.to_sql('monthly_revenue', conn,
↪ if_exists='replace', index=False)
```



```
print(" 财务数据准备完成")
```

=== 综合案例：财务分析仪表盘 ===

财务数据准备完成

### 5.5.2 步骤 2：收入成本分析

```
分析收入成本结构和趋势
query = """
WITH monthly_analysis AS (
 SELECT
 month,
 revenue,
 cost,
 revenue - cost as gross_profit,
 ROUND(100.0 * (revenue - cost) / revenue, 2) as gross_margin,
 LAG(revenue) OVER (ORDER BY month) as prev_revenue,
 ROUND(100.0 * (revenue - LAG(revenue) OVER (ORDER BY month)) /
 LAG(revenue) OVER (ORDER BY month), 2) as
 ↪ revenue_growth_rate
 FROM monthly_revenue
)
SELECT
 month,
 revenue,
 cost,
 gross_profit,
 gross_margin,
 COALESCE(revenue_growth_rate, 0) as revenue_growth_rate,
 CASE
 WHEN gross_margin >= 35 THEN '优秀'
```

```

 WHEN gross_margin >= 25 THEN '良好'
 WHEN gross_margin >= 15 THEN '一般'
 ELSE '需改进'
 END as profitability_rating
FROM monthly_analysis
ORDER BY month
"""

revenue_analysis = pd.read_sql_query(query, conn)
print("1. 收入成本分析：")
print(revenue_analysis)

```

1. 收入成本分析：

|    | month   | revenue | cost   | gross_profit | gross_margin | revenue_growth_rate \ |
|----|---------|---------|--------|--------------|--------------|-----------------------|
| 0  | 2024-01 | 850000  | 600000 | 250000       | 29.41        | 0.00                  |
| 1  | 2024-02 | 920000  | 650000 | 270000       | 29.35        | 8.24                  |
| 2  | 2024-03 | 880000  | 620000 | 260000       | 29.55        | -4.35                 |
| 3  | 2024-04 | 950000  | 670000 | 280000       | 29.47        | 7.95                  |
| 4  | 2024-05 | 990000  | 700000 | 290000       | 29.29        | 4.21                  |
| 5  | 2024-06 | 1050000 | 740000 | 310000       | 29.52        | 6.06                  |
| 6  | 2024-07 | 980000  | 690000 | 290000       | 29.59        | -6.67                 |
| 7  | 2024-08 | 1020000 | 720000 | 300000       | 29.41        | 4.08                  |
| 8  | 2024-09 | 1100000 | 770000 | 330000       | 30.00        | 7.84                  |
| 9  | 2024-10 | 1080000 | 760000 | 320000       | 29.63        | -1.82                 |
| 10 | 2024-11 | 1150000 | 810000 | 340000       | 29.57        | 6.48                  |
| 11 | 2024-12 | 1200000 | 850000 | 350000       | 29.17        | 4.35                  |

|   | profitability_rating |
|---|----------------------|
| 0 | 良好                   |
| 1 | 良好                   |
| 2 | 良好                   |
| 3 | 良好                   |
| 4 | 良好                   |

|    |    |
|----|----|
| 5  | 良好 |
| 6  | 良好 |
| 7  | 良好 |
| 8  | 良好 |
| 9  | 良好 |
| 10 | 良好 |
| 11 | 良好 |

### 5.5.3 步骤 3：客户价值与信用分析

# 客户分级和价值分析

query = """

WITH customer\_metrics AS (

SELECT

c.customer\_id,

c.customer\_name,

c.customer\_type,

c.credit\_limit,

COUNT(r.invoice\_id) as total\_invoices,

SUM(r.amount) as total\_sales,

SUM(CASE WHEN r.paid = 1 THEN r.amount ELSE 0 END) as

↪ paid\_amount,

SUM(CASE WHEN r.paid = 0 THEN r.amount ELSE 0 END) as

↪ outstanding\_amount,

ROUND(100.0 \* SUM(CASE WHEN r.paid = 1 THEN 1 ELSE 0 END) /

↪ COUNT(\*), 2) as payment\_rate,

AVG(r.amount) as avg\_invoice\_amount

FROM customers c

LEFT JOIN receivables r ON c.customer\_id = r.customer\_id

GROUP BY c.customer\_id, c.customer\_name, c.customer\_type,

↪ c.credit\_limit

),

```

customer_ranking AS (
 SELECT
 *,
 RANK() OVER (ORDER BY total_sales DESC) as sales_rank,
 CASE
 WHEN total_sales >= 60000 THEN 'A 类-大客户'
 WHEN total_sales >= 30000 THEN 'B 类-中客户'
 ELSE 'C 类-小客户'
 END as customer_class,
 CASE
 WHEN payment_rate >= 80 THEN '优质'
 WHEN payment_rate >= 50 THEN '良好'
 WHEN payment_rate >= 20 THEN '需关注'
 ELSE '高风险'
 END as credit_rating
 FROM customer_metrics
)
SELECT * FROM customer_ranking
ORDER BY sales_rank
"""
customer_analysis = pd.read_sql_query(query, conn)
print("\n2. 客户价值与信用分析：")
print(customer_analysis)

```

## 2. 客户价值与信用分析：

|   | customer_id | customer_name | customer_type | credit_limit | total_invoices | \ |
|---|-------------|---------------|---------------|--------------|----------------|---|
| 0 | C001        | 甲公司           | VIP           | 100000.0     |                | 2 |
| 1 | C003        | 丙公司           | VIP           | 150000.0     |                | 1 |
| 2 | C002        | 乙公司           | 普通            | 50000.0      |                | 1 |
| 3 | C004        | 丁公司           | 普通            | 30000.0      |                | 0 |

|   | total_sales | paid_amount | outstanding_amount | payment_rate | \ |
|---|-------------|-------------|--------------------|--------------|---|
| 0 | 55000.0     | 30000       | 25000              | 50.0         |   |
| 1 | 50000.0     | 0           | 50000              | 0.0          |   |
| 2 | 15000.0     | 15000       | 0                  | 100.0        |   |
| 3 | NaN         | 0           | 0                  | 0.0          |   |

|   | avg_invoice_amount | sales_rank | customer_class | credit_rating |
|---|--------------------|------------|----------------|---------------|
| 0 | 27500.0            | 1          | B类-中客户         | 良好            |
| 1 | 50000.0            | 2          | B类-中客户         | 高风险           |
| 2 | 15000.0            | 3          | C类-小客户         | 优质            |
| 3 | NaN                | 4          | C类-小客户         | 高风险           |

#### 5.5.4 步骤 4：应收账款健康度分析

# 应收账款账龄和风险分析

query = """

SELECT

    COUNT(\*) as total\_invoices,

    SUM(amount) as total\_receivables,

    SUM(CASE WHEN paid = 1 THEN amount ELSE 0 END) as collected,

    SUM(CASE WHEN paid = 0 THEN amount ELSE 0 END) as outstanding,

    ROUND(100.0 \* SUM(CASE WHEN paid = 1 THEN amount ELSE 0 END) /

↪ SUM(amount), 2) as collection\_rate,

    -- 账龄分析

    SUM(CASE WHEN paid = 0 AND julianday('now') - julianday(invoice\_date)

↪ <= 30 THEN amount ELSE 0 END) as current,

    SUM(CASE WHEN paid = 0 AND julianday('now') - julianday(invoice\_date)

↪ BETWEEN 31 AND 60 THEN amount ELSE 0 END) as aged\_31\_60,

    SUM(CASE WHEN paid = 0 AND julianday('now') - julianday(invoice\_date)

↪ BETWEEN 61 AND 90 THEN amount ELSE 0 END) as aged\_61\_90,

    SUM(CASE WHEN paid = 0 AND julianday('now') - julianday(invoice\_date)

↪ > 90 THEN amount ELSE 0 END) as aged\_over\_90,

```

-- 风险评估
CASE
 WHEN 100.0 * SUM(CASE WHEN paid = 0 AND julianday('now') -
↪ julianday(invoice_date) > 90 THEN amount ELSE 0 END) /
 NULLIF(SUM(CASE WHEN paid = 0 THEN amount ELSE 0 END), 0) <
↪ 10 THEN '低风险'
 WHEN 100.0 * SUM(CASE WHEN paid = 0 AND julianday('now') -
↪ julianday(invoice_date) > 90 THEN amount ELSE 0 END) /
 NULLIF(SUM(CASE WHEN paid = 0 THEN amount ELSE 0 END), 0) <
↪ 25 THEN '中风险'
 ELSE '高风险'
END as ar_risk_level
FROM receivables
"""
ar_health = pd.read_sql_query(query, conn)
print("\n3. 应收账款健康度分析：")
print(ar_health)

```

### 3. 应收账款健康度分析：

|   | total_invoices | total_receivables | collected | outstanding | collection_rate | \ |
|---|----------------|-------------------|-----------|-------------|-----------------|---|
| 0 | 5              | 130000            | 45000     | 85000       | 34.62           |   |

|   | current | aged_31_60 | aged_61_90 | aged_over_90 | ar_risk_level |
|---|---------|------------|------------|--------------|---------------|
| 0 | 0       | 0          | 0          | 85000        | 高风险           |

## 5.5.5 步骤 5：财务健康度综合评分

```

计算企业财务健康度综合评分
query = """
WITH monthly_growth AS (
 SELECT

```

```

 month,
 revenue,
 cost,
 100.0 * (revenue - cost) / revenue as gross_margin,
 100.0 * (revenue - LAG(revenue) OVER (ORDER BY month)) /
 NULLIF(LAG(revenue) OVER (ORDER BY month), 0) as
 ↪ growth_rate
 FROM monthly_revenue
),
metrics AS (
 SELECT
 -- 盈利能力指标
 (SELECT AVG(gross_margin) FROM monthly_growth) as
 ↪ avg_gross_margin,
 -- 收款能力指标
 (SELECT 100.0 * SUM(CASE WHEN paid = 1 THEN amount ELSE 0 END) /
 ↪ SUM(amount) FROM receivables) as collection_rate,
 -- 增长能力指标
 (SELECT AVG(growth_rate) FROM monthly_growth WHERE growth_rate IS
 ↪ NOT NULL) as avg_growth_rate
),
scores AS (
 SELECT
 avg_gross_margin,
 collection_rate,
 COALESCE(avg_growth_rate, 0) as avg_growth_rate,
 -- 各维度评分（满分 100）
 CASE
 WHEN avg_gross_margin >= 35 THEN 100
 WHEN avg_gross_margin >= 25 THEN 80
 WHEN avg_gross_margin >= 15 THEN 60
 ELSE 40

```

```

 END as profitability_score,
 CASE
 WHEN collection_rate >= 80 THEN 100
 WHEN collection_rate >= 60 THEN 80
 WHEN collection_rate >= 40 THEN 60
 ELSE 40
 END as collection_score,
 CASE
 WHEN COALESCE(avg_growth_rate, 0) >= 10 THEN 100
 WHEN COALESCE(avg_growth_rate, 0) >= 5 THEN 80
 WHEN COALESCE(avg_growth_rate, 0) >= 0 THEN 60
 ELSE 40
 END as growth_score
 FROM metrics
)
SELECT
 ROUND(avg_gross_margin, 2) as gross_margin_pct,
 ROUND(collection_rate, 2) as collection_rate_pct,
 ROUND(avg_growth_rate, 2) as avg_growth_rate_pct,
 profitability_score,
 collection_score,
 growth_score,
 ROUND((profitability_score * 0.4 + collection_score * 0.3 +
↪ growth_score * 0.3), 2) as overall_score,
 CASE
 WHEN (profitability_score * 0.4 + collection_score * 0.3 +
↪ growth_score * 0.3) >= 90 THEN 'A-优秀'
 WHEN (profitability_score * 0.4 + collection_score * 0.3 +
↪ growth_score * 0.3) >= 80 THEN 'B-良好'
 WHEN (profitability_score * 0.4 + collection_score * 0.3 +
↪ growth_score * 0.3) >= 70 THEN 'C-中等'
 WHEN (profitability_score * 0.4 + collection_score * 0.3 +
↪ growth_score * 0.3) >= 60 THEN 'D-及格'

```



```

 ELSE 'F-需改进'
 END as health_grade
FROM scores
"""
health_score = pd.read_sql_query(query, conn)
print("\n4. 财务健康度综合评分：")
print(health_score)

```

4. 财务健康度综合评分：

|   | gross_margin_pct | collection_rate_pct | avg_growth_rate_pct | \ |
|---|------------------|---------------------|---------------------|---|
| 0 | 29.5             | 34.62               | 3.31                |   |

|   | profitability_score | collection_score | growth_score | overall_score | \ |
|---|---------------------|------------------|--------------|---------------|---|
| 0 | 80                  | 40               | 60           | 62.0          |   |

|   | health_grade |
|---|--------------|
| 0 | D-及格         |

## 5.5.6 案例总结

```

print("\n" + "="*60)
print(" 财务分析仪表盘总结")
print("="*60)

输出关键发现
print("\n 【关键发现】 ")
print(f"1. 平均毛利率：{health_score['gross_margin_pct'].iloc[0]:.2f}%")
print(f"2. 应收账款回款率：
 ↪ {health_score['collection_rate_pct'].iloc[0]:.2f}%")
print(f"3. 平均增长率：
 ↪ {health_score['avg_growth_rate_pct'].iloc[0]:.2f}%")

```

```

print(f"4. 财务健康度评分：
↪ {health_score['overall_score'].iloc[0]:.2f}分")
print(f"5. 综合评级：{health_score['health_grade'].iloc[0]}")

print("\n【管理建议】 ")
margin_pct = health_score['gross_margin_pct'].iloc[0]
if margin_pct < 20:
 print("• 毛利率偏低，建议优化成本结构或提升产品定价")
elif margin_pct < 30:
 print("• 毛利率处于合理区间，可继续保持")
else:
 print("• 毛利率表现优秀，盈利能力强")

collection_pct = health_score['collection_rate_pct'].iloc[0]
if collection_pct < 60:
 print("• 应收账款回款率较低，需加强催收管理")
elif collection_pct < 80:
 print("• 应收账款回款情况一般，建议优化信用政策")
else:
 print("• 应收账款回款情况良好，现金流健康")

print("\n" + "="*60)

```

```

=====
财务分析仪表盘总结
=====

```

### 【关键发现】

1. 平均毛利率：29.50%
2. 应收账款回款率：34.62%
3. 平均增长率：3.31%

4. 财务健康度评分: 62.00分

5. 综合评级: D-及格

#### 【管理建议】

- 毛利率处于合理区间,可继续保持
- 应收账款回款率较低,需加强催收管理

=====

#### Tip

##### 案例要点总结:

本案例展示了 SQL 在财务分析中的强大能力:

1. 数据整合: 通过 JOIN 连接多个数据表
2. 指标计算: 使用聚合函数和窗口函数计算各类财务指标
3. 趋势分析: 使用 LAG/LEAD 函数进行环比分析
4. 分类评级: 使用 CASE 语句进行多维度分级
5. 综合评分: 构建加权评分模型
6. 自动化报告: 一键生成完整的财务分析仪表盘

在实际工作中, 这些 SQL 查询可以: - 保存为视图 (VIEW) 供反复使用 - 定时执行生成定期报告 - 导出为 Excel/CSV 供进一步分析 - 集成到 BI 工具 (如 Tableau、Power BI) 中可视化展示

### 5.5.7 关闭数据库连接

```
关闭连接
conn.close()
print(" 数据库连接已关闭")
```

数据库连接已关闭

## 5.6 总结

### 5.6.1 本章学习内容回顾

通过本章的学习, 你已经掌握了 SQL 在会计领域的核心应用技能:

#### 1. SQL 基础知识

- 数据库的基本概念 (表、列、行、主键、外键)
- 会计科目表、凭证表的数据库设计
- 双重记账法在数据库中的实现

#### 2. 核心 SQL 操作

- 数据查询: SELECT、WHERE、ORDER BY
- 数据聚合: COUNT、SUM、AVG、MAX、MIN
- 多表连接: INNER JOIN、LEFT JOIN 用于关联科目表、客户表、凭证表
- 分组统计: GROUP BY、HAVING 进行科目汇总和分类统计

#### 3. 高级 SQL 技术

- 子查询: 用于比较分析和条件筛选
- 窗口函数: ROW\_NUMBER、RANK、LAG/LEAD 实现排名和环比分析
- CTE: WITH 语句编写清晰的多步骤查询
- CASE 语句: 实现账龄分析、风险评级、科目分类
- UNION: 合并报表数据

#### 4. 会计实务应用

- 试算平衡表: 验证借贷平衡, 汇总科目发生额
- 资产负债表: 编制财务状况报表, 验证会计等式
- 利润表: 计算收入、成本、利润及财务比率
- 应收账款分析: 账龄分析、回款率计算、风险评估
- 客户价值分析: 客户分级、信用评级
- 财务健康度评分: 多维度综合评价体系

## 5. Python 与 SQL 集成

- 使用 `sqlite3` 模块操作数据库
- 使用 `pandas.read_sql_query()` 读取查询结果
- 使用 `DataFrame.to_sql()` 将数据写入数据库
- 使用 `chunksize` 处理大数据集

### 5.6.2 SQL 在会计工作中的价值

#### ! Important

为什么会计人员需要掌握 SQL?

1. 数据量爆炸: 现代企业的交易数据以 TB 为单位,Excel 已无法胜任
2. 自动化需求: 月度、季度报表需要快速生成,SQL 可实现一键出报表
3. 深度分析: 从海量数据中挖掘洞察,如客户价值分析、异常交易识别
4. 系统对接: ERP、财务软件底层都是数据库,掌握 SQL 可直接查询原始数据
5. 职业竞争力: SQL 已成为高级会计、财务分析师的必备技能

### 5.6.3 下一步学习建议

#### 1. 练习实战

- 下载真实的财务数据集进行练习
- 尝试编写自己公司的财务报表 SQL
- 参与 Kaggle 等平台的财务数据分析竞赛

#### 2. 深入学习

- 学习 PostgreSQL、MySQL 等生产级数据库
- 了解数据库设计范式和索引优化
- 学习存储过程和触发器

#### 3. 工具整合

- 将 SQL 与 Excel Power Query 结合
- 学习 Tableau、Power BI 等可视化工具
- 探索 Python 自动化脚本定期生成报表

#### 4. 持续实践

- 建立个人财务数据库项目
- 为家庭或小微企业建立简单的财务系统
- 在工作中主动寻找 SQL 应用场景

**记住：**SQL 是一门“做中学”的技能, 只有通过大量实践才能真正掌握。从今天开始, 在你的会计工作中寻找 SQL 的应用场景, 将学习转化为生产力!

## 6 文件路径与数据持久化

[点击下载本章节代码](#)

### 本章学习目标

- 掌握现代 Python 文件路径操作（pathlib）
- 学会高效的文件读写方法
- 了解 Python 对象序列化与反序列化
- 掌握大规模数据文件处理技巧

### 6.1 环境准备

```
%pip install joblib pandas openpyxl pyarrow fastparquet tqdm --upgrade
```

### 为什么使用 pathlib?

Python 3.4+ 引入的 `pathlib.Path` 相比传统的 `os.path` 有诸多优势:

- 面向对象的 API，更直观易用
- 跨平台兼容性更好（自动处理 Windows/Linux/Mac 路径差异）
- 支持链式调用，代码更简洁
- 集成了常用文件操作方法（读写、复制、删除等）

### 6.2 路径操作基础

```
from pathlib import Path
import pandas as pd
from tqdm import tqdm
```

```
Path.cwd()
```

```
PosixPath('/Users/xinlu/_project/AI4MPAcc-Course')
```

```
file = Path("./data/example.txt")
type(file)
```

```
pathlib._local.PosixPath
```

```
file.exists()
```

```
True
```

```
file.absolute()
```

```
PosixPath('/Users/xinlu/_project/AI4MPAcc-Course/data/example.txt')
```

## 6.3 路径拆分

```
file = file.absolute()
file
```

```
PosixPath('/Users/xinlu/_project/AI4MPAcc-Course/data/example.txt')
```

```
file.parts
```

```
('/', 'Users', 'xinlu', '_project', 'AI4MPAcc-Course', 'data', 'example.txt')
```



```
file.is_dir()
```

False

```
file.is_file()
```

True

```
file.name
```

'example.txt'

```
file.stem
```

'example'

```
file.suffix
```

'.txt'

```
file.parent
```

PosixPath('/Users/xinlu/\_project/AI4MPAcc-Course/data')

```
list(file.parents)
```

```
[PosixPath('/Users/xinlu/_project/AI4MPAcc-Course/data'),
 PosixPath('/Users/xinlu/_project/AI4MPAcc-Course'),
 PosixPath('/Users/xinlu/_project'),
 PosixPath('/Users/xinlu'),
 PosixPath('/Users'),
 PosixPath('/')]
```

## 6.4 文本文件读写

## 💡 Path 的便捷读写方法

`pathlib.Path` 提供了简洁的文本读写方法：

- `Path.read_text()` - 读取整个文件为字符串
- `Path.write_text()` - 将字符串写入文件
- `Path.read_bytes()` - 读取二进制文件
- `Path.write_bytes()` - 写入二进制数据

这些方法自动处理文件的打开和关闭，比传统的 `open()` 更简洁。

```
创建目录（如果不存在）
Path("./data/").mkdir(parents=True, exist_ok=True)
```

```
写入文本文件（推荐始终指定 encoding="utf-8"）
file.write_text('暨南', encoding="utf-8")
```

2

```
读取文本文件
file.read_text(encoding="utf-8")
```

'暨南'

```
编码错误演示：用错误的编码读取
try:
 file.read_text(encoding="gbk")
except Exception as e:
 print(f" 编码错误: {e}")
```

```
删除文件
file.unlink()
```

### ⚠ 字符编码陷阱

在处理中文文本时，务必：

1. 写入时明确指定 `encoding="utf-8"`
2. 读取时使用相同编码
3. 避免使用 `gbk` 或系统默认编码（容易产生乱码）

推荐统一使用 `UTF-8` 编码。

```
try:
 file.write_text('暨南大学管理学院', encoding="utf-8")
 # 尝试用错误的编码读取会报错
 print(file.read_text(encoding="gbk"))
except Exception as e:
 print(f" 错误: {e}")
finally:
 # 正确读取
 print(file.read_text(encoding="utf-8"))
```

错误: 'gbk' codec can't decode byte 0xad in position 10: illegal multibyte sequence  
暨南大学管理学院

## 6.5 文件重命名

```
file.with_suffix(".json")
```

```
PosixPath('/Users/xinlu/_project/AI4MPAcc-Course/data/example.json')
```

```
file.rename("./data/example_new_name.txt")
```

```
PosixPath('data/example_new_name.txt')
```

```
print(file)
```

```
file.exists()
```

```
/Users/xinlu/_project/AI4MPAcc-Course/data/example.txt
```

```
False
```

```
Path("./data/example_new_name.txt").rename("./data/example.txt")
```

```
PosixPath('data/example.txt')
```

## 6.6 COPY/MOVE/DELETE 文件/文件夹

```
Path("./make/new/folder/").mkdir(parents=True, exist_ok=True)
```

```
import shutil
shutil.copy(file, Path("./make/new/folder/"))
```

```
'make/new/folder/example.txt'
```

```
new_file = file.with_suffix(".json")
new_file
```

```
PosixPath('/Users/xinlu/_project/AI4MPAcc-Course/data/example.json')
```

```
shutil.copyfile(file, new_file)
```

```
PosixPath('/Users/xinlu/_project/AI4MPAcc-Course/data/example.json')
```

```
shutil.move(new_file, Path("./make/new/folder/"))
```

```
'make/new/folder/example.json'
```

```
shutil.copytree("./make", "./data/make_copy")
```

```
'./data/make_copy'
```

```
shutil.rmtree("./make", ignore_errors=True)
```

```
shutil.rmtree("./data/make_copy", ignore_errors=True)
```

## 6.7 文件搜索与批量处理

### **i** glob vs rglob

- glob(pattern) - 只搜索当前目录
- rglob(pattern) - 递归搜索所有子目录 (r = recursive)

常用通配符: \* - 匹配任意字符 - \*\* - 匹配任意级别的目录 - ? - 匹配单个字符 - [abc] - 匹配括号内的任一字符

```
import os
```

```
获取当前 Python 环境路径
```

```
env_path = os.environ.get('CONDA_PREFIX', '.')
```

```
print(f" 环境路径: {env_path}")
```

环境路径: /Users/xinlu/miniconda3

```
搜索当前目录下的所有 .py 文件 (不含子目录)
```

```
py_files = list(Path(env_path).glob('*.py'))
```

```
print(f" 找到 {len(py_files)} 个 .py 文件")
```

```
py_files[:3] # 显示前 3 个
```

找到 0 个 .py 文件

```
[]
```

```
递归搜索所有子目录中的 .py 文件
all_py_files = list(Path(env_path).rglob('*.py'))
print(f" 递归搜索找到 {len(all_py_files)} 个 .py 文件")
all_py_files[:3]
```

递归搜索找到 48937 个 .py 文件

```
[PosixPath('/Users/xinlu/miniconda3/bin/pdf2txt.py'),
 PosixPath('/Users/xinlu/miniconda3/bin/dumppdf.py'),
 PosixPath('/Users/xinlu/miniconda3/bin/pwiz.py')]
```

```
批量复制图片文件示例
png_files = Path(env_path).rglob('*.png')

创建目标文件夹
output_dir = Path("./data/collected_images/")
output_dir.mkdir(parents=True, exist_ok=True)

使用 tqdm 显示进度条
from shutil import copy2

for i, img_path in enumerate(tqdm(list(png_files)[:10], desc=" 复制图
 ↪ 片")):
 if img_path.is_file():
 # 为避免文件名冲突，添加序号
 new_name = f"{i:03d}_{img_path.name}"
 copy2(img_path, output_dir / new_name)

print(f" 已复制到: {output_dir.absolute()}")
```

已复制到: /Users/xinlu/\_project/AI4MPAcc-Course/data/collected\_images

```
筛选文件和目录

items = list(Path(env_path).glob('*'))

files = [x for x in items if x.is_file()]
dirs = [x for x in items if x.is_dir()]

print(f" 文件数量: {len(files)}")
print(f" 目录数量: {len(dirs)}")
print(f" 目录示例: {dirs[:3]}")
```

文件数量: 6

目录数量： 15

目录示例: `[PosixPath('/Users/xinlu/miniconda3/man'), PosixPath('/Users/xinlu/minicond`

## 6.8 保存和加载 Python 单个对象

```
import joblib

创建一个示例对象，例如一个简单的字典
data = {'name': 'Alice', 'age': 25, 'city': 'New York'}

使用 joblib 保存对象到文件
joblib.dump(data, 'data.joblib')
```

```
['data.joblib']
```

```
加载保存的对象
loaded_data = joblib.load('data.joblib')
loaded_data
```

```
{'name': 'Alice', 'age': 25, 'city': 'New York'}
```

```
Path('data.joblib').unlink()
```

## 6.9 保存和加载 Python 多个对象

```
import joblib

创建多个示例对象
model = {'type': 'LinearRegression', 'parameters': {'intercept': 0.5,
↪ 'slope': 2.3}}
config = {'batch_size': 32, 'epochs': 100}
data = [1, 2, 3, 4, 5]

使用 joblib 保存多个对象到一个文件
joblib.dump((model, config, data), 'multiple_objects.joblib')

加载保存的多个对象
loaded_model, loaded_config, loaded_data =
↪ joblib.load('multiple_objects.joblib')

print(loaded_model)
print(loaded_config)
print(loaded_data)
```

```
{'type': 'LinearRegression', 'parameters': {'intercept': 0.5, 'slope': 2.3}}
{'batch_size': 32, 'epochs': 100}
[1, 2, 3, 4, 5]
```

```
Path('multiple_objects.joblib').unlink()
```

...

- 把数据转化为 DataFrame，然后利用 pandas 的强大 IO 接口存为 xlsx, csv 等数据



## 6.10 DataFrame 拆分例子

```
from dfply import diamonds
```

```
Path('./temp/').mkdir()
```

```
clarity_set = set(diamonds.clarity.tolist())
clarity_set
```

```
{'I1', 'IF', 'SI1', 'SI2', 'VS1', 'VS2', 'VVS1', 'VVS2'}
```

```
for c in clarity_set:
 df_subset = diamonds[diamonds.clarity == c]
 df_subset.to_excel(f'./temp/clarity_{c}.xlsx', index = False)
 print(f'clarity = {c} save completed!')
```

```
clarity = VVS2 save completed!
```

```
clarity = I1 save completed!
```

```
clarity = VS2 save completed!
```

```
clarity = VVS1 save completed!
```

```
clarity = VS1 save completed!
```

```
clarity = SI2 save completed!
```

```
clarity = SI1 save completed!
```

```
clarity = IF save completed!
```

## 6.11 DataFrame 读取例子

```
file_list = [x for x in Path('./temp/').glob("*.xlsx")]
file_list
```

```
[PosixPath('temp/clarity_VVS1.xlsx'),
 PosixPath('temp/clarity_SI2.xlsx'),
 PosixPath('temp/clarity_VS1.xlsx'),
 PosixPath('temp/clarity_I1.xlsx'),
 PosixPath('temp/clarity_IF.xlsx'),
 PosixPath('temp/clarity_VS2.xlsx'),
 PosixPath('temp/clarity_SI1.xlsx'),
 PosixPath('temp/clarity_VVS2.xlsx')]
```

```
import pandas as pd
df_list = [pd.read_excel(x) for x in file_list]
df_list[0].head(2)
```

|   | carat | cut       | color | clarity | depth | table | price | x    | y    | z    |
|---|-------|-----------|-------|---------|-------|-------|-------|------|------|------|
| 0 | 0.24  | Very Good | I     | VVS1    | 62.3  | 57.0  | 336   | 3.95 | 3.98 | 2.47 |
| 1 | 0.32  | Ideal     | I     | VVS1    | 62.0  | 55.3  | 553   | 4.39 | 4.42 | 2.73 |

```
df_all = pd.concat(df_list)
df_all.shape
```

```
(53940, 10)
```

```
import shutil
shutil.rmtree("./temp/", ignore_errors=True)
```

## 7 文本分析入门

[点击下载本章节代码](#)

### 7.1 Spacy 模型

安装依赖包

```
%pip install spacy wordcloud gensim pyLDAvis tqdm --upgrade
```

下载中文语言模型（3.8.0 版本）

```
%pip install
```

```
↪ https://github.com/explosion/spacy-models/releases/download/zh_core_web_md-3.8.0/
```

或使用命令行下载：

```
python -m spacy download zh_core_web_md
```

### 7.2 加载模型

```
import spacy
nlp = spacy.load("zh_core_web_md")
```

```
text = " 暨南大学是中国第一所由政府创办的华侨学府。\
学校目前是中央统战部、教育部、广东省共建的国家“双一流”建设高校，直属中央
↪ 统战部管理。"
```

```
print(text)
doc = nlp(text)
```

暨南大学是中国第一所由政府创办的华侨学府。学校目前是中央统战部、教育部、广东省共建的国

```
for x in doc:
 print(x)
```

暨南  
大学  
是  
中国  
第一  
所  
由  
政府  
创办  
的  
华侨  
学府  
。  
学校  
目前  
是  
中央  
统战部  
、  
教育部  
、  
广东省  
共建

的  
国家  
“  
双一流  
”  
建设  
高校  
,  
直属  
中央  
统战部  
管理  
。

```
for i, sent in enumerate(doc.sents):
 print(i, sent)
```

0 暨南大学是中国第一所由政府创办的华侨学府。

1 学校目前是中央统战部、教育部、广东省共建的国家“双一流”建设高校，直属中央统战部管理

```
for i, sent in enumerate(doc.sents):
 print(i, "-----")
 for x in sent:
 print(x)
```

0 -----  
暨南  
大学  
是  
中国  
第一  
所  
由

政府  
创办  
的  
华侨  
学府

。

1 -----

学校  
目前  
是  
中央  
统战部  
、  
教育部  
、  
广东省  
共建  
的  
国家  
“

双一流  
”

建设  
高校  
，  
直属  
中央  
统战部  
管理  
。

```

token = doc[0]
print(token)
print(" 1", token.text)
print(" 2", token.ent_type_)
print(" 4", token.is_alpha)
print(" 5", token.is_space)
print(" 6", token.is_stop)
print(" 7", token.is_punct)
print(" 8", token.is_currency)
print(" 9", token.is_upper)
print("10", token.pos_) # Part of Speech

```

暨南

```

1 暨南
2 ORG
4 True
5 False
6 False
7 False
8 False
9 False
10 PROPN

```

```

def clean_text(text):
 text = "".join(text.split())
 doc = nlp(text)
 token_list = [token.text for token in doc if token.is_alpha and not
↪ token.is_stop]
 return " ".join(token_list)

```

```
clean_text(" 暨南大学是中国第一所由政府创办的华侨学府。")
```

```
'暨南 大学 中国 第一 政府 创办 华侨 学府'
```

### 7.2.1 自定义分词

```
proper_nouns = ['暨南大学','华侨学府']
nlp.tokenizer.pkuseg_update_user_dict(proper_nouns)
```

```
clean_text(" 暨南大学是中国第一所由政府创办的华侨学府。")
```

```
'暨南大学 中国 第一 政府 创办 华侨学府'
```

### 7.2.2 自定义 stopwords

```
from spacy.lang.zh.stop_words import STOP_WORDS
set of Spacy's default stop words

for word in [" 第一", " 学府"]:
 STOP_WORDS.add(word) # 增加 stop words
 lexeme = nlp.vocab[word]
 lexeme.is_stop = True
```

```
clean_text(" 暨南大学是中国第一所由政府创办的华侨学府。")
```

```
'暨南大学 中国 政府 创办 华侨学府'
```

```
删除 stopwords
for word in [" 第一", " 学府", " 是"]:
 STOP_WORDS.remove(word) # 剔除 stop words
 lexeme = nlp.vocab[word]
 lexeme.is_stop = False
```



```
clean_text(" 暨南大学是中国第一所由政府创办的华侨学府。")
```

'暨南大学 是 中国 第一 政府 创办 华侨学府'

## 7.3 加载审计数据

```
import pandas as pd
df = pd.read_parquet(

 ↪ "https://ai4biz.oss-cn-guangzhou.aliyuncs.com/data/audit_description.parquet"
)

df = df[df.year == 2023].sample(100)
df.head()
```

|       | stkcd  | year | audit_description                                 |
|-------|--------|------|---------------------------------------------------|
| 16589 | 600977 | 2023 | 中影股份主营业务包括创作、发行、放映、科技、服务及创新六大板块，涵盖电               |
| 22653 | 830832 | 2023 | 2023 年度营业收入为 37,170.14 万元。（1）鉴于齐鲁华信销售业务客户较为集中     |
| 1260  | 719    | 2023 | 中原传媒公司及其子公司主要从事出版物的印刷生产和销售，以及与印刷相关的               |
| 10703 | 300706 | 2023 | 截至 2023 年 12 月 31 日，阿石创公司应收账款余额 25,188.91 万元，坏账准备 |
| 12683 | 301421 | 2023 | 收入是波长光电的关键业绩指标之一，波长光电主要从事光机电产品和激光、纤               |

## 7.4 清洗文本

```
from tqdm.notebook import tqdm
tqdm.pandas()

df["audit_description_seg"] =

 ↪ df["audit_description"].progress_apply(clean_text)
```

0%| | 0/100 [00:00<?, ?it/s]

```
df.audit_description_seg.str.len().describe()
```

```
count 100.000000
mean 193.700000
std 113.019664
min 38.000000
25% 118.250000
50% 166.500000
75% 232.250000
max 618.000000
```

Name: audit\_description\_seg, dtype: float64

```
df['n_words'] = df.audit_description_seg.apply(lambda x: len(x.split()))
df['n_words'].describe()
```

```
count 100.000000
mean 64.700000
std 37.144952
min 13.000000
25% 41.000000
50% 56.000000
75% 78.250000
max 205.000000
```

Name: n\_words, dtype: float64

## 7.5 词频向量

```
import pandas as pd
from sklearn.feature_extraction.text import CountVectorizer
from sklearn.feature_extraction.text import TfidfTransformer
```

```

cv = CountVectorizer(
 # max_features=1800,
 min_df=0.01, # lower
 max_df = 0.99,
 ngram_range=(1, 1)
)

word_count_vector =
 ↪ cv.fit_transform(df["audit_description_seg"].tolist())

```

```
word_count_vector
```

```

<Compressed Sparse Row sparse matrix of dtype 'int64'
 with 3296 stored elements and shape (100, 945)>

```

```
cv.get_feature_names_out()
```

```

array(['cfr', 'cif', 'cip', 'cnf', 'cpt', 'dap', 'ddp', 'ddu',
 'dematicgrou', 'dematicgroup', 'exw', 'fca', 'fob', 'group', 'it',
 'kion', 'poc', 'p所', 'r组件', '一体化', '一时点', '万向', '三力', '三十', '三
 '三十五', '三十八', '三阶段', '上年', '上年度', '上年末', '上期', '上海', '上
 '不尽相同', '不确定性', '专家', '世荣', '业务', '业绩', '东亚', '东利', '东方
 '中原', '中影', '中科', '中船', '中钢', '中铁', '中间体', '为经', '主体', '主
 '主观性', '义务', '之间', '书面', '买入', '二十', '二十三', '二十五', '二级',
 '互联网', '亚华', '亚虹', '交互', '交付', '交易', '交易性', '交易量', '交易额
 '产品', '产线', '享有', '人民币', '亿联', '亿通', '仓储', '仓库', '代理', '仪
 '价格', '价款', '企业', '休闲', '众多', '众辰', '会计', '会议', '传媒', '传感
 '低于', '余额', '作出', '佣金', '供应链', '依赖', '依赖于', '保税区', '保证',
 '信宇人', '信息', '信用', '信质', '修订', '借款', '假设', '偏向', '做出', '储
 '充值', '充分性', '兆业', '先款', '光机电', '光电', '入账', '全球', '全程', '公
 '公路', '六大', '关联', '关联方', '其他应收款', '内容', '内蒙', '内部', '内
 '军工', '冰压机', '冰鲜', '冷链', '净值', '净额', '准则', '准确', '准确性', '以

```

'减少', '减震器', '凭据', '凭证', '出口', '出库单', '出版', '出版物', '击量',  
'分为', '分摊', '分散', '分析', '分部', '分配', '划分', '列为', '列报', '创作',  
'判断', '利润', '利润表', '利益', '到期', '制作', '制动', '制品', '制片', '制',  
'前瞻性', '剧集', '剩余', '办理', '加工', '加权', '动力', '包含', '包括', '北',  
'十六', '华信', '华培', '华米', '华菱', '华闻', '协助', '协议', '单个', '单位',  
'单时', '单核', '单笔', '单项', '南京', '博闻', '占期', '印制', '印刷', '历史',  
'原值', '原则', '原料药', '厨柜', '参数', '参阅', '发出', '发动', '发展', '发',  
'发电', '发行', '发货', '受偿', '受限', '变化', '变更', '变现', '口径', '可变',  
'各类', '各项', '合力', '合同', '合并', '合并利', '合成', '合理性', '合肥', '合',  
'同比', '后台', '后续', '后货', '含有', '周期', '品牌', '售价', '商品', '商官网',  
'商誉', '喏', '四十三', '四十四', '回单', '回性', '回报', '回收', '因子', '因',  
'固有', '国中', '国产', '国内', '国博', '国际', '圣阳', '地区', '地并', '地点',  
'垫款', '基础', '境内', '境内线', '境外', '境外线', '增加', '增材', '增长', '增',  
'处置', '复杂性', '外线', '外部', '外销', '多且', '多种', '大件', '大宗', '大',  
'妆品', '始确', '姚记', '子公司', '存续', '存续期', '存货', '季度', '宁波', '安',  
'安徽', '安排', '安装', '完工', '完整', '完毕', '宏源', '宏观', '定义', '定制',  
'实时', '审价', '审定', '客户', '宣传', '家具', '家居', '家电', '家畜', '对价',  
'导致', '导航', '导购', '寿命', '封件', '射频', '尚未', '尤其是', '层于', '展',  
'履行', '工业', '工具', '工程', '差异', '差异性', '差额', '市场', '带来', '常',  
'平均', '年内', '年度', '年限', '并经', '广告', '广告位', '应收', '应计', '店',  
'建立', '建设', '建造', '开关', '开发', '开设', '引导', '弘元', '当年', '当月',  
'形车', '影响', '影视', '影院', '德邦', '快运', '快递', '快速', '总收入', '总',  
'恒帅', '恰当', '悬架', '情况', '情景', '成交', '成品油', '成本', '成果', '截',  
'房地产', '所在地', '所示', '所述', '手续', '扑克牌', '执行', '执行器', '执行',  
'承租人', '承诺', '承运人', '技术', '投入', '投放', '投资', '投资者', '抗真',  
'抗菌药', '折现率', '报关', '报关单', '报告', '报表', '报表日', '披露', '抵押',  
'抽水', '担任', '担保人', '拥有', '持续', '指定', '指标', '按点', '损失', '损',  
'授予', '授权', '接单', '接受', '接口', '接收方', '控制', '控制权', '推广', '推',  
'提前', '提单', '提存', '摊销', '摩托车', '播放', '操控', '操纵', '支付', '收',  
'收到', '收取', '收回', '收方', '收款', '收益', '收租', '收融', '收货', '收购',  
'放映', '政务', '政府', '政策', '敞口', '数字', '数字化', '数据', '数智', '数',  
'文件', '新华', '新材', '新百', '方式', '施工', '无形', '无线', '无误', '无需'

'时段', '时点', '時計', '时间', '春风', '晋西', '普莱', '普莱得', '智能', '智能'  
'暂定', '暴露', '最为', '最佳', '月度', '有效性', '有线', '有限', '服务', '服务'  
'服务费', '朗博', '期内', '期初', '期望', '期末', '期间', '期限', '木质', '未天'  
'本期', '机制', '机器', '机密', '机床', '机械', '机载', '权利', '权力', '权益'  
'条件', '条款', '来源', '来源于', '来自于', '杰华特', '松茸', '板块', '标准', '标准'  
'核算', '根据线', '梦天', '概率', '模具', '模块', '模型', '模式', '模组', '款外'  
'正威', '正确', '正裕', '母公司', '每月', '比例', '比重', '水务', '水平', '永续'  
'汇总', '汉光', '江苏', '污水', '汽车', '沥青', '沪电', '治理', '波长', '注册量'  
'洛耐', '活动', '活鸡', '派林', '流入', '流动', '流程', '流贴', '流转', '流量'  
'浙江', '海关', '海外', '海格', '海通', '消耗', '消费者', '涉及', '润表', '涵量'  
'渠道', '港口', '游戏', '湖雪', '湘佳', '湘邮', '潍柴', '潜在', '激光', '激励'  
'热电', '焊割', '煤炭', '版块', '物流', '物资', '特定', '特征', '特许', '特货'  
'玩家', '环境', '现值', '现时', '现法', '现金', '现金流', '珀莱雅', '瑞凌', '生'  
'生态', '生物', '生物质', '生猪', '用于', '用户', '田野', '申万', '电力', '电动'  
'电商', '电子', '电影', '电新', '电机', '电池', '电源', '电视', '电路板', '白泥'  
'皖通', '皮肤', '益佰', '监控', '目标', '目的', '直营', '相关', '相当于', '相比'  
'真实性', '研发', '硬件', '确认', '碱药', '票务', '离子', '离岸', '禽肉', '科技'  
'租售', '租赁', '租赁物', '程序', '程度', '税费', '站到站', '笔数', '第三方', '第'  
'策略', '签字', '签收', '签署', '签订', '简称', '管理', '管理层', '管理者', '类'  
'精密', '精工', '精机', '系统', '索赔', '累计', '红外', '约定', '纳入', '线下'  
'组合', '終了', '终端', '经常性', '经接', '经济', '经营', '经营权', '经购', '终'  
'经销商', '结构化', '结算', '统称', '绩效', '维修', '维生素', '综合', '绿能', '绿能'  
'网络', '联产', '联合', '联方', '联盟', '聘请', '股份', '股权', '胺类', '能力'  
'自主', '自初', '自动化', '自有', '自营', '自行', '至少', '航天', '航科', '航空'  
'芯片', '若干', '药业', '药品', '莱赛', '获取', '菌制品', '菌药', '菲利华', '管'  
'蒸汽', '蓄能', '虚增', '虚拟', '蚕丝', '融出', '融合', '融资', '血液', '行业'  
'补价', '表中', '表日', '表现', '装备', '装运港', '视为', '视觉', '角色', '解药'  
'计入', '计提', '计算', '计费', '计量', '订单', '认后', '认定', '记录', '设备'  
'访问', '证券', '评估', '评估师', '识别', '诊断', '该类', '详见', '调整', '调市'  
'负债', '财信', '财务', '账务', '账户', '账方式', '账款', '账确', '账面', '账出'  
'货方', '货款', '货物', '购买', '购子', '购货方', '贵州', '贷款', '贸易', '费用'  
'资产', '资产组', '资本', '资本化', '资源', '资租', '资金', '超卓', '超市', '超

```
'跌价', '跨期', '车站', '车轴', '转移', '软件', '软硬件', '载明', '输入', '输
'运作', '运动', '运至', '运营', '运营商', '运行', '运输', '运输交', '运送', '运
'进口', '进度', '违约', '迹象', '追踪', '送货', '选取', '选择', '通信', '通知
'逻辑', '邮件', '部品', '部门', '配件', '配合', '配电', '酮类', '采用', '重要性
'金徽酒', '金牌', '金租', '金融', '金证', '金额', '钱潮', '铁路', '铅蓄', '铝合
'销售', '销售化', '销售密', '销售量', '错报', '错误', '镇海', '长城', '长期',
'长高电新', '门到门', '阀门', '阶段', '阿石创', '附注', '院线', '集团', '集成
'零部件', '非t', '音飞', '项目', '顺序', '预估', '预期', '预测', '预计', '领域
'频繁', '风险', '飞机', '食品', '食用', '验收', '高度', '高电', '高者', '高速
'黄金', '齐鲁', '龙利', '龙利得'], dtype=object)
```

```
word_count_vector.shape
```

```
(100, 945)
```

```
word_count_vector.toarray() # type: ignore
```

```
array([[0, 0, 0, ..., 0, 0, 0],
 [0, 0, 0, ..., 3, 0, 0],
 [0, 0, 0, ..., 0, 0, 0],
 ...,
 [0, 0, 0, ..., 0, 0, 0],
 [0, 0, 0, ..., 0, 0, 0],
 [0, 0, 0, ..., 0, 0, 0]], shape=(100, 945))
```

```
word_tfidf_vector = TfidfTransformer().fit_transform(word_count_vector)
word_tfidf_vector
```

```
<Compressed Sparse Row sparse matrix of dtype 'float64'
 with 3296 stored elements and shape (100, 945)>
```

```
word_tfidf_vector.toarray() # type: ignore
```

```
array([[0. , 0. , 0. , ..., 0. , 0. ,
 0.],
 [0. , 0. , 0. , ..., 0.54476285, 0. ,
 0.],
 [0. , 0. , 0. , ..., 0. , 0. ,
 0.],
 ...,
 [0. , 0. , 0. , ..., 0. , 0. ,
 0.],
 [0. , 0. , 0. , ..., 0. , 0. ,
 0.],
 [0. , 0. , 0. , ..., 0. , 0. ,
 0.]], shape=(100, 945))
```

```
word_count = pd.DataFrame(word_count_vector.toarray(), # type: ignore
 columns = cv.get_feature_names_out(),
 index = df['stkcd'])
```

```
word_count
```

|        | cfr | cif | cip | cnf | cpt | dap | ddp | ddu | dematicgrou | dematicgroup | ... | 验收  | 高度  |
|--------|-----|-----|-----|-----|-----|-----|-----|-----|-------------|--------------|-----|-----|-----|
| stkcd  |     |     |     |     |     |     |     |     |             |              |     |     |     |
| 600977 | 0   | 0   | 0   | 0   | 0   | 0   | 0   | 0   | 0           | 0            | ... | 0   | 0   |
| 830832 | 0   | 0   | 0   | 0   | 0   | 0   | 0   | 0   | 0           | 0            | ... | 0   | 0   |
| 719    | 0   | 0   | 0   | 0   | 0   | 0   | 0   | 0   | 0           | 0            | ... | 0   | 0   |
| 300706 | 0   | 0   | 0   | 0   | 0   | 0   | 0   | 0   | 0           | 0            | ... | 0   | 0   |
| 301421 | 0   | 0   | 0   | 0   | 0   | 0   | 0   | 0   | 0           | 0            | ... | 0   | 0   |
| ...    | ... | ... | ... | ... | ... | ... | ... | ... | ...         | ...          | ... | ... | ... |
| 2853   | 0   | 0   | 0   | 0   | 0   | 0   | 0   | 0   | 0           | 0            | ... | 0   | 0   |

|        | cfr | cif | cip | cnf | cpt | dap | ddp | ddu | dematicgrou | dematicgroup | ... | 验收 | 高度 |
|--------|-----|-----|-----|-----|-----|-----|-----|-----|-------------|--------------|-----|----|----|
| stkcd  |     |     |     |     |     |     |     |     |             |              |     |    |    |
| 338    | 0   | 0   | 0   | 0   | 0   | 0   | 0   | 0   | 2           | 1            | ... | 0  | 0  |
| 603180 | 0   | 0   | 0   | 0   | 0   | 0   | 0   | 0   | 0           | 0            | ... | 0  | 0  |
| 603056 | 0   | 0   | 0   | 0   | 0   | 0   | 0   | 0   | 0           | 0            | ... | 0  | 0  |
| 793    | 0   | 0   | 0   | 0   | 0   | 0   | 0   | 0   | 0           | 0            | ... | 0  | 0  |

### 7.5.1 基于词典的方法

```
word_count
```

|        | cfr | cif | cip | cnf | cpt | dap | ddp | ddu | dematicgrou | dematicgroup | ... | 验收  | 高度  |
|--------|-----|-----|-----|-----|-----|-----|-----|-----|-------------|--------------|-----|-----|-----|
| stkcd  |     |     |     |     |     |     |     |     |             |              |     |     |     |
| 600977 | 0   | 0   | 0   | 0   | 0   | 0   | 0   | 0   | 0           | 0            | ... | 0   | 0   |
| 830832 | 0   | 0   | 0   | 0   | 0   | 0   | 0   | 0   | 0           | 0            | ... | 0   | 0   |
| 719    | 0   | 0   | 0   | 0   | 0   | 0   | 0   | 0   | 0           | 0            | ... | 0   | 0   |
| 300706 | 0   | 0   | 0   | 0   | 0   | 0   | 0   | 0   | 0           | 0            | ... | 0   | 0   |
| 301421 | 0   | 0   | 0   | 0   | 0   | 0   | 0   | 0   | 0           | 0            | ... | 0   | 0   |
| ...    | ... | ... | ... | ... | ... | ... | ... | ... | ...         | ...          | ... | ... | ... |
| 2853   | 0   | 0   | 0   | 0   | 0   | 0   | 0   | 0   | 0           | 0            | ... | 0   | 0   |
| 338    | 0   | 0   | 0   | 0   | 0   | 0   | 0   | 0   | 2           | 1            | ... | 0   | 0   |
| 603180 | 0   | 0   | 0   | 0   | 0   | 0   | 0   | 0   | 0           | 0            | ... | 0   | 0   |
| 603056 | 0   | 0   | 0   | 0   | 0   | 0   | 0   | 0   | 0           | 0            | ... | 0   | 0   |
| 793    | 0   | 0   | 0   | 0   | 0   | 0   | 0   | 0   | 0           | 0            | ... | 0   | 0   |

```
wcdf = word_count.stack().reset_index()
```

```
wcdf
```



|       | stkcd  | level_1 | 0   |
|-------|--------|---------|-----|
| 0     | 600977 | cfr     | 0   |
| 1     | 600977 | cif     | 0   |
| 2     | 600977 | cip     | 0   |
| 3     | 600977 | cnf     | 0   |
| 4     | 600977 | cpt     | 0   |
| ...   | ...    | ...     | ... |
| 94495 | 793    | 鱼微      | 0   |
| 94496 | 793    | 黄金      | 0   |
| 94497 | 793    | 齐鲁      | 0   |
| 94498 | 793    | 龙利      | 0   |
| 94499 | 793    | 龙利得     | 0   |

```
wcdf.columns = ["stkcd", "word", "N"]
wcdf = wcdf[wcdf.N > 0].sort_values(by=['stkcd',
 ↪ "N"]).reset_index(drop=True)
wcdf
```

|      | stkcd  | word | N   |
|------|--------|------|-----|
| 0    | 166    | 包括   | 1   |
| 1    | 166    | 影响   | 1   |
| 2    | 166    | 投资   | 1   |
| 3    | 166    | 投资者  | 1   |
| 4    | 166    | 担任   | 1   |
| ...  | ...    | ...  | ... |
| 3291 | 871396 | 执行器  | 4   |
| 3292 | 871396 | 控制   | 4   |
| 3293 | 871396 | 阀门   | 4   |
| 3294 | 871396 | 收入   | 5   |
| 3295 | 871396 | 销售   | 5   |

## 7.6 词云

```
from wordcloud import WordCloud
```

```
wordcloudddf =
 ↪ wcdf.groupby('word').N.sum().reset_index().sort_values(by='N',
 ↪ ascending=False).set_index('word')
wordcloudddf
```

|      | N   |
|------|-----|
| word |     |
| 收入   | 457 |
| 确认   | 215 |
| 公司   | 204 |
| 营业   | 151 |
| 销售   | 129 |
| ...  | ... |
| 地并   | 1   |
| 版块   | 1   |
| 煤炭   | 1   |
| 焊割   | 1   |
| cfr  | 1   |

```
worddic = wordcloudddf["N"].to_dict()
worddic
```

```
{'收入': 457,
 '确认': 215,
 '公司': 204,
 '营业': 151,
 '销售': 129,
```

'管理层': 98,  
'业务': 91,  
'年度': 90,  
'风险': 76,  
'指标': 66,  
'产品': 65,  
'业绩': 61,  
'金额': 59,  
'财务': 56,  
'人民币': 54,  
'固有': 54,  
'客户': 50,  
'报表': 48,  
'特定': 48,  
'目标': 48,  
'资产': 47,  
'减值': 46,  
'预期': 41,  
'信用': 40,  
'股份': 38,  
'判断': 35,  
'影响': 34,  
'合同': 32,  
'相关': 32,  
'识别': 32,  
'商誉': 31,  
'合并': 31,  
'服务': 31,  
'时点': 30,  
'科技': 29,  
'应收': 28,  
'操纵': 28,

'估计': 27,  
'主营': 27,  
'期望': 27,  
'损失': 27,  
'恰当': 27,  
'模式': 27,  
'账款': 26,  
'会计': 25,  
'涉及': 25,  
'账面': 24,  
'系统': 24,  
'生产': 23,  
'价值': 22,  
'项目': 20,  
'包括': 19,  
'评估': 17,  
'设备': 17,  
'计量': 17,  
'简称': 17,  
'控制': 17,  
'信息': 17,  
'经营': 16,  
'货物': 16,  
'工程': 16,  
'成本': 15,  
'金融': 15,  
'假设': 15,  
'收回': 14,  
'预计': 14,  
'附注': 14,  
'出口': 14,  
'余额': 14,

'来自于': 14,  
'模型': 13,  
'测试': 13,  
'履约': 13,  
'约定': 13,  
'错报': 13,  
'平台': 12,  
'商品': 12,  
'比例': 12,  
'发生': 12,  
'坏账': 12,  
'参数': 12,  
'集团': 11,  
'控制权': 11,  
'外销': 11,  
'开发': 11,  
'收款': 11,  
'资产组': 11,  
'情况': 10,  
'指定': 10,  
'提供': 10,  
'主体': 10,  
'特许': 10,  
'制药': 10,  
'结构化': 10,  
'公路': 10,  
'运输': 10,  
'管理': 10,  
'报关': 9,  
'未来': 9,  
'物流': 9,  
'药业': 9,

'子公司': 9,  
'现金': 9,  
'利润': 9,  
'研发': 9,  
'运营': 9,  
'交付': 9,  
'计提': 8,  
'贷款': 8,  
'经销商': 8,  
'经营权': 8,  
'地点': 8,  
'采用': 8,  
'汽车': 8,  
'房地产': 8,  
'签收': 8,  
'义务': 8,  
'网络': 8,  
'游戏': 8,  
'收取': 8,  
'增加': 7,  
'认定': 7,  
'快运': 7,  
'快递': 7,  
'收租': 7,  
'因素': 7,  
'总额': 7,  
'期间': 7,  
'交易': 7,  
'发货': 7,  
'进度': 7,  
'通信': 7,  
'无形': 7,

'状况': 7,  
'技术': 7,  
'违约': 7,  
'过程': 7,  
'长期': 7,  
'收费': 7,  
'来源于': 7,  
'存货': 7,  
'权利': 7,  
'流量': 7,  
'政策': 7,  
'电源': 6,  
'经济': 6,  
'原值': 6,  
'前瞻性': 6,  
'能源': 6,  
'电商': 6,  
'益佰': 6,  
'发行': 6,  
'结算': 6,  
'组合': 6,  
'验收': 6,  
'收到': 6,  
'潜在': 6,  
'投资': 6,  
'负债': 6,  
'设计': 6,  
'合计': 6,  
'it': 6,  
'境外': 6,  
'本期': 6,  
'内销': 6,

'履行': 6,  
'境内': 6,  
'普莱': 6,  
'宏源': 5,  
'金租': 5,  
'动力': 5,  
'皖通': 5,  
'润表': 5,  
'运至': 5,  
'江苏': 5,  
'圣阳': 5,  
'综合': 5,  
'注释': 5,  
'湘佳': 5,  
'合并利': 5,  
'智能': 5,  
'承包': 5,  
'方式': 5,  
'所述': 5,  
'瑞凌': 5,  
'报告': 5,  
'截止': 5,  
'成果': 5,  
'日发': 5,  
'零部件': 5,  
'净值': 5,  
'国博': 5,  
'准确性': 5,  
'电子': 5,  
'信质': 5,  
'收购': 5,  
'有限': 5,



'依赖': 5,  
'重要性': 5,  
'之间': 5,  
'上年': 5,  
'转移': 5,  
'广告': 5,  
'航空': 5,  
'机械': 5,  
'条款': 5,  
'股权': 5,  
'来源': 5,  
'镇海': 5,  
'数据': 5,  
'中铁': 4,  
'珀莱雅': 4,  
'激光': 4,  
'现值': 4,  
'特货': 4,  
'固定': 4,  
'增长': 4,  
'购货方': 4,  
'杰华特': 4,  
'中原': 4,  
'一时点': 4,  
'弘元': 4,  
'当虹': 4,  
'智造': 4,  
'普莱得': 4,  
'德邦': 4,  
'总收入': 4,  
'所示': 4,  
'大宗': 4,

'执行器': 4,  
'新材': 4,  
'kion': 4,  
'提单': 4,  
'推广': 4,  
'损失率': 4,  
'阶段': 4,  
'阀门': 4,  
'工业': 4,  
'用户': 4,  
'梦天': 4,  
'正威': 4,  
'家居': 4,  
'正裕': 4,  
'世荣': 4,  
'东亚': 4,  
'比重': 4,  
'汇宇': 4,  
'污水': 4,  
'波长': 4,  
'派林': 4,  
'东利': 4,  
'海格': 4,  
'生物': 4,  
'国内': 4,  
'申万': 4,  
'光电': 4,  
'变现': 4,  
'传媒': 4,  
'企业': 4,  
'超卓': 4,  
'签订': 4,

'关联': 4,  
'订单': 4,  
'价格': 4,  
'航天': 4,  
'包含': 4,  
'航科': 4,  
'芯片': 4,  
'博闻': 4,  
'准则': 4,  
'表日': 4,  
'历史': 4,  
'减去': 4,  
'联合': 4,  
'程序': 4,  
'兆业': 4,  
'费用': 4,  
'产线': 4,  
'贷款': 4,  
'充值': 4,  
'作出': 4,  
'货款': 4,  
'制品': 4,  
'精机': 4,  
'各类': 4,  
'电影': 4,  
'绿能': 4,  
'货币': 4,  
'概率': 3,  
'交货': 3,  
'莱赛': 3,  
'不确定性': 3,  
'获取': 3,

'常辅': 3,  
'导购': 3,  
'权重': 3,  
'条件': 3,  
'市场': 3,  
'错误': 3,  
'亿通': 3,  
'期末': 3,  
'利益': 3,  
'集成': 3,  
'代理': 3,  
'证券': 3,  
'龙利': 3,  
'齐鲁': 3,  
'高速': 3,  
'贵州': 3,  
'提前': 3,  
'贸易': 3,  
'预测': 3,  
'财信': 3,  
'折现率': 3,  
'数字化': 3,  
'资金': 3,  
'三力': 3,  
'施工': 3,  
'手续': 3,  
'截止性': 3,  
'计算': 3,  
'计入': 3,  
'时间': 3,  
'春风': 3,  
'恒帅': 3,

'装备': 3,  
'跌价': 3,  
'办理': 3,  
'工具': 3,  
'中影': 3,  
'真实': 3,  
'依赖于': 3,  
'百货': 3,  
'迹象': 3,  
'基础': 3,  
'流程': 3,  
'租赁物': 3,  
'宁波': 3,  
'流入': 3,  
'安排': 3,  
'电池': 3,  
'亚华': 3,  
'回收': 3,  
'海通': 3,  
'发展': 3,  
'运行': 3,  
'印刷': 3,  
'现时': 3,  
'华信': 3,  
'合肥': 3,  
'现金流': 3,  
'组件': 3,  
'海外': 3,  
'真实性': 3,  
'环境': 3,  
'终端': 3,  
'运营商': 3,

'计费': 2,  
'音飞': 2,  
'认后': 2,  
'相当于': 2,  
'火腿': 2,  
'湘邮': 2,  
'选择': 2,  
'金牌': 2,  
'物资': 2,  
'白酒': 2,  
'记录': 2,  
'接受': 2,  
'金徽酒': 2,  
'该类': 2,  
'玩家': 2,  
'电新': 2,  
'配件': 2,  
'电机': 2,  
'高者': 2,  
'部门': 2,  
'操控': 2,  
'食用': 2,  
'支付': 2,  
'食品': 2,  
'邮件': 2,  
'政府': 2,  
'预估': 2,  
'电视': 2,  
'电路板': 2,  
'调试': 2,  
'科目': 2,  
'调整': 2,

'特征': 2,  
'详见': 2,  
'政务': 2,  
'运送': 2,  
'经销': 2,  
'湖雪': 2,  
'程度': 2,  
'第三方': 2,  
'自动化': 2,  
'权力': 2,  
'长城': 2,  
'自主': 2,  
'软件': 2,  
'电力': 2,  
'治理': 2,  
'沪电': 2,  
'精工': 2,  
'销售量': 2,  
'松茸': 2,  
'板块': 2,  
'标准': 2,  
'核算': 2,  
'汉光': 2,  
'終了': 2,  
'模具': 2,  
'水务': 2,  
'钱潮': 2,  
'模组': 2,  
'流转': 2,  
'机床': 2,  
'计价': 2,  
'药品': 2,

'租赁': 2,  
'晋西': 2,  
'渠道': 2,  
'清洗': 2,  
'消费者': 2,  
'表中': 2,  
'补价': 2,  
'衡量': 2,  
'行业': 2,  
'消耗': 2,  
'月度': 2,  
'虚拟': 2,  
'虚增': 2,  
'阿石创': 2,  
'朗博': 2,  
'车轴': 2,  
'期内': 2,  
'菌制品': 2,  
'期限': 2,  
'长高': 2,  
'金证': 2,  
'收货': 2,  
'龙利得': 2,  
'庞大': 2,  
'出库单': 2,  
'冷链': 2,  
'价款': 2,  
'发电': 2,  
'军工': 2,  
'当月': 2,  
'审价': 2,  
'分摊': 2,



'中间体': 2,  
'中钢': 2,  
'中船': 2,  
'中科': 2,  
'影视': 2,  
'内部': 2,  
'东方': 2,  
'恒华': 2,  
'橱柜': 2,  
'回性': 2,  
'众多': 2,  
'回报': 2,  
'定制化': 2,  
'原料药': 2,  
'仪器': 2,  
'变更': 2,  
'下降': 2,  
'储存': 2,  
'准确': 2,  
'射频': 2,  
'减少': 2,  
'享有': 2,  
'净额': 2,  
'亿联': 2,  
'差异': 2,  
'凭证': 2,  
'交易量': 2,  
'交易性': 2,  
'后续': 2,  
'亚虹': 2,  
'导致': 2,  
'后台': 2,

'同比': 2,  
'同期': 2,  
'对价': 2,  
'合力': 2,  
'可收': 2,  
'可变': 2,  
'口径': 2,  
'传感器': 2,  
'会议': 2,  
'宏观': 2,  
'安徽': 2,  
'安居宝': 2,  
'上海': 2,  
'抗菌药': 2,  
'入账': 2,  
'披露': 2,  
'存续': 2,  
'姚记': 2,  
'光机电': 2,  
'dematicgrou': 2,  
'天味': 2,  
'大恒': 2,  
'制造': 2,  
'大件': 2,  
'持续': 2,  
'剩余': 2,  
'多种': 2,  
'华菱': 2,  
'处置': 2,  
'外部': 2,  
'p所': 2,  
'封件': 2,

'r组件': 2,  
'万向': 2,  
'执行': 2,  
'印制': 2,  
'上年度': 2,  
'完毕': 2,  
'国中': 2,  
'承租人': 2,  
'列报': 2,  
'投入': 2,  
'单项': 2,  
'公允': 2,  
'其他应收款': 1,  
'冰压机': 1,  
'表现': 1,  
'调节': 1,  
'内蒙': 1,  
'解痉药': 1,  
'访问': 1,  
'内酰': 1,  
'全程': 1,  
'内容': 1,  
'评估师': 1,  
'视觉': 1,  
'全球': 1,  
'充分性': 1,  
'装运港': 1,  
'先款': 1,  
'冰鲜': 1,  
'诊断': 1,  
'视为': 1,  
'关联方': 1,

'六大': 1,  
'角色': 1,  
'接单': 1,  
'减震器': 1,  
'制作': 1,  
'自初': 1,  
'创作': 1,  
'能力': 1,  
'胺类': 1,  
'创新': 1,  
'利润表': 1,  
'聘请': 1,  
'联盟': 1,  
'联方': 1,  
'到期': 1,  
'联产': 1,  
'编辑': 1,  
'凭据': 1,  
'制动': 1,  
'制片': 1,  
'维生素': 1,  
'维修': 1,  
'绩效': 1,  
'统称': 1,  
'剧集': 1,  
'加工': 1,  
'经购': 1,  
'加权': 1,  
'北斗': 1,  
'列为': 1,  
'自有': 1,  
'自营': 1,

'自行': 1,  
'血液': 1,  
'融资': 1,  
'融合': 1,  
'融出': 1,  
'蚕丝': 1,  
'出版': 1,  
'蓄能': 1,  
'蒸汽': 1,  
'营运': 1,  
'出版物': 1,  
'菲利华': 1,  
'菌药': 1,  
'击量': 1,  
'分t': 1,  
'分为': 1,  
'分散': 1,  
'若干': 1,  
'分析': 1,  
'船舷': 1,  
'分部': 1,  
'分配': 1,  
'划分': 1,  
'至少': 1,  
'储能': 1,  
'保税区': 1,  
'做出': 1,  
'铝合金': 1,  
'三十八': 1,  
'门到门': 1,  
'长高电新': 1,  
'三阶段': 1,

'上年末': 1,  
'上期': 1,  
'上涨': 1,  
'销售密': 1,  
'销售化': 1,  
'不尽相同': 1,  
'银泰': 1,  
'铅蓄': 1,  
'三十一': 1,  
'铁路': 1,  
'专家': 1,  
'丝绸': 1,  
'金徽': 1,  
'为经': 1,  
'主观': 1,  
'酮类': 1,  
'配电': 1,  
'配合': 1,  
'主观性': 1,  
'书面': 1,  
'三十五': 1,  
'三十': 1,  
'买入': 1,  
'dematicgroup': 1,  
'cip': 1,  
'cnf': 1,  
'黄金': 1,  
'鱼微': 1,  
'cpt': 1,  
'dap': 1,  
'高电': 1,  
'高度': 1,

'ddp': 1,  
'ddu': 1,  
'飞机': 1,  
'频繁': 1,  
'院线': 1,  
'领用': 1,  
'领域': 1,  
'exw': 1,  
'fca': 1,  
'fob': 1,  
'group': 1,  
'顺序': 1,  
'poct': 1,  
'非t': 1,  
'零售': 1,  
'一体化': 1,  
'部品': 1,  
'逻辑': 1,  
'偏向': 1,  
'购子': 1,  
'超市': 1,  
'休闲': 1,  
'资租': 1,  
'资源': 1,  
'资本化': 1,  
'资本': 1,  
'众辰': 1,  
'低于': 1,  
'佣金': 1,  
'供应链': 1,  
'经接': 1,  
'购买': 1,

'越过': 1,  
'保证': 1,  
'信号': 1,  
'货方': 1,  
'信宇人': 1,  
'账龄': 1,  
'修订': 1,  
'账确': 1,  
'借款': 1,  
'账方式': 1,  
'账户': 1,  
'账务': 1,  
'超过': 1,  
'跨期': 1,  
'通讯': 1,  
'返售': 1,  
'通知': 1,  
'二十': 1,  
'二十三': 1,  
'选取': 1,  
'送货': 1,  
'追踪': 1,  
'二十五': 1,  
'二级': 1,  
'云办公': 1,  
'进口': 1,  
'还款': 1,  
'互联网': 1,  
'车站': 1,  
'运输交': 1,  
'交互': 1,  
'交易额': 1,



'运动': 1,  
'运作': 1,  
'输配电': 1,  
'输入': 1,  
'载明': 1,  
'软硬件': 1,  
'仓储': 1,  
'仓库': 1,  
'医院': 1,  
'单笔': 1,  
'经常性': 1,  
'暴露': 1,  
'年内': 1,  
'年限': 1,  
'机载': 1,  
'并经': 1,  
'广告位': 1,  
'机密': 1,  
'机器': 1,  
'机制': 1,  
'应计': 1,  
'未计': 1,  
'店铺': 1,  
'木质': 1,  
'建立': 1,  
'建设': 1,  
'建造': 1,  
'期初': 1,  
'开关': 1,  
'开设': 1,  
'服务费': 1,  
'服务方': 1,

'引导': 1,  
'当年': 1,  
'有线': 1,  
'有效性': 1,  
'最佳': 1,  
'权益': 1,  
'平均': 1,  
'带来': 1,  
'款外': 1,  
'实时': 1,  
'永续': 1,  
'水平': 1,  
'审定': 1,  
'宣传': 1,  
'每月': 1,  
'母公司': 1,  
'家具': 1,  
'正确': 1,  
'家电': 1,  
'款确': 1,  
'家畜': 1,  
'差额': 1,  
'对账': 1,  
'模块': 1,  
'导航': 1,  
'寿命': 1,  
'根据线': 1,  
'核心': 1,  
'尚未': 1,  
'尤其是': 1,  
'层于': 1,  
'展示': 1,

'差异性': 1,  
'最为': 1,  
'暂定': 1,  
'十六': 1,  
'形车': 1,  
'抗真': 1,  
'cif': 1,  
'收融': 1,  
'抗胆': 1,  
'收益': 1,  
'收方': 1,  
'报关单': 1,  
'报表日': 1,  
'收入区': 1,  
'抵押物': 1,  
'抵销': 1,  
'抽水': 1,  
'担任': 1,  
'播放': 1,  
'摩托车': 1,  
'摊销': 1,  
'提存': 1,  
'担保人': 1,  
'拥有': 1,  
'推迟': 1,  
'按点': 1,  
'损益': 1,  
'授予': 1,  
'接收方': 1,  
'接口': 1,  
'投资者': 1,  
'放映': 1,

'投放': 1,  
'无线': 1,  
'智能化': 1,  
'影院': 1,  
'快速': 1,  
'悬架': 1,  
'情景': 1,  
'時計': 1,  
'成交': 1,  
'时段': 1,  
'成品油': 1,  
'无需': 1,  
'无误': 1,  
'所在地': 1,  
'承运人': 1,  
'扑克牌': 1,  
'新百': 1,  
'执行性': 1,  
'新华': 1,  
'文件': 1,  
'整体': 1,  
'数量': 1,  
'数智': 1,  
'承诺': 1,  
'数字': 1,  
'敞口': 1,  
'汇总': 1,  
'实施': 1,  
'定义': 1,  
'沥青': 1,  
'占期': 1,  
'历次': 1,

'租售': 1,  
'原则': 1,  
'禽肉': 1,  
'离岸': 1,  
'离子': 1,  
'票务': 1,  
'碱药': 1,  
'硬件': 1,  
'参阅': 1,  
'发出': 1,  
'发动': 1,  
'相比': 1,  
'发放': 1,  
'直营': 1,  
'目的': 1,  
'受偿': 1,  
'监控': 1,  
'受限': 1,  
'皮肤': 1,  
'变化': 1,  
'各项': 1,  
'合成': 1,  
'合理性': 1,  
'南京': 1,  
'税费': 1,  
'站到站': 1,  
'精密': 1,  
'华培': 1,  
'华米': 1,  
'线下': 1,  
'纳入': 1,  
'华闻': 1,

'红外': 1,  
'累计': 1,  
'索赔': 1,  
'协助': 1,  
'协议': 1,  
'单个': 1,  
'类型': 1,  
'笔数': 1,  
'类似': 1,  
'管理者': 1,  
'单位': 1,  
'单据': 1,  
'单时': 1,  
'单核': 1,  
'签署': 1,  
'授权': 1,  
'签字': 1,  
'策略': 1,  
'第四': 1,  
'电动车': 1,  
'电动': 1,  
'后货': 1,  
'海关': 1,  
'境外线': 1,  
'潍柴': 1,  
'增材': 1,  
'增长率': 1,  
'复杂性': 1,  
'港口': 1,  
'外线': 1,  
'涵盖': 1,  
'多且': 1,

'妆品': 1,  
'始确': 1,  
'浙江': 1,  
'激励': 1,  
'存续期': 1,  
'流贴': 1,  
'季度': 1,  
'流动': 1,  
'活鸡': 1,  
'活动': 1,  
'洛耐': 1,  
'安装': 1,  
'注册量': 1,  
'完工': 1,  
'完整': 1,  
'境内线': 1,  
'垫款': 1,  
'田野': 1,  
'嗲啞': 1,  
'含有': 1,  
'用于': 1,  
'生猪': 1,  
'生物质': 1,  
'周期': 1,  
'生态': 1,  
'生命': 1,  
'品牌': 1,  
'售价': 1,  
'商官网': 1,  
'商平台': 1,  
'现法': 1,  
'热电': 1,

```
'四十三': 1,
'四十四': 1,
'回单': 1,
'因子': 1,
'国产': 1,
'国际': 1,
'地区': 1,
'地并': 1,
'版块': 1,
'煤炭': 1,
'焊割': 1,
'cfr': 1}
```

open source font: <https://fonts.google.com/>

```
wordcloud = WordCloud(font_path="data/canger03-W03.ttf",
 background_color="white", max_words=100,
 max_font_size=250, random_state=42, width=1200,
 height=600,
 ↪ margin=2).generate_from_frequencies(worddic)
```

```
import matplotlib.pyplot as plt
plt.imshow(wordcloud, interpolation='bilinear')
plt.axis("off")
plt.show()
```





```
wordcloud = WordCloud(font_path="data/MaShanZheng-Regular.ttf",
 background_color="white", max_words=100,
 max_font_size=250, random_state=42, width=1200,
 height=600,
 ↪ margin=2).generate_from_frequencies(wordddic)
```

```
plt.imshow(wordcloud, interpolation='bilinear')
plt.axis("off")
plt.show()
```



## 7.7 词表占比

```
total = wcdf.groupby("stkcd").N.sum().reset_index().rename(columns =
↪ {"N":"total"})
total.head()
```

|   | stkcd | total |
|---|-------|-------|
| 0 | 166   | 73    |
| 1 | 338   | 96    |
| 2 | 403   | 80    |
| 3 | 417   | 89    |

|   | stkcd | total |
|---|-------|-------|
| 4 | 559   | 50    |

```
define your own word list
wordlist = [" 收入"]
```

```
wordlistN =
 ↪ wcdf[wcdf.word.isin(wordlist)].groupby("stkcd").N.sum().reset_index().rename(column="listN")
 ↪ = {"N":"listN"})
wordlistN
```

|     | stkcd  | listN |
|-----|--------|-------|
| 0   | 403    | 7     |
| 1   | 417    | 1     |
| 2   | 719    | 9     |
| 3   | 799    | 9     |
| 4   | 838    | 6     |
| ... | ...    | ...   |
| 77  | 688819 | 4     |
| 78  | 830832 | 4     |
| 79  | 832023 | 4     |
| 80  | 838262 | 4     |
| 81  | 871396 | 5     |

```
wordlistN = total.merge(wordlistN, how="left", on = "stkcd").fillna(0)
wordlistN
```


|   | stkcd | total | listN |
|---|-------|-------|-------|
| 0 | 166   | 73    | 0.0   |

|     | stkcd  | total | listN |
|-----|--------|-------|-------|
| 1   | 338    | 96    | 0.0   |
| 2   | 403    | 80    | 7.0   |
| 3   | 417    | 89    | 1.0   |
| 4   | 559    | 50    | 0.0   |
| ... | ...    | ...   | ...   |
| 95  | 830832 | 27    | 4.0   |
| 96  | 832023 | 24    | 4.0   |
| 97  | 838262 | 33    | 4.0   |
| 98  | 871263 | 39    | 0.0   |
| 99  | 871396 | 53    | 5.0   |

```
wordlistN['wordrate'] = wordlistN["listN"]/wordlistN["total"]
wordlistN.head()
```

|   | stkcd | total | listN | wordrate |
|---|-------|-------|-------|----------|
| 0 | 166   | 73    | 0.0   | 0.000000 |
| 1 | 338   | 96    | 0.0   | 0.000000 |
| 2 | 403   | 80    | 7.0   | 0.087500 |
| 3 | 417   | 89    | 1.0   | 0.011236 |
| 4 | 559   | 50    | 0.0   | 0.000000 |

```
wordlistN.wordrate.hist(bins = 30)
```



```
wordlistN.to_excel("data/wordlist_ratio.xlsx", index = False)
```


```
wordlistN = wordlistN.assign(sentiment =
 ↪ wordlistN["listN"]/wordlistN["total"])
wordlistN.query("sentiment < 0")
```

| stkcd | total | listN | wordrate | sentiment |
|-------|-------|-------|----------|-----------|
|-------|-------|-------|----------|-----------|

```
wordlistN.sentiment.describe()
```

```
count 100.000000
mean 0.102567
std 0.066533
min 0.000000
25% 0.061800
50% 0.110243
75% 0.148148
max 0.285714
Name: sentiment, dtype: float64
```

```
wordlistN.sentiment.hist(bins = 30)
```



## 7.8 相似度

```
from sklearn.metrics.pairwise import cosine_similarity
```

```
xx = cosine_similarity(word_tfidf_vector)
```

```
xx.shape
```

```
(100, 100)
```

```
pd.DataFrame(xx, columns = df.stkcd,
 index = df.stkcd)
```

| stkcd  | 600977   | 830832   | 719      | 300706   | 301421   | 688553   | 799      | 603070   | 3012 |
|--------|----------|----------|----------|----------|----------|----------|----------|----------|------|
| 600977 | 1.000000 | 0.048218 | 0.125220 | 0.004306 | 0.073676 | 0.063892 | 0.132036 | 0.087896 | 0.06 |

| stkcd  | 600977   | 830832   | 719      | 300706   | 301421   | 688553   | 799      | 603070   | 3012 |
|--------|----------|----------|----------|----------|----------|----------|----------|----------|------|
| stkcd  |          |          |          |          |          |          |          |          |      |
| 830832 | 0.048218 | 1.000000 | 0.130587 | 0.000000 | 0.060503 | 0.072498 | 0.230335 | 0.086199 | 0.05 |
| 719    | 0.125220 | 0.130587 | 1.000000 | 0.010078 | 0.083489 | 0.105940 | 0.390918 | 0.151922 | 0.09 |
| 300706 | 0.004306 | 0.000000 | 0.010078 | 1.000000 | 0.003765 | 0.023940 | 0.025468 | 0.032614 | 0.02 |
| 301421 | 0.073676 | 0.060503 | 0.083489 | 0.003765 | 1.000000 | 0.102491 | 0.224208 | 0.116393 | 0.09 |
| ...    | ...      | ...      | ...      | ...      | ...      | ...      | ...      | ...      | ...  |
| 2853   | 0.135564 | 0.234815 | 0.480994 | 0.024555 | 0.158285 | 0.206910 | 0.707412 | 0.269446 | 0.18 |
| 338    | 0.006073 | 0.003409 | 0.008334 | 0.117279 | 0.007342 | 0.023701 | 0.030085 | 0.028313 | 0.02 |
| 603180 | 0.092044 | 0.108199 | 0.213851 | 0.009752 | 0.104312 | 0.136175 | 0.258173 | 0.160411 | 0.11 |
| 603056 | 0.120057 | 0.059891 | 0.111101 | 0.009871 | 0.037954 | 0.042566 | 0.122016 | 0.062185 | 0.03 |
| 793    | 0.048434 | 0.000000 | 0.004514 | 0.076536 | 0.008403 | 0.019549 | 0.012863 | 0.025381 | 0.01 |

```
simi_pair = pd.DataFrame(xx, columns = df.stkcd, index =
 ↪ df.stkcd).stack()
simi_pair
```

```
stkcd stkcd
600977 600977 1.000000
 830832 0.048218
 719 0.125220
 300706 0.004306
 301421 0.073676
 ...
793 2853 0.010998
 338 0.125898
 603180 0.003733
 603056 0.010922
 793 1.000000

Length: 10000, dtype: float64
```

```
simi_pair.index.names = ['stkcd_x', 'stkcd_y']
simi_pair.reset_index().rename(columns = {0: "similarity"})
```

|      | stkcd_x | stkcd_y | similarity |
|------|---------|---------|------------|
| 0    | 600977  | 600977  | 1.000000   |
| 1    | 600977  | 830832  | 0.048218   |
| 2    | 600977  | 719     | 0.125220   |
| 3    | 600977  | 300706  | 0.004306   |
| 4    | 600977  | 301421  | 0.073676   |
| ...  | ...     | ...     | ...        |
| 9995 | 793     | 2853    | 0.010998   |
| 9996 | 793     | 338     | 0.125898   |
| 9997 | 793     | 603180  | 0.003733   |
| 9998 | 793     | 603056  | 0.010922   |
| 9999 | 793     | 793     | 1.000000   |

## 8 可视化

[点击下载本章节代码](#)

### 8.1 Matplotlib 数据可视化

Matplotlib 模块是 Python 最基础的可视化库，可以绘制多种形式的图形，包括线图、直方图、饼状图、散点图、误差线图等等。在我们的工作和学习中，将数据图形化展示是一项非常重要的任务，可以让数据更加直观。

Matplotlib 最重要的特性之一就是具有良好的操作系统兼容性和图形显示底层接口兼容性。

```
%pip install matplotlib pandas numpy seaborn plotly --upgrade
```


```
import matplotlib.pyplot as plt
from matplotlib import animation
import pandas as pd
import numpy as np
import math
```

```
t = np.linspace(0, math.pi, 1000)
x = np.sin(t)
y = np.cos(t) + np.power(x, 2.0/3)
plt.plot(x, y, color='red', linewidth=2, label='h')
plt.plot(-x, y, color='red', linewidth=2, label='-h')
plt.xlabel('t')
plt.ylabel('h')
```



```
plt.ylim(-2, 2)
plt.xlim(-2, 2)

plt.show()
```



### 8.1.1 设置绘图样式

使用 `plt.style` 来选择图形的绘图风格。

#### **i** Matplotlib 样式说明

从 Matplotlib 3.6 版本开始，`seaborn` 样式已被移除。可以使用以下替代方案：

- `seaborn-v0_8` - 使用旧版 `seaborn` 样式
- `default` - Matplotlib 默认样式
- `ggplot` - ggplot2 风格
- `bmh` - Bayesian Methods for Hackers 样式

```
查看所有可用样式
print(plt.style.available)
```

```
['Solarize_Light2', '_classic_test_patch', '_mpl-gallery', '_mpl-gallery-nogrid', 'bm
```


```
使用 seaborn-v0_8 样式 (兼容旧代码)
plt.style.use('seaborn-v0_8')
```

### 8.1.2 关于 plt.show()

如果你在一个脚本文件中使用 Matplotlib, 那么显示图形的时候必须使用 `plt.show()`, 而在 notebook 中可以不要, 特别注意在 notebook 中画图:


- `%matplotlib notebook` 会在 Notebook 中启动交互式图形。
- `%matplotlib inline` 会在 Notebook 中启动静态图形。

```
import numpy as np
x = np.linspace(0, 10, 100)
fig = plt.figure()
plt.plot(x, np.sin(x), '-')
plt.plot(x, np.cos(x), '--')
```



```
fig.savefig('my_figure.png')
```

```
from IPython.display import Image
Image('my_figure.png')
```




```
fig.savefig('my_figure.pdf')
```

```
fig.canvas.get_supported_filetypes()
```

```
{'eps': 'Encapsulated Postscript',
 'jpg': 'Joint Photographic Experts Group',
 'jpeg': 'Joint Photographic Experts Group',
 'pdf': 'Portable Document Format',
 'pgf': 'PGF code for LaTeX',
 'png': 'Portable Network Graphics',
 'ps': 'Postscript',
```

```
'raw': 'Raw RGBA bitmap',
'rgba': 'Raw RGBA bitmap',
'svg': 'Scalable Vector Graphics',
'svgz': 'Scalable Vector Graphics',
'tif': 'Tagged Image File Format',
'tiff': 'Tagged Image File Format',
'webp': 'WebP Image Format'}
```


```
plt.figure(figsize= (8,6)) # 创建图形
创建两个子图中的第一个，设置坐标轴
plt.subplot(2, 1, 1) # (行、列、子图编号)
plt.plot(x, np.sin(x))
创建两个子图中的第二个，设置坐标轴
plt.subplot(2, 1, 2)
plt.plot(x, np.cos(x));
```



```

fig = plt.figure()
ax = plt.axes()
x = np.linspace(0, 10, 1000)
ax.plot(x, np.sin(x))
ax.plot(x, np.cos(x))


```



```


plt.plot(x, x + 0, linestyle='solid')
plt.plot(x, x + 1, linestyle='dashed')
plt.plot(x, x + 2, linestyle='dashdot')
plt.plot(x, x + 3, linestyle='dotted');
你可以用下面的简写形式
plt.plot(x, x + 4, linestyle='-') # 实线
plt.plot(x, x + 5, linestyle='--') # 虚线
plt.plot(x, x + 6, linestyle='-.') # 点划线
plt.plot(x, x + 7, linestyle=':'); # 实点线

```



```
import numpy as np
import matplotlib.pyplot as plt
data = np.random.randn(1000)
plt.hist(data)
```

```
(array([2., 20., 55., 168., 252., 246., 167., 71., 17., 2.]),
 array([-3.33782825, -2.66315348, -1.98847871, -1.31380394, -0.63912918,
 0.03554559, 0.71022036, 1.38489513, 2.0595699 , 2.73424466,
 3.40891943]),
 <BarContainer object of 10 artists>)
```



## 8.2 Pandas plot

```
df = pd.DataFrame(np.random.randn(1000, 4),
 index=pd.date_range('1/1/2000', periods=1000),
 columns=list('ABCD'))


df = df.cumsum()
df.head()
```

---

|            | A         | B         | C         | D         |
|------------|-----------|-----------|-----------|-----------|
| 2000-01-01 | 0.201344  | -0.077865 | -0.551789 | -0.278203 |
| 2000-01-02 | -0.472940 | -1.402981 | -1.647169 | -1.118338 |
| 2000-01-03 | -1.396229 | -1.398226 | -0.723251 | -1.250755 |

|            | A         | B         | C         | D         |
|------------|-----------|-----------|-----------|-----------|
| 2000-01-04 | -2.445071 | -0.838639 | -0.386590 | 0.097072  |
| 2000-01-05 | -3.407625 | -1.322600 | -0.804589 | -1.288955 |

```
df.A.hist()
```



```
df["gp"] = df.A // 15
```

```
df.gp.drop_duplicates()
```

```
2000-01-01 0.0
2000-01-02 -1.0
2000-07-09 -2.0
Name: gp, dtype: float64
```




```
df.head()
```


|            | A         | B         | C         | D         | gp   |
|------------|-----------|-----------|-----------|-----------|------|
| 2000-01-01 | 0.201344  | -0.077865 | -0.551789 | -0.278203 | 0.0  |
| 2000-01-02 | -0.472940 | -1.402981 | -1.647169 | -1.118338 | -1.0 |
| 2000-01-03 | -1.396229 | -1.398226 | -0.723251 | -1.250755 | -1.0 |
| 2000-01-04 | -2.445071 | -0.838639 | -0.386590 | 0.097072  | -1.0 |
| 2000-01-05 | -3.407625 | -1.322600 | -0.804589 | -1.288955 | -1.0 |

```
df.A.hist(by= df.gp, figsize=(10, 6))
```


```
array([[<Axes: title={'center': '-2.0'}>,
 <Axes: title={'center': '-1.0'}>],
 [<Axes: title={'center': '0.0'}>, <Axes: >]], dtype=object)
```




```
df.A.plot(kind='box')
```



```
df.plot(kind='box')
```




```
df.plot(figsize= (10,5))
```




```
df = abs(df)
```

```
del df["gp"]
```


```
df.plot.area()
```




```
df.iloc[5].plot(kind='bar', figsize= (5,5))
```



```
df.plot.scatter(x = "A", y = "B", figsize= (6,6))
```




```
df2 = pd.DataFrame(np.random.rand(10, 4), columns=['a', 'b', 'c', 'd'])
df2.plot.bar()
```



```
df2.plot.bar(stacked=True)
```




```
df2.plot.barh(stacked=True)
```



```
df2 = df2.div(df2.sum("columns"), axis = "rows")
```

```
df2.plot.barh(stacked=True)
```




```
df = pd.DataFrame(np.random.rand(50, 4), columns=['a', 'b', 'c', 'd'])
df.head()
```


|   | a        | b        | c        | d        |
|---|----------|----------|----------|----------|
| 0 | 0.656485 | 0.920260 | 0.993871 | 0.065119 |
| 1 | 0.305955 | 0.236032 | 0.513419 | 0.289175 |
| 2 | 0.959830 | 0.628607 | 0.228175 | 0.735164 |
| 3 | 0.752016 | 0.474612 | 0.588254 | 0.899860 |
| 4 | 0.124703 | 0.913492 | 0.048444 | 0.969139 |

```
df.plot.scatter(x='a', y='b')
```






```
df.plot.scatter(x='a', y='b', c='c', s=100)
```




```
df = pd.DataFrame(np.random.randn(1000, 2), columns=['a', 'b'])

df['b'] = df['b'] + np.arange(1000)

df.plot.scatter(x='a', y='b')
```




```
df.plot.hexbin(x='a', y='b', gridsize=25)
```



```
import seaborn as sns
```

```
import seaborn as sns
sns.jointplot(x="a", y="b", data=df, kind="kde")
```



## 8.3 Plotly 交互式可视化

### ! 关于 cufflinks

**cufflinks** 库已停止维护，且与新版本的 **plotly/numpy** 存在兼容性问题。

推荐使用 **Plotly Express**，它是现代化的、官方支持的交互式可视化库。

### 8.3.1 安装 Plotly

```
%pip install plotly kaleido --upgrade
```

### 8.3.2 Plotly Express 基础示例

Plotly Express 提供了简洁的 API 来创建交互式图表。

```
import plotly.express as px
import pandas as pd
import numpy as np

创建示例数据
df = pd.DataFrame({
 'x': np.random.randn(100),
 'y': np.random.randn(100),
 'category': np.random.choice(['A', 'B', 'C'], 100)
})

df.head()
```

|   | x         | y         | category |
|---|-----------|-----------|----------|
| 0 | 0.627366  | -0.499237 | B        |
| 1 | -1.045043 | 0.234597  | B        |
| 2 | 0.068052  | -0.707555 | A        |
| 3 | 2.302555  | 0.124455  | A        |
| 4 | -1.340164 | -0.690232 | B        |

```
散点图
fig = px.scatter(df, x='x', y='y', color='category',
 title='交互式散点图',
 labels={'x': 'X 轴', 'y': 'Y 轴'})
fig.show()
```

Unable to display output for mime type(s): text/html

Unable to display output for mime type(s): text/html

```
创建时间序列数据
ts_df = pd.DataFrame({
 'date': pd.date_range('2024-01-01', periods=100),
 'value': np.cumsum(np.random.randn(100))
})

线图
fig = px.line(ts_df, x='date', y='value',
 title='时间序列图',
 labels={'date': '日期', 'value': '数值'})
fig.show()
```

Unable to display output for mime type(s): text/html

```
直方图
fig = px.histogram(df, x='x', color='category',
 title='分组直方图',
 nbins=20)
fig.show()
```

Unable to display output for mime type(s): text/html

```
箱线图
fig = px.box(df, x='category', y='y',
 title='箱线图',
 labels={'category': '类别', 'y': '数值'})
fig.show()
```

Unable to display output for mime type(s): text/html

### 💡 Plotly 优势

- 交互式：可以缩放、平移、悬停查看数据
- 现代化：API 简洁，文档完善
- 导出方便：支持导出为 HTML、PNG、PDF 等格式
- 样式丰富：内置多种主题和配色方案

---

## 8.4 Seaborn 可视化库

<https://seaborn.pydata.org/index.html>

Seaborn 是基于 matplotlib 的图形可视化 python 包。它提供了一种高度交互式界面，便于用户能够做出各种有吸引力的统计图表。


<https://seaborn.pydata.org/examples/index.html>

```
library
import seaborn as sns
import pandas as pd
import numpy as np

Create a dataset (fake)
df = pd.DataFrame(np.random.random((5,5)), columns=["a","b","c","d","e"])

Default heatmap: just a visualization of this square matrix
p1 = sns.heatmap(df)
```






```
library
import seaborn as sns
import pandas as pd
import numpy as np

Create a dataset (fake)
df = pd.DataFrame(np.random.random((100,5)),
 ↪ columns=["a","b","c","d","e"])

Calculate correlation between each pair of variable
corr_matrix=df.corr()

plot it
sns.heatmap(corr_matrix, cmap='PuOr')
```



```
import seaborn as sns
import matplotlib.pyplot as plt
sns.set_theme(style="whitegrid")


Load the example diamonds dataset
diamonds = sns.load_dataset("diamonds")

Draw a scatter plot while assigning point colors and sizes to different
variables in the dataset
f, ax = plt.subplots(figsize=(6.5, 6.5))
sns.despine(f, left=True, bottom=True)
clarity_ranking = ["I1", "SI2", "SI1", "VS2", "VS1", "VVS2", "VVS1",
 ↪ "IF"]
sns.scatterplot(x="carat", y="price",
 hue="clarity", size="depth",
```

```

palette="ch:r=-.2,d=.3_r",
hue_order=clarity_ranking,
sizes=(1, 8), linewidth=0,
data=diamonds, ax=ax).get_figure().savefig("output.png",
↪ dpi=600)

```



```


import seaborn as sns
import matplotlib.pyplot as plt
sns.set_theme(style="darkgrid")

Load an example dataset with long-form data
fmri = sns.load_dataset("fmri")

```

```
Plot the responses for different events and regions
sns.lineplot(x="timepoint", y="signal",
 hue="region", style="event",
 data=fmri).get_figure()

plt.savefig('saving-a-seaborn-plot-as-png-file-transparent.png',
 transparent=True, dpi = 600)
```



## 8.5 folium 地图可视化

<https://python-visualization.github.io/folium/>

```
%pip install folium --upgrade
```

```

import folium
local = [23.132, 113.345]
local = [23.155, 113.327]
local = [23.019, 113.411]
m = folium.Map(location=local,zoom_start=16)
m

```

<folium.folium.Map at 0x11ce2b230>

```

local = [23.087, 113.37]
使用 OpenStreetMap 默认底图（推荐）
m = folium.Map(
 location=local,
 zoom_start=12
)

folium.Circle(
 radius=800,
 location=[23.133, 113.342],
 popup='暨南大学石牌校区',
 color='crimson',
 fill=False,
).add_to(m)

folium.CircleMarker(
 location=[23.155, 113.327],
 radius=15,
 popup='暨南大学华文校区',
 color='#3186cc',
 fill=True,
 fill_color='#3186cc'
).add_to(m)

```

```

folium.CircleMarker(
 location=[23.02829562968323, 113.41585435512872],
 radius=20,
 popup='暨南大学番禺校区',
 color='#3186cc',
 fill=True,
 fill_color='#3186cc'
).add_to(m)

m

```

<folium.folium.Map at 0x11ba59310>

```

generated data
import numpy as np
data = (
 np.random.normal(size=(300, 3)) *
 np.array([[0.05, 0.05, 0.05]]) +
 np.array([[23.087, 113.3, 1]])
).tolist()
data

```

```

[[23.12292567475108, 113.31809261106721, 0.9512346127155135],
 [23.041480981566522, 113.27505139810303, 1.0014561027021551],
 [23.110695281822395, 113.18403315916512, 0.9318375272376518],
 [23.09015812185156, 113.29098970584552, 0.947261809937028],
 [23.125066284225852, 113.2412566302634, 0.9936659017200175],
 [23.0954231884294, 113.39268341322936, 0.9409524132677773],
 [23.076206805399124, 113.3092817998647, 1.0755670093995926],
 [23.08886483885913, 113.29449376179657, 1.073226387462056],

```

[23.156695116674182, 113.31020011468533, 1.020796497479569],  
[23.134805461434812, 113.3221590889464, 1.1198492637777768],  
[23.09212528354766, 113.3286074318886, 1.0147310800921767],  
[23.130694765251995, 113.3162900943547, 0.9661963141438934],  
[23.075351474581307, 113.33722577131158, 0.9755031633158013],  
[22.972608530006, 113.40229425729164, 0.8756159305541846],  
[23.15044704874554, 113.31430078675666, 0.9463823071198089],  
[23.06513758525095, 113.32697030164556, 0.921914060110518],  
[23.05153121843535, 113.30091381712379, 1.0006419441635177],  
[23.025794479210848, 113.39099042839162, 1.0961652796852122],  
[23.112030712037267, 113.3788489958498, 1.012073202829108],  
[23.07953633211426, 113.34716647159757, 0.9936592812261629],  
[23.139570208994762, 113.285401897008, 0.9872969515019017],  
[23.051343255187913, 113.33695792088785, 1.0917263739890593],  
[23.097304538933965, 113.28139877991453, 0.9992924654582637],  
[23.14512611667325, 113.31463752631878, 0.9137752941933122],  
[23.054589373217766, 113.3438156510386, 1.1095838617572624],  
[23.085193414095166, 113.27282343645759, 0.991227732968647],  
[23.04444550661176, 113.29261571096772, 1.0884383400706585],  
[23.126469545037004, 113.29379422496584, 0.9950141219218092],  
[23.16791937627841, 113.32066195555569, 1.097353598590821],  
[23.084368287822745, 113.38645441751699, 1.0006209889297821],  
[23.137260903962407, 113.37090679580558, 1.0327426991374837],  
[23.18274299039718, 113.22943369468808, 0.968816356160638],  
[23.071299767658658, 113.26832362514449, 1.0526259755276077],  
[23.078726175885194, 113.33032814775468, 0.9871838871859377],  
[23.164499776347228, 113.27613841888774, 0.9831172547378841],  
[23.08717660000457, 113.2958480141386, 1.0197082057281965],  
[23.074763998802222, 113.2681607221764, 1.0313599422889252],  
[23.020664668731182, 113.31658825862529, 1.0214707785175974],  
[23.003087013029866, 113.30526938021956, 1.00431206667352],  
[23.071556998953913, 113.35323157123479, 1.0802903370424324],

[23.08600201916953, 113.3194171393517, 0.9009619505636194],  
[23.17410926529449, 113.31945303347577, 1.0127410889218496],  
[23.0907295903923, 113.37367801803224, 0.9747770184339344],  
[22.95096957529456, 113.2573105512718, 1.0709426552931949],  
[23.133050780284957, 113.40678506511614, 0.9710102127702553],  
[23.103403176667694, 113.24245030272121, 1.0341702627979958],  
[23.19895759617069, 113.21834348342354, 0.9522490882116766],  
[23.09798261222306, 113.30418117662032, 0.9791823244296058],  
[23.007328434250343, 113.40031473166533, 1.029881128305673],  
[23.07566222810024, 113.24170776518467, 1.0634749888731827],  
[23.156741602689266, 113.3095073072332, 1.0031023188314387],  
[23.07726907285033, 113.4004272717788, 1.0197222625996527],  
[23.040623362283043, 113.28614658196811, 0.9975025863737166],  
[23.10262035764237, 113.24102439897791, 1.0290853582832504],  
[23.127858343876927, 113.33058772052696, 0.9902143488522896],  
[23.087728940980334, 113.27100555684953, 1.0539794987326014],  
[23.008814303713372, 113.32201821706005, 0.9551414985218852],  
[23.082233795456343, 113.30194055689061, 0.9657589639402723],  
[23.041896914643907, 113.31723263463309, 1.0394398132117124],  
[23.1224638991438, 113.32172613820511, 0.9568114416174717],  
[23.146654880529777, 113.22812518016103, 1.0038200866173963],  
[23.0975864533372, 113.34684012282491, 0.9683882167872174],  
[23.089788402788614, 113.28752529075138, 0.9340373173381542],  
[22.995836791976014, 113.30142615078746, 0.9629764047587978],  
[23.003966523163946, 113.28457824481265, 0.9974131719999153],  
[23.084525661563358, 113.35218560634391, 1.063595808791513],  
[23.044687235416173, 113.23858897936852, 1.0206296596624913],  
[23.14218103928034, 113.31843292594432, 0.9731828391542027],  
[23.00185879732825, 113.24931714611772, 1.0532470158418312],  
[23.071254111600165, 113.25771011122946, 0.9981969962138197],  
[23.162371094979214, 113.28414356620009, 1.0338432641090314],  
[23.047355414556744, 113.28052642007968, 0.9768681049053216],



[23.051297336293757, 113.27761609786553, 0.9759883987156982],  
[23.102498025655056, 113.2844402229352, 0.9612772593739601],  
[23.06641312912853, 113.26452200167576, 0.9554492381139845],  
[22.986649257705917, 113.43406363511278, 1.0105403000507227],  
[23.11281963296153, 113.31941999249435, 0.9839878843692701],  
[23.129075443928663, 113.3421156036694, 1.047942380726218],  
[23.041486049586045, 113.2204967313712, 0.949280909265336],  
[23.21177627548372, 113.38316471859672, 0.9256469145588638],  
[23.108231492091345, 113.35882904528813, 1.066215003547937],  
[23.120619551085966, 113.27506705696995, 0.994967877121682],  
[23.096050360411947, 113.32513760857503, 1.1003517155110996],  
[23.128120591704246, 113.32032980412413, 0.9327065831130598],  
[23.069894640732066, 113.29039879496638, 0.9141795265980605],  
[23.098494116284062, 113.24325348576602, 1.0170363797536706],  
[23.121697667224577, 113.34340381375044, 1.037742532290055],  
[23.038806377916277, 113.25721686668791, 0.994931491491079],  
[22.999223596270056, 113.2934426669681, 1.049197861487439],  
[23.104323307031247, 113.26526525834568, 0.9530484433712318],  
[23.1387809667552, 113.32706768524493, 0.989258130616403],  
[22.996414889133398, 113.33839286539919, 0.9537001386655031],  
[23.07448440537044, 113.29332386459518, 0.9986984686341231],  
[23.06781378216937, 113.34201710406913, 1.0328437857808297],  
[23.03617280481243, 113.34417150957852, 0.9485877592584417],  
[23.1458776298731, 113.37550386091327, 1.0138418763405146],  
[23.1298319124015, 113.32211853247115, 0.9584238834911811],  
[23.06618384924404, 113.1840113196497, 1.1002199282375327],  
[23.05928269870583, 113.31012935616161, 0.9758915125782275],  
[23.073494284809, 113.26217409986687, 0.9838915982295962],  
[23.078787238754064, 113.26146865730784, 0.9680667685124081],  
[23.10626428089576, 113.23983719610032, 0.9935165600423754],  
[23.082647996953735, 113.308209656826, 0.965444915621199],  
[23.10123192857074, 113.33730147248562, 1.129757863707711],

[23.04795512117888, 113.32913020104714, 1.003476636674064],  
[23.11057886697128, 113.4271198055599, 0.9967332536172089],  
[23.06117462823625, 113.1870854826703, 1.044796739723515],  
[23.052049673249314, 113.32336552803926, 0.9433316011860172],  
[23.092545236891564, 113.39011186348878, 0.9863813717996438],  
[23.124719163520435, 113.2462614664115, 1.022928402214007],  
[23.023084338403375, 113.26946832128952, 1.0362699616454099],  
[23.077580441388186, 113.27253666607423, 0.9837941157446796],  
[23.062890758168997, 113.36763215916993, 0.9890372151314588],  
[23.104786849333387, 113.20978417600725, 1.0478071273897254],  
[23.114018249625932, 113.25134029764436, 0.9747826065417896],  
[23.153550432573386, 113.21794829404622, 0.9636764217168993],  
[23.045360725144544, 113.37187084265922, 1.0263292074909873],  
[23.04842621155067, 113.38470546997445, 0.9211024234734683],  
[22.981004845735384, 113.34405638395721, 0.9202682577348917],  
[23.087771977063532, 113.3227173780349, 1.0136750501679086],  
[22.985984637096774, 113.30347140582688, 1.0669938980296503],  
[23.050709843770502, 113.35887477226288, 1.02573719754271],  
[22.99742354171756, 113.24888218591104, 0.9504541072600879],  
[23.05023101311708, 113.37683191834329, 1.0479384919392547],  
[23.077204786163, 113.29512751595561, 1.0286484183562605],  
[22.969160848071894, 113.33886443147135, 0.9276116139548678],  
[23.07096926789701, 113.29140424465719, 0.9879327706259524],  
[23.079665285527327, 113.33353340890324, 1.1255368063283484],  
[23.034212275934664, 113.23035225634703, 1.0181725018603602],  
[23.113186152632373, 113.27903339473215, 1.0431089008628824],  
[23.01040294763731, 113.376599829609, 0.973446870371315],  
[23.064284443604908, 113.27975522644063, 1.0293959739538052],  
[23.171650923764687, 113.31444346388845, 0.9949925578913307],  
[23.007602118667847, 113.22430437405451, 1.057509012413103],  
[23.07903579319951, 113.26999200112336, 1.1139912753640133],  
[23.114486758176113, 113.12956197321343, 0.991093562220511],

[23.132626920236408, 113.25896646702371, 1.0115296312068003],  
[23.069011842770095, 113.29593823135492, 1.0284655783407466],  
[23.055037906881083, 113.33453502940509, 0.9339961143041128],  
[23.096198994421272, 113.33987068178011, 0.9656040715007674],  
[23.003605723643055, 113.36536639010548, 0.9550579592802125],  
[22.97709721866362, 113.30188341391961, 1.0023084610162543],  
[23.172023636774703, 113.32397024317054, 1.0423898906684972],  
[23.05130137437062, 113.33179687128145, 0.9711534620666442],  
[23.103178951354266, 113.28099687999223, 1.0138104363486076],  
[23.11716812946778, 113.3223397644357, 0.9253814715723656],  
[23.147678969874594, 113.26430415487924, 0.910272688919386],  
[23.105772870624897, 113.27330393757747, 0.9592355319781251],  
[23.040658092751706, 113.276122185894, 1.0532973867324158],  
[23.020549688806398, 113.34614126627224, 0.9798801434221969],  
[23.16892821315353, 113.30843415856708, 0.9966871351606071],  
[23.131013837480403, 113.30613252257513, 1.0916744033777226],  
[23.14848371965029, 113.35901316590264, 1.0481371367225172],  
[23.168109777378152, 113.32530231844041, 1.0639136615545666],  
[23.104891393044248, 113.2467825705774, 1.0383617181697853],  
[23.040166705705083, 113.16162576546051, 0.9717354318318634],  
[23.06063419390737, 113.33796831285375, 0.9738527183327209],  
[23.0299233728093, 113.30680414009801, 0.9920796128258713],  
[23.102123496530478, 113.20536059492618, 0.9671166918987479],  
[23.05007677019235, 113.36109629139268, 1.0034781655933736],  
[23.110615328951056, 113.34031091240281, 1.0436867714054057],  
[23.063493394175413, 113.38046956768963, 0.9411821497616826],  
[23.036581327271097, 113.29690560025129, 0.9107429049876126],  
[23.038392351904587, 113.32248579483938, 0.931044160477816],  
[23.102190941950134, 113.2609104006009, 1.005136804097656],  
[23.1341250673337, 113.26523704926888, 0.9687817844978972],  
[23.167180637766545, 113.35914723035545, 1.0162737339381747],  
[23.083677766772404, 113.30681337071519, 0.9655823335620674],

[23.175136817316684, 113.19189359501969, 1.0471277217801767],  
[23.1492107608909, 113.44210183575827, 1.0301354492223733],  
[23.127186171568624, 113.30593923497145, 1.0280133659885327],  
[23.033934060950056, 113.25968864517034, 0.9455019836596257],  
[23.144665101590146, 113.32049001835182, 1.0095401422061794],  
[23.033907688282518, 113.34924501962671, 0.9527465100546084],  
[22.982492332603798, 113.32713527512823, 0.9249915866485441],  
[23.103679023992267, 113.29136881108371, 0.9865558276660872],  
[23.04382898418947, 113.34558598697292, 0.9761868655546372],  
[23.09541912886149, 113.26737295498934, 1.038372349810079],  
[23.133578422328558, 113.2789178147626, 0.9815678041713445],  
[23.137297964465656, 113.28922095283336, 0.9372065395239505],  
[23.171181050822984, 113.37956900974099, 1.0890442885068372],  
[23.205473377766886, 113.22507707219653, 1.027814317290653],  
[23.109384961551115, 113.33525830688913, 0.9840579128199375],  
[23.04273709056374, 113.33023167722227, 0.9284830627815504],  
[23.123747222217098, 113.22151373781539, 0.9938482047406878],  
[23.080453493522132, 113.25941777907177, 1.0030941149751162],  
[23.082607634200734, 113.25199585137314, 0.9025227004427396],  
[23.037229196607385, 113.29354365306872, 0.9493449971738958],  
[23.111686618621526, 113.4188488889875, 0.9679566969587095],  
[23.08368646811695, 113.29536095653303, 1.0537445372183525],  
[23.03449307912378, 113.30491823690242, 0.977923142848577],  
[22.998420297984705, 113.4201682538007, 0.8815339810421324],  
[23.080917669082503, 113.35129289842445, 1.0197517587869973],  
[23.11482063874529, 113.40915895042686, 0.9461470785747483],  
[23.090328957611145, 113.32348035671063, 1.037866286006159],  
[23.024919059823144, 113.21566393889339, 0.92059232648922],  
[23.11066331082251, 113.32689642933225, 0.9789650400454358],  
[23.075105588097852, 113.27043109124348, 1.0104678853073994],  
[23.06832391460701, 113.32425146760727, 0.9979330854351578],  
[23.13060978915038, 113.34583015432841, 0.9438880321913511],

[23.062444101491927, 113.36329255241412, 0.9857168512673958],  
[23.01715970979868, 113.34486795965574, 0.9396929893350328],  
[22.99258675859923, 113.28296997666338, 0.9134284388330829],  
[23.044958970789985, 113.25759845367584, 0.9440999133477848],  
[23.12792063927098, 113.22027378939943, 0.9719477821953935],  
[23.058731091146914, 113.38111896052935, 0.98553700125542],  
[23.138650724662842, 113.36398398256469, 1.0020789606280478],  
[23.073932367858315, 113.24337191417074, 1.005833617098707],  
[23.12413331271888, 113.35009835708352, 1.0609536685996555],  
[23.06113848503462, 113.28044949706566, 0.9698245744039555],  
[23.076074513029813, 113.2944823481715, 0.9125046692961192],  
[23.054729425462934, 113.3173596569306, 1.0562035532928036],  
[23.13241763531783, 113.26745036287632, 0.9897997443571512],  
[23.036160887718385, 113.33445699208183, 1.0649388685737],  
[23.105538025975665, 113.26230608223963, 1.0544525447651114],  
[23.193746228321803, 113.33321568350172, 1.0110967306532803],  
[23.05261489695624, 113.34286870541185, 1.0065826912760452],  
[23.087026039190597, 113.30816138359104, 0.9892350993807316],  
[23.085789155891767, 113.25965442837615, 0.9737294321608534],  
[23.061689142955476, 113.36729753503141, 1.0292209732711293],  
[23.102335416841647, 113.30299963325102, 0.9249983969836697],  
[23.06941056471305, 113.26101296617104, 1.0888640438972836],  
[23.05325394808547, 113.36692529114484, 1.0391889285797389],  
[23.112604859402875, 113.2325176729842, 0.8853144688706669],  
[23.048108831694538, 113.36513376941906, 1.0255553056677393],  
[23.047472664654315, 113.25282242998384, 1.09044728363618],  
[22.964981579734918, 113.30456825549108, 0.9460953778071548],  
[23.15937445868103, 113.35809310361283, 0.9733278209284137],  
[23.009000179362978, 113.28253406265881, 1.0326927147576812],  
[23.131638450677762, 113.25648212899264, 0.9495265721925205],  
[22.997272868240877, 113.25246082123445, 1.1095879427158188],  
[23.17425496606531, 113.37475031693936, 1.0260024308492381],

[23.047037146605142, 113.32168068234373, 0.9985534845248806],  
[23.044573642663554, 113.3002333400525, 0.9567043240003137],  
[23.016253534427598, 113.27155263810711, 0.9240905368947935],  
[23.071561793358434, 113.27246812206441, 1.0146094757216226],  
[23.10089962927346, 113.34380591516414, 0.9870438801374537],  
[23.122700358916344, 113.28923755693053, 0.981689092385444],  
[23.200754882929566, 113.23907569011978, 1.0736132143541073],  
[23.05671729294272, 113.24642174272074, 0.9692499528211079],  
[23.167807593499635, 113.29851390138822, 1.0071695327149592],  
[23.19136111254222, 113.30882594653231, 0.9125699229562564],  
[23.046133447345536, 113.26348105252589, 1.03978639515402],  
[23.097530233575515, 113.31678261747464, 0.9091412181823305],  
[23.158675513862832, 113.2615309240117, 1.0299487778761662],  
[23.185145839082082, 113.34828191107871, 1.0025543147642881],  
[23.083570028900922, 113.32150832429629, 1.0389021268202652],  
[23.156604860217367, 113.3162292559205, 1.0228526696579607],  
[23.096316578215287, 113.27016004829684, 0.9505642196076789],  
[23.025555850233598, 113.30214536268608, 1.0078529572945947],  
[23.062132859741347, 113.30445163105126, 0.9969475879579656],  
[23.03153547786772, 113.32888725908839, 1.0888461193400105],  
[23.082141900890342, 113.25891160644882, 0.955259765104159],  
[23.143349132065488, 113.242494827586, 0.9722884190071142],  
[23.087927341444058, 113.25519751013817, 1.0012227462315],  
[23.115135527124963, 113.29294594556991, 0.9845582022259945],  
[23.221179964722534, 113.3260404961154, 0.9534455353958193],  
[23.037307893990537, 113.33594319927164, 1.0164118946833003],  
[22.999228959890033, 113.24970715913389, 0.9589220366117504],  
[23.096801025800882, 113.33199633866889, 1.0770371514698034],  
[23.012642977079754, 113.31347590510333, 0.9806021725707501],  
[23.105027615653626, 113.25852398480747, 1.0013523119866372],  
[23.065268830752185, 113.28842446685438, 1.0028081790139378],  
[23.017506270583866, 113.22491653765282, 0.9944864864541447],

[23.12629992454365, 113.37958220773633, 1.100685226484174],  
[23.126055945805724, 113.28401858381856, 0.9486954539886417],  
[23.057901547697778, 113.28648228878693, 1.0391973752529808],  
[23.083635136684972, 113.3856954646631, 1.023335494180312],  
[23.106299851195743, 113.35951305057117, 1.0302995529608698],  
[23.096894140300634, 113.24120418732883, 0.9961796101627634],  
[23.142976882739866, 113.35503749152537, 0.9084820811782881],  
[23.06715875993821, 113.26409727061159, 1.0049097499701758],  
[23.10243444560605, 113.33849679912996, 1.057151442241974],  
[23.134683177792613, 113.2307063641154, 1.1305059610778272],  
[23.10919096962813, 113.36936740118813, 0.9371372444604422],  
[23.065299291835842, 113.36137768639006, 0.9813025219542669],  
[23.103077926922897, 113.21470289176665, 0.9787826944062553],  
[23.11193358743528, 113.25444093940071, 1.0259783994161253],  
[23.107091104104892, 113.29697053174657, 0.9459933496786161],  
[23.09066164435428, 113.34389972389853, 1.000195849170243],  
[23.008421107753463, 113.2455672346012, 1.0049417644408518],  
[23.062317380800778, 113.30664066812115, 1.0673273326550967],  
[23.073789624105586, 113.30980088686773, 0.955515988226136],  
[23.13182146001401, 113.3719943767497, 1.0273175324681623],  
[23.079624306906567, 113.25209601362968, 0.9701390813946531],  
[23.04024156804249, 113.23588257560213, 1.0543141198897426],  
[23.132801163346954, 113.33248803940424, 0.9822636866450936],  
[23.091146672562882, 113.31807210595011, 1.0870583428927847],  
[23.11779544895673, 113.26879578218016, 0.9015952114800665],  
[23.129750244312568, 113.30546749688361, 1.0773147162456953],  
[23.045895642418674, 113.35038822875588, 0.9079177149086665],  
[23.047365655385324, 113.28427890230681, 1.0460633743681738],  
[23.066444217155958, 113.2356766566315, 1.0379761377716792],  
[23.02945551767962, 113.28140420937177, 0.9189601933999842],  
[23.087559170199537, 113.31509792730053, 0.9751871810170482],  
[23.066930940600745, 113.27258025336806, 0.9707835515964236],

```
[23.127008142124485, 113.34711601904912, 0.9945290058488773],
[23.00988761104292, 113.25435234197204, 1.0518326649244096],
[23.189407458899797, 113.34642333613476, 1.0259994701721056],
[23.067016086343415, 113.245147780456, 1.0835103203591014]]
```

```
HeatMap (热力图)
from folium.plugins import HeatMap

创建地图 (使用默认 OpenStreetMap 底图)
m = folium.Map([23.087, 113.3], zoom_start=12)

添加热力图层
HeatMap(data).add_to(m)

保存为 HTML 文件
m.save('Heatmap.html')
print(" 热力图已保存到 Heatmap.html")

显示地图
m
```

热力图已保存到 Heatmap.html

<folium.folium.Map at 0x11b987c50>

#### Folium 底图选择

新版本 folium 推荐使用以下方式指定底图:



```
默认 OpenStreetMap (推荐)
folium.Map(location=[lat, lon])

使用其他底图提供商
folium.Map(location=[lat, lon], tiles='OpenStreetMap')
folium.Map(location=[lat, lon], tiles='CartoDB positron')
folium.Map(location=[lat, lon], tiles='CartoDB dark_matter')
```

注意: Stamen 底图已不再免费提供, 建议使用 OpenStreetMap 或 CartoDB。

## 9 网络爬虫

[点击下载本章节代码](#)

### 9.1 网页基础知识

#### 9.1.1 核心概念

##### 1. 什么是网站？

- 网站是通过互联网提供的一组相互链接的网页。
- 网站的组成部分：
  - 前端：用户可见的部分，包括网页结构（HTML）、样式（CSS）和交互功能（JavaScript）。
  - 后端：运行在服务器上的部分，负责逻辑处理、数据存储和提供 API 接口。

##### 2. 网络如何工作

- 域名和 IP 地址：
  - 域名（如 `example.com`）是方便人类记忆的网络地址，通过 DNS（域名系统）映射到具体的 IP 地址。
- HTTP 和 HTTPS 协议：
  - 超文本传输协议（HTTP）定义了客户端和服务端之间的通信规则。
  - HTTPS 是加密版本，确保数据传输的安全性。
- 客户端请求和服务端响应：
  - 请求包含方法（如 GET 或 POST）、URL、头部信息等。
  - 响应包含状态码（如 200 表示成功）、内容类型（如 HTML）和具体的数据。

##### 3. 基本网页技术

- HTML（超文本标记语言）：

- 定义网页的结构，包括标题、段落、链接、图片等。
- 示例：

```
<html>
<head>
 <title>示例网页</title>
</head>
<body>
 <h1>欢迎来到示例网页</h1>
 <p>这是一个段落。</p>
</body>
</html>
```

- **CSS (层叠样式表):**

- 控制网页的外观样式（颜色、字体、布局等）。
- 示例：

```
<style>
 h1 {
 color: red;
 }
 p {
 font-size: 30px;
 }
</style>
```

- **JavaScript:**

- 为网页添加交互性（如按钮点击、动态加载内容）。
- 示例：

```
<button id="myButton">Click Me</button>
<p id="message"></p>
<script>
 // Get references to the button and the paragraph
 const button = document.getElementById("myButton");
```

```

 const message = document.getElementById("message");

 // Add an event listener to the button
 button.addEventListener("click", () => {
 // Change the text content of the paragraph
 message.textContent = "You clicked the button!";
 });
</script>

```

#### 4. 客户端-服务器模型

- 客户端：
  - 发送请求到服务器。请求 `requests`
  - 示例：浏览器、Python 爬虫脚本。
- 服务器：
  - 接收请求并返回响应。响应 `response`
  - 示例：托管网页的服务器、提供 API 服务的服务器。
  - 响应 `response`
  - 响应的内容类型：
    - \* text, 如 HTML、CSS、JavaScript
    - \* image, 如 JPEG、PNG
    - \* pdf, 如 PDF 文档
    - \* json, 书写格式类似于 python 的字典 dict
    - \* xml, 类似于 html 的标记语言

#### ### HTTP 状态码简介

- **200**: 请求成功。
- **404**: 资源未找到。
- **500**: 服务器内部错误。

#### ### 浏览器开发者工具

- **检查网页元素**: 右键点击网页，选择“检查”可以打开开发者工具。
- **Network 标签**: 查看页面加载过程中所有请求和响应。

- **Elements** 标签：查看网页的 HTML 和 CSS 结构。

### ### 演示

1. 打开浏览器并访问一个示例网站，例如 <https://www.jnu.edu.cn>。
2. 使用开发者工具查看：
  - HTML 元素结构。
  - 页面中加载的 CSS 和 JavaScript 文件。
  - 通过 Network 标签查看页面加载时的网络请求。
  - 豆瓣读书 <https://book.douban.com/tag/小说>

## 9.2 爬虫基础

安装所需的库:

```
%pip install requests httpx parsel playwright --upgrade
```

安装 Playwright 浏览器（在终端运行）：

```
playwright install chromium
```

### 9.2.1 分析网址规律

1. 网址包含信息
2. 是否需要 load javascript
3. response 是否为 json 数据
4. 是否需要用模拟浏览器

### 9.2.2 requests 库

找到网页 url 规律后，我们需要将这些 url 对应的网页数据下载下来，这里就用到[requests 库文档链接](#)。

**requests** 两种访问方法, 两者都返回 Response 对象：

requests 常用函数	参数解读
<b>requests.get(url, params, verify)</b>	发起 <b>get</b> 访问，返回 <b>Response</b> 对象；除非需要传参，否则不需要用 <b>params</b> 和 <b>verify</b> 参数
<b>requests.post(url, data)</b>	发起 <b>post</b> 访问，返回 <b>Response</b> 对象；除非需要传参，否则不需要用 <b>data</b> 参数

```
import requests

url = "http://www.ruanyifeng.com/blog/archives.html"

try:
 r = requests.get(url)
 print(type(r))
 print(r.status_code)
except Exception as e:
 print(e)
```

```
<class 'requests.models.Response'>
200
```

```
import requests

headers = {'User-Agent':
 'Mozilla/5.0 (Windows NT 10.0; Win64; x64) AppleWebKit/537.36
 ↪ (KHTML, like Gecko) Chrome/106.0.0.0 Safari/537.36'
}

url = 'https://book.douban.com/tag/小说?start=20&type=T'

try:
 r = requests.get(url, headers = headers)
```

```

print(type(r))
print(r.status_code)
except Exception as e:
 print(e)

```

```

<class 'requests.models.Response'>
200

```

注意 **Response** 后面带有的状态码：- 2 开头表示访问正常 - 4 开头，比如 403 表示爬虫被网站封锁 - 5 开头表示服务器出问题

### 9.2.3 Response 响应对象

Response 对象的方法	作用
<b>Response.json()</b>	获得 json 格式网页数据
<b>Response.text</b>	获得 html 网页数据
<b>Response.content</b>	获得网页二进制文件数据，常常用该方法爬取图片、视频等数据
<b>Response.encoding</b>	更改网页数据的编码方式。除非使用 <b>Response.text</b> 得到的 html 中文本是乱码的，否则一般不用 <b>Response.encoding</b>
<b>Response.status_code</b>	查看当前访问的状态码，200 表示访问正常，4 开头的状态码表示访问出问题，5 开头的状态码表示服务器出问题

以上三种方法，最常用的是 **text** 和 **json** 方法，分别对应于 **html** 网页数据和 **json** 网页数据

```

r.status_code

```

```

200

```

```
print(r.text[:1000])
```

```
<!DOCTYPE html>
```

```
<html lang="zh-cmn-Hans" class="ua-windows ua-webkit book-new-nav">
```

```
<head>
```

```
 <meta http-equiv="Content-Type" content="text/html; charset=utf-8">
```

```
 <title>
```

```
 豆瓣图书标签: 小说
```

```
</title>
```

```
<script>!function(e){var o=function(o,n,t){var c,i,r=new Date;n=n||30,t=t||"/",r.setT
```

```
with open("sample.html", "w+", encoding=r.encoding) as file:
```

```
 file.write(r.text)
```

```
from pathlib import Path
```

```
Path("sample.html").write_text(r.text)
```

```
54094
```

```
r.encoding
```

```
'utf-8'
```

```
import requests
```

```
r = requests.get('http://httpbin.org/get')
```

```
print(r.text)
```

```
{
```



```

"args": {},
"headers": {
 "Accept": "/*/*",
 "Accept-Encoding": "gzip, deflate",
 "Host": "httpbin.org",
 "User-Agent": "python-requests/2.32.5",
 "X-Amzn-Trace-Id": "Root=1-69071ea9-404f98341e9f9d7a2ab0c878"
},
"origin": "129.227.235.26",
"url": "http://httpbin.org/get"
}

```

```

x = r.json()
x

```

```

{'args': {},
 'headers': {'Accept': '/*/*',
 'Accept-Encoding': 'gzip, deflate',
 'Host': 'httpbin.org',
 'User-Agent': 'python-requests/2.32.5',
 'X-Amzn-Trace-Id': 'Root=1-69071ea9-404f98341e9f9d7a2ab0c878'},
 'origin': '129.227.235.26',
 'url': 'http://httpbin.org/get'}

```

```

x['url']

```

```

'http://httpbin.org/get'

```

## 9.2.4 巨潮资讯网

科创板的公告：

<http://www.cninfo.com.cn/new/commonUrl?url=disclosure/list/notice#sseKcp>

```

import requests
import pandas as pd

url = "http://www.cninfo.com.cn/new/hisAnnouncement/query"

headers = {
 'content-type': 'application/json',
 'Accept-Encoding': 'gzip, deflate',
 'User-Agent': 'Mozilla/5.0 (Windows NT 6.1; WOW64; rv:53.0)
 ↪ Gecko/20100101 Firefox/53.0'
}

```

```

params = {'column': 'szse',
 'pageNum': 1,
 'plate': 'sz',
 'searchkey': '辞职;', # key1 or key2
 'pageSize': 30,
 'seDate': '2023-10-01 ~ 2023-10-22',
 'tabName': 'fulltext'}

r = requests.post(url, params=params, headers=headers)

```

```

r.json()

```

```

{'classifiedAnnouncements': None,
 'totalSecurities': 0,
 'totalAnnouncement': 95,
 'totalRecordNum': 95,
 'announcements': [{'id': None,
 'secCode': '002939',
 'secName': '长城证券',
 'orgId': 'qsgn0000030',
 'announcementId': '1218108610',

```

'announcementTitle': '关于公司董事辞职的公告',  
 'announcementTime': 1697817600000,  
 'adjunctUrl': 'finalpage/2023-10-21/1218108610.PDF',  
 'adjunctSize': 211,  
 'adjunctType': 'PDF',  
 'storageTime': None,  
 'columnId': '09020202||250101||251302',  
 'pageColumn': 'SZZB',  
 'announcementType': '01010503||010112||012303',  
 'associateAnnouncement': None,  
 'important': None,  
 'batchNum': None,  
 'announcementContent': '',  
 'orgName': None,  
 'tileSecName': '长城证券',  
 'shortTitle': '关于公司董事辞职的公告',  
 'announcementTypeName': None,  
 'secNameList': None},  
 {'id': None,  
 'secCode': '300801',  
 'secName': '泰和科技',  
 'orgId': '9900031706',  
 'announcementId': '1218108177',  
 'announcementTitle': '关于独立董事辞职暨补选独立董事的公告',  
 'announcementTime': 1697817600000,  
 'adjunctUrl': 'finalpage/2023-10-21/1218108177.PDF',  
 'adjunctSize': 210,  
 'adjunctType': 'PDF',  
 'storageTime': None,  
 'columnId': '09020202||160203||250301||251302',  
 'pageColumn': 'SZCY',  
 'announcementType': '01010503||010112||010115||012303',

```

'associateAnnouncement': None,
'important': None,
'batchNum': None,
'announcementContent': '',
'orgName': None,
'tileSecName': '泰和科技',
'shortTitle': '关于独立董事辞职暨补选独立董事的公告',
'announcementTypeName': None,
'secNameList': None},
{'id': None,
'secCode': '000420',
'secName': '吉林化纤',
'orgId': 'gssz0000420',
'announcementId': '1218108160',
'announcementTitle': '关于董事、董事会秘书辞职的公告',
'announcementTime': 1697817600000,
'adjunctUrl': 'finalpage/2023-10-21/1218108160.PDF',
'adjunctSize': 149,
'adjunctType': 'PDF',
'storageTime': None,
'columnId': '09020202||250101||251302',
'pageColumn': 'SZZB',
'announcementType': '01010503||010112||012303',
'associateAnnouncement': None,
'important': None,
'batchNum': None,
'announcementContent': '',
'orgName': None,
'tileSecName': '吉林化纤',
'shortTitle': '关于董事、董事会秘书辞职的公告',
'announcementTypeName': None,
'secNameList': None},

```

```

{'id': None,
 'secCode': '001965',
 'secName': '招商公路',
 'orgId': 'GD008065',
 'announcementId': '1218108158',
 'announcementTitle': '关于高级管理人员辞职的公告',
 'announcementTime': 1697817600000,
 'adjunctUrl': 'finalpage/2023-10-21/1218108158.PDF',
 'adjunctSize': 105,
 'adjunctType': 'PDF',
 'storageTime': None,
 'columnId': '09020202||250101||251302',
 'pageColumn': 'SZZB',
 'announcementType': '01010503||010112||012303',
 'associateAnnouncement': None,
 'important': None,
 'batchNum': None,
 'announcementContent': '',
 'orgName': None,
 'tileSecName': '招商公路',
 'shortTitle': '关于高级管理人员辞职的公告',
 'announcementTypeName': None,
 'secNameList': None},
{'id': None,
 'secCode': '002075',
 'secName': '沙钢股份',
 'orgId': '9900001101',
 'announcementId': '1218107902',
 'announcementTitle': '关于职工代表监事辞职及补选的公告',
 'announcementTime': 1697817600000,
 'adjunctUrl': 'finalpage/2023-10-21/1218107902.PDF',
 'adjunctSize': 77,

```

```

'adjunctType': 'PDF',
'storageTime': None,
'columnId': '09020202||250101||251302',
'pageColumn': 'SZZB',
'announcementType': '01010503||010112||012303',
'associateAnnouncement': None,
'important': None,
'batchNum': None,
'announcementContent': '',
'orgName': None,
'titleSecName': '沙钢股份',
'shortTitle': '关于职工代表监事辞职及补选的公告',
'announcementTypeName': None,
'secNameList': None},
{'id': None,
'secCode': '000532',
'secName': '华金资本',
'orgId': 'gssz0000532',
'announcementId': '1218106993',
'announcementTitle': '关于公司董事辞职的公告',
'announcementTime': 1697817600000,
'adjunctUrl': 'finalpage/2023-10-21/1218106993.PDF',
'adjunctSize': 119,
'adjunctType': 'PDF',
'storageTime': None,
'columnId': '09020202||250101||251302',
'pageColumn': 'SZZB',
'announcementType': '01010503||010112||012303',
'associateAnnouncement': None,
'important': None,
'batchNum': None,
'announcementContent': '',

```

```

'orgName': None,
'tileSecName': '华金资本',
'shortTitle': '关于公司董事辞职的公告',
'announcementTypeName': None,
'secNameList': None},
{'id': None,
'secCode': '300053',
'secName': '航宇微',
'orgId': '9900010151',
'announcementId': '1218109594',
'announcementTitle': '关于副总经理辞职的公告',
'announcementTime': 1697798665000,
'adjunctUrl': 'finalpage/2023-10-20/1218109594.PDF',
'adjunctSize': 99,
'adjunctType': 'PDF',
'storageTime': None,
'columnId': '09020202||160203||250301||251302',
'pageColumn': 'SZCY',
'announcementType': '01010503||010112||010115||012303',
'associateAnnouncement': None,
'important': None,
'batchNum': None,
'announcementContent': '',
'orgName': None,
'tileSecName': '航宇微',
'shortTitle': '关于副总经理辞职的公告',
'announcementTypeName': None,
'secNameList': None},
{'id': None,
'secCode': '300650',
'secName': '太龙股份',
'orgId': '9900031733',

```

```

'announcementId': '1218109108',
'announcementTitle': '关于副总经理辞职的公告',
'announcementTime': 1697796629000,
'adjunctUrl': 'finalpage/2023-10-20/1218109108.PDF',
'adjunctSize': 62,
'adjunctType': 'PDF',
'storageTime': None,
'columnId': '09020202||160203||250301||251302',
'pageColumn': 'SZCY',
'announcementType': '01010503||010112||010115||012303',
'associateAnnouncement': None,
'important': None,
'batchNum': None,
'announcementContent': '',
'orgName': None,
'tileSecName': '太龙股份',
'shortTitle': '关于副总经理辞职的公告',
'announcementTypeName': None,
'secNameList': None},
{'id': None,
'secCode': '002761',
'secName': '浙江建投',
'orgId': '9900023671',
'announcementId': '1218108414',
'announcementTitle': '中国国际金融股份有限公司关于浙江省建设投资集团股份有限公司董
'announcementTime': 1697793563000,
'adjunctUrl': 'finalpage/2023-10-20/1218108414.PDF',
'adjunctSize': 315,
'adjunctType': 'PDF',
'storageTime': None,
'columnId': '09020202||250101||251302',
'pageColumn': 'SZZB',

```



'announcementType': '01010501||010112||013999',  
 'associateAnnouncement': None,  
 'important': None,  
 'batchNum': None,  
 'announcementContent': '',  
 'orgName': None,  
 'tileSecName': '浙江建投',  
 'shortTitle': '中国国际金融股份有限公司关于浙江省建设投资集团股份有限公司董事长辞职暨补选',  
 'announcementTypeName': None,  
 'secNameList': None},  
 {'id': None,  
 'secCode': '002761',  
 'secName': '浙江建投',  
 'orgId': '9900023671',  
 'announcementId': '1218108413',  
 'announcementTitle': '招商证券股份有限公司关于浙江省建设投资集团股份有限公司董事长辞职暨补选',  
 'announcementTime': 1697793434000,  
 'adjunctUrl': 'finalpage/2023-10-20/1218108413.PDF',  
 'adjunctSize': 397,  
 'adjunctType': 'PDF',  
 'storageTime': None,  
 'columnId': '09020202||250101||251302',  
 'pageColumn': 'SZZB',  
 'announcementType': '01010501||010112||013999',  
 'associateAnnouncement': None,  
 'important': None,  
 'batchNum': None,  
 'announcementContent': '',  
 'orgName': None,  
 'tileSecName': '浙江建投',  
 'shortTitle': '招商证券股份有限公司关于浙江省建设投资集团股份有限公司董事长辞职暨补选',  
 'announcementTypeName': None,

```

 'secNameList': None},
{'id': None,
 'secCode': '000584',
 'secName': 'ST工智',
 'orgId': 'gssz0000584',
 'announcementId': '1218097684',
 'announcementTitle': '关于公司监事辞职暨选举非职工监事的公告',
 'announcementTime': 1697731200000,
 'adjunctUrl': 'finalpage/2023-10-20/1218097684.PDF',
 'adjunctSize': 221,
 'adjunctType': 'PDF',
 'storageTime': None,
 'columnId': '09020202||250101||251302',
 'pageColumn': 'SZZB',
 'announcementType': '01010503||010112||012303',
 'associateAnnouncement': None,
 'important': None,
 'batchNum': None,
 'announcementContent': '',
 'orgName': None,
 'tileSecName': 'ST工智',
 'shortTitle': '关于公司监事辞职暨选举非职工监事的公告',
 'announcementTypeName': None,
 'secNameList': None},
{'id': None,
 'secCode': '000826',
 'secName': '启迪环境',
 'orgId': 'gssz0000826',
 'announcementId': '1218097065',
 'announcementTitle': '关于公司高级管理人员辞职的公告',
 'announcementTime': 1697731200000,
 'adjunctUrl': 'finalpage/2023-10-20/1218097065.PDF',

```

```

'adjunctSize': 163,
'adjunctType': 'PDF',
'storageTime': None,
'columnId': '09020202||250101||251302',
'pageColumn': 'SZZB',
'announcementType': '01010503||010112||012303',
'associateAnnouncement': None,
'important': None,
'batchNum': None,
'announcementContent': '',
'orgName': None,
'titleSecName': '启迪环境',
'shortTitle': '关于公司高级管理人员辞职的公告',
'announcementTypeName': None,
'secNameList': None},
{'id': None,
'secCode': '000030',
'secName': '富奥股份',
'orgId': 'gssz0000030',
'announcementId': '1218095768',
'announcementTitle': '关于公司董事辞职的公告',
'announcementTime': 1697731200000,
'adjunctUrl': 'finalpage/2023-10-20/1218095768.PDF',
'adjunctSize': 56,
'adjunctType': 'PDF',
'storageTime': None,
'columnId': '09020202||250101||251302',
'pageColumn': 'SZZB',
'announcementType': '01010503||010112||012303',
'associateAnnouncement': None,
'important': None,
'batchNum': None,

```

```

'announcementContent': '',
'orgName': None,
'tileSecName': '富奥股份',
'shortTitle': '关于公司董事辞职的公告',
'announcementTypeName': None,
'secNameList': None},
{'id': None,
'secCode': '000158',
'secName': '常山北明',
'orgId': 'gssz0000158',
'announcementId': '1218095021',
'announcementTitle': '关于职工代表监事辞职及补选职工代表监事的公告',
'announcementTime': 1697731200000,
'adjunctUrl': 'finalpage/2023-10-20/1218095021.PDF',
'adjunctSize': 165,
'adjunctType': 'PDF',
'storageTime': None,
'columnId': '09020202||250101||251302',
'pageColumn': 'SZZB',
'announcementType': '01010503||010112||012303',
'associateAnnouncement': None,
'important': None,
'batchNum': None,
'announcementContent': '',
'orgName': None,
'tileSecName': '常山北明',
'shortTitle': '关于职工代表监事辞职及补选职工代表监事的公告',
'announcementTypeName': None,
'secNameList': None},
{'id': None,
'secCode': '002238',
'secName': '天威视讯',

```

'orgId': '9900004647',  
 'announcementId': '1218094640',  
 'announcementTitle': '天威视讯关于高级管理人员辞职的公告',  
 'announcementTime': 1697731200000,  
 'adjunctUrl': 'finalpage/2023-10-20/1218094640.PDF',  
 'adjunctSize': 152,  
 'adjunctType': 'PDF',  
 'storageTime': None,  
 'columnId': '09020202||250101||251302',  
 'pageColumn': 'SZZB',  
 'announcementType': '01010503||010112||012303',  
 'associateAnnouncement': None,  
 'important': None,  
 'batchNum': None,  
 'announcementContent': '',  
 'orgName': None,  
 'tileSecName': '天威视讯',  
 'shortTitle': '天威视讯关于高级管理人员辞职的公告',  
 'announcementTypeName': None,  
 'secNameList': None},  
 {'id': None,  
 'secCode': '300686',  
 'secName': '智动力',  
 'orgId': '99000029630',  
 'announcementId': '1218093982',  
 'announcementTitle': '2023-039 智动力：关于独立董事辞职的公告',  
 'announcementTime': 1697731200000,  
 'adjunctUrl': 'finalpage/2023-10-20/1218093982.PDF',  
 'adjunctSize': 68,  
 'adjunctType': 'PDF',  
 'storageTime': None,  
 'columnId': '09020202||160203||250301||251302',

```

'pageColumn': 'SZCY',
'announcementType': '01010503||010112||010115||012303',
'associateAnnouncement': None,
'important': None,
'batchNum': None,
'announcementContent': '',
'orgName': None,
'tileSecName': '智动力',
'shortTitle': '2023-039 智动力：关于独立董事辞职的公告',
'announcementTypeName': None,
'secNameList': None},
{'id': None,
'secCode': '300513',
'secName': '恒实科技',
'orgId': '9900026672',
'announcementId': '1218093902',
'announcementTitle': '关于独立董事辞职及提名独立董事候选人、监事辞职及补选监事的公告',
'announcementTime': 1697731200000,
'adjunctUrl': 'finalpage/2023-10-20/1218093902.PDF',
'adjunctSize': 100,
'adjunctType': 'PDF',
'storageTime': None,
'columnId': '09020202||160203||250301||251302',
'pageColumn': 'SZCY',
'announcementType': '01010503||010112||010115||012303',
'associateAnnouncement': None,
'important': None,
'batchNum': None,
'announcementContent': '',
'orgName': None,
'tileSecName': '恒实科技',
'shortTitle': '关于独立董事辞职及提名独立董事候选人、监事辞职及补选监事的公告',

```

```

'announcementTypeName': None,
'secNameList': None},
{'id': None,
'secCode': '002818',
'secName': '富森美',
'orgId': '9900026774',
'announcementId': '1218093786',
'announcementTitle': '关于职工代表监事辞职及补选职工代表监事的公告',
'announcementTime': 1697731200000,
'adjunctUrl': 'finalpage/2023-10-20/1218093786.PDF',
'adjunctSize': 233,
'adjunctType': 'PDF',
'storageTime': None,
'columnId': '09020202||250101||251302',
'pageColumn': 'SZZB',
'announcementType': '01010503||010112||012303',
'associateAnnouncement': None,
'important': None,
'batchNum': None,
'announcementContent': '',
'orgName': None,
'tileSecName': '富森美',
'shortTitle': '关于职工代表监事辞职及补选职工代表监事的公告',
'announcementTypeName': None,
'secNameList': None},
{'id': None,
'secCode': '301370',
'secName': '国科恒泰',
'orgId': '9900035522',
'announcementId': '1218093153',
'announcementTitle': '关于监事辞职的公告',
'announcementTime': 1697709263000,

```

'adjunctUrl': 'finalpage/2023-10-19/1218093153.PDF',  
 'adjunctSize': 105,  
 'adjunctType': 'PDF',  
 'storageTime': None,  
 'columnId': '09020202||160203||250301||251302',  
 'pageColumn': 'SZCY',  
 'announcementType': '01010503||010112||010115||012303',  
 'associateAnnouncement': None,  
 'important': None,  
 'batchNum': None,  
 'announcementContent': '',  
 'orgName': None,  
 'tileSecName': '国科恒泰',  
 'shortTitle': '关于监事辞职的公告',  
 'announcementTypeName': None,  
 'secNameList': None},  
 {'id': None,  
 'secCode': '300337',  
 'secName': '银邦股份',  
 'orgId': '9900022204',  
 'announcementId': '1218092322',  
 'announcementTitle': '银邦股份关于独立董事辞职的公告',  
 'announcementTime': 1697707584000,  
 'adjunctUrl': 'finalpage/2023-10-19/1218092322.PDF',  
 'adjunctSize': 87,  
 'adjunctType': 'PDF',  
 'storageTime': None,  
 'columnId': '09020202||160203||250301||251302',  
 'pageColumn': 'SZCY',  
 'announcementType': '01010503||010112||010115||012303',  
 'associateAnnouncement': None,  
 'important': None,



```

'batchNum': None,
'announcementContent': '',
'orgName': None,
'titleSecName': '银邦股份',
'shortTitle': '银邦股份关于独立董事辞职的公告',
'announcementTypeName': None,
'secNameList': None},
{'id': None,
'secCode': '300849',
'secName': '锦盛新材',
'orgId': '9900035518',
'announcementId': '1218094124',
'announcementTitle': '关于公司非独立董事辞职的公告',
'announcementTime': 1697707223000,
'adjunctUrl': 'finalpage/2023-10-19/1218094124.PDF',
'adjunctSize': 107,
'adjunctType': 'PDF',
'storageTime': None,
'columnId': '09020202||160203||250301||251302',
'pageColumn': 'SZCY',
'announcementType': '01010503||010112||010115||012303',
'associateAnnouncement': None,
'important': None,
'batchNum': None,
'announcementContent': '',
'orgName': None,
'titleSecName': '锦盛新材',
'shortTitle': '关于公司非独立董事辞职的公告',
'announcementTypeName': None,
'secNameList': None},
{'id': None,
'secCode': '002761',

```

'secName': '浙江建投',  
 'orgId': '9900023671',  
 'announcementId': '1218078979',  
 'announcementTitle': '浙江省建设投资集团股份有限公司关于公司董事长辞职暨推举董事代  
 'announcementTime': 1697644800000,  
 'adjunctUrl': 'finalpage/2023-10-19/1218078979.PDF',  
 'adjunctSize': 139,  
 'adjunctType': 'PDF',  
 'storageTime': None,  
 'columnId': '09020202||250101||251302',  
 'pageColumn': 'SZZB',  
 'announcementType': '01010503||010112||012303',  
 'associateAnnouncement': None,  
 'important': None,  
 'batchNum': None,  
 'announcementContent': '',  
 'orgName': None,  
 'tileSecName': '浙江建投',  
 'shortTitle': '浙江省建设投资集团股份有限公司关于公司董事长辞职暨推举董事代行董事  
 'announcementTypeName': None,  
 'secNameList': None},  
 {'id': None,  
 'secCode': '001286',  
 'secName': '陕西能源',  
 'orgId': '9900048369',  
 'announcementId': '1218074786',  
 'announcementTitle': '陕西能源投资股份有限公司关于董事辞职的公告',  
 'announcementTime': 1697644800000,  
 'adjunctUrl': 'finalpage/2023-10-19/1218074786.PDF',  
 'adjunctSize': 150,  
 'adjunctType': 'PDF',  
 'storageTime': None,

```

'columnId': '09020202||250101||251302',
'pageColumn': 'SZZB',
'announcementType': '01010503||010112||012303',
'associateAnnouncement': None,
'important': None,
'batchNum': None,
'announcementContent': '',
'orgName': None,
'tileSecName': '陕西能源',
'shortTitle': '陕西能源投资股份有限公司关于董事辞职的公告',
'announcementTypeName': None,
'secNameList': None},
{'id': None,
'secCode': '300157',
'secName': '新锦动力',
'orgId': '9900015787',
'announcementId': '1218076867',
'announcementTitle': '关于公司董事辞职的公告',
'announcementTime': 1697622747000,
'adjunctUrl': 'finalpage/2023-10-18/1218076867.PDF',
'adjunctSize': 110,
'adjunctType': 'PDF',
'storageTime': None,
'columnId': '09020202||160203||250301||251302',
'pageColumn': 'SZCY',
'announcementType': '01010503||010112||010115||012303',
'associateAnnouncement': None,
'important': None,
'batchNum': None,
'announcementContent': '',
'orgName': None,
'tileSecName': '新锦动力',

```

```

'shortTitle': '关于公司董事辞职的公告',
'announcementTypeName': None,
'secNameList': None},
{'id': None,
'secCode': '002201',
'secName': '正威新材',
'orgId': '9900003944',
'announcementId': '1218072521',
'announcementTitle': '关于董事会秘书辞职的公告',
'announcementTime': 1697600664000,
'adjunctUrl': 'finalpage/2023-10-18/1218072521.PDF',
'adjunctSize': 144,
'adjunctType': 'PDF',
'storageTime': None,
'columnId': '09020202||250101||251302',
'pageColumn': 'SZZB',
'announcementType': '01010503||010112||012303',
'associateAnnouncement': None,
'important': None,
'batchNum': None,
'announcementContent': '',
'orgName': None,
'tileSecName': '正威新材',
'shortTitle': '关于董事会秘书辞职的公告',
'announcementTypeName': None,
'secNameList': None},
{'id': None,
'secCode': '000755',
'secName': '山西路桥',
'orgId': 'gssz0000755',
'announcementId': '1218061388',
'announcementTitle': '关于独立董事辞职的公告',

```

```

'announcementTime': 1697558400000,
'adjunctUrl': 'finalpage/2023-10-18/1218061388.PDF',
'adjunctSize': 221,
'adjunctType': 'PDF',
'storageTime': None,
'columnId': '09020202||250101||251302',
'pageColumn': 'SZZB',
'announcementType': '01010503||010112||012303',
'associateAnnouncement': None,
'important': None,
'batchNum': None,
'announcementContent': '',
'orgName': None,
'tileSecName': '山西路桥',
'shortTitle': '关于独立董事辞职的公告',
'announcementTypeName': None,
'secNameList': None},
{'id': None,
'secCode': '301188',
'secName': '力诺特玻',
'orgId': 'gfbj0833017',
'announcementId': '1218059956',
'announcementTitle': '关于公司总经理、部分董事、董事长辞职暨聘任总经理、补选董事、
'announcementTime': 1697558400000,
'adjunctUrl': 'finalpage/2023-10-18/1218059956.PDF',
'adjunctSize': 198,
'adjunctType': 'PDF',
'storageTime': None,
'columnId': '09020202||160203||250301||251302',
'pageColumn': 'SZCY',
'announcementType': '01010503||010112||010115||012301||012303',
'associateAnnouncement': None,

```

```

'important': None,
'batchNum': None,
'announcementContent': '',
'orgName': None,
'tileSecName': '力诺特玻',
'shortTitle': '关于公司总经理、部分董事、董事长辞职暨聘任总经理、补选董事、选举董事',
'announcementTypeName': None,
'secNameList': None},
{'id': None,
'secCode': '301188',
'secName': '力诺特玻',
'orgId': 'gfbj0833017',
'announcementId': '1218059949',
'announcementTitle': '关于公司监事会主席辞职暨补选监事的公告',
'announcementTime': 1697558400000,
'adjunctUrl': 'finalpage/2023-10-18/1218059949.PDF',
'adjunctSize': 94,
'adjunctType': 'PDF',
'storageTime': None,
'columnId': '09020202||160203||250301||251302',
'pageColumn': 'SZCY',
'announcementType': '01010503||010112||010115||012303',
'associateAnnouncement': None,
'important': None,
'batchNum': None,
'announcementContent': '',
'orgName': None,
'tileSecName': '力诺特玻',
'shortTitle': '关于公司监事会主席辞职暨补选监事的公告',
'announcementTypeName': None,
'secNameList': None},
{'id': None,

```

'secCode': '002833',  
 'secName': '弘亚数控',  
 'orgId': '9900029438',  
 'announcementId': '1218059468',  
 'announcementTitle': '关于高级管理人员辞职暨聘任高级管理人员的公告',  
 'announcementTime': 1697558400000,  
 'adjunctUrl': 'finalpage/2023-10-18/1218059468.PDF',  
 'adjunctSize': 252,  
 'adjunctType': 'PDF',  
 'storageTime': None,  
 'columnId': '09020202||250101||251302',  
 'pageColumn': 'SZZB',  
 'announcementType': '01010503||010112||012303',  
 'associateAnnouncement': None,  
 'important': None,  
 'batchNum': None,  
 'announcementContent': '',  
 'orgName': None,  
 'tileSecName': '弘亚数控',  
 'shortTitle': '关于高级管理人员辞职暨聘任高级管理人员的公告',  
 'announcementTypeName': None,  
 'secNameList': None},  
 {'id': None,  
 'secCode': '002771',  
 'secName': '真视通',  
 'orgId': '9900023511',  
 'announcementId': '1218059327',  
 'announcementTitle': '关于公司副总经理辞职的公告',  
 'announcementTime': 1697558400000,  
 'adjunctUrl': 'finalpage/2023-10-18/1218059327.PDF',  
 'adjunctSize': 255,  
 'adjunctType': 'PDF',

```

'storageTime': None,
'columnId': '09020202||250101||251302',
'pageColumn': 'SZZB',
'announcementType': '01010503||010112||012303',
'associateAnnouncement': None,
'important': None,
'batchNum': None,
'announcementContent': '',
'orgName': None,
'titleSecName': '真视通',
'shortTitle': '关于公司副总经理辞职的公告',
'announcementTypeName': None,
'secNameList': None}],
'categoryList': None,
'hasMore': True,
'totalpages': 3}

```

```

content = r.json()
record = content["totalAnnouncement"]
record

```

95

```

df = pd.DataFrame(content["announcements"])
df.head()

```

	id	secCode	secName	orgId	announcementId	announcementTitle
0	None	002939	长城证券	qsgn0000030	1218108610	关于公司董事辞职的公告
1	None	300801	泰和科技	9900031706	1218108177	关于独立董事辞职暨补选独立董事的公告
2	None	000420	吉林化纤	gssz0000420	1218108160	关于董事、董事会秘书辞职的公告
3	None	001965	招商公路	GD008065	1218108158	关于高级管理人员辞职的公告
4	None	002075	沙钢股份	9900001101	1218107902	关于职工代表监事辞职及补选的公告



<http://static.cninfo.com.cn/finalpage/2021-11-22/1211672004.PDF>

```
row = df.loc[0,:]
print(type(row))
row
```

```
<class 'pandas.core.series.Series'>
```

id	None
secCode	002939
secName	长城证券
orgId	qsgn0000030
announcementId	1218108610
announcementTitle	关于公司董事辞职的公告
announcementTime	1697817600000
adjunctUrl	finalpage/2023-10-21/1218108610.PDF
adjunctSize	211
adjunctType	PDF
storageTime	None
columnId	09020202  250101  251302
pageColumn	SZZB
announcementType	01010503  010112  012303
associateAnnouncement	None
important	None
batchNum	None
announcementContent	
orgName	None
tileSecName	长城证券
shortTitle	关于公司董事辞职的公告
announcementTypeName	None
secNameList	None

Name: 0, dtype: object

```
Path("pdf").mkdir(exist_ok=True)
```

```
pdf_url = f"http://static.cninfo.com.cn/{row.adjunctUrl}"
```

```
local_pdf = f'pdf/{row.secName}_{row.announcementId}.pdf'
```

```
from urllib.request import urlretrieve
```

```
urlretrieve(pdf_url, local_pdf)
```

```
print(f"download from {pdf_url} to local file: {local_pdf}")
```

download from http://static.cninfo.com.cn/finalpage/2023-10-21/1218108610.PDF to local

## 9.3 模拟浏览器

### 💡 Playwright 文档

- [Playwright Python 入门](#)
- [API 文档](#)
- [库模式使用](#)

Playwright 是一个强大的浏览器自动化工具，支持 Chromium、Firefox 和 WebKit。

### ❗ Jupyter Notebook 中的注意事项

在 Jupyter/Quarto 环境中，由于已存在 asyncio 事件循环，需要使用 **异步 API**。

在普通 Python 脚本中，可以使用同步 API。

### 9.3.1 异步 API 示例 (Notebook 推荐)

```
from playwright.async_api import async_playwright
```

```
async def browse_example():
```

```

async with async_playwright() as p:
 # 启动浏览器 (headless=True 表示无界面模式)
 browser = await p.chromium.launch(headless=True)
 page = await browser.new_page()

 # 访问网页
 await page.goto("https://playwright.dev")

 # 获取标题
 title = await page.title()
 print(f" 页面标题: {title}")

 # 截图
 await page.screenshot(path="./data/playwright_example.png")
 print(" 截图已保存")

 # 关闭浏览器
 await browser.close()

在 Jupyter 中直接运行异步函数
await browse_example()

```

### 9.3.2 完整的网页自动化示例

```

from playwright.async_api import async_playwright
from pathlib import Path

async def search_and_save():
 async with async_playwright() as p:
 # 启动浏览器
 browser = await p.chromium.launch(headless=True)

```

```

page = await browser.new_page()

访问百度首页
await page.goto('https://www.baidu.com')
print(" 已打开百度首页")

搜索" 暨南大学管理学院"
await page.fill('input[name="wd"]', '暨南大学管理学院')
await page.click('input[type="submit"]')
print(" 已提交搜索")

等待搜索结果加载
await page.wait_for_load_state('networkidle')

获取页面标题
title = await page.title()
print(f" 页面标题: {title}")

保存页面内容
html_content = await page.content()
Path('search_results.html').write_text(html_content,
↪ encoding='utf-8')
print(" 页面内容已保存到 search_results.html")

截图
await page.screenshot(path='search_screenshot.png')
print(" 截图已保存到 search_screenshot.png")

关闭浏览器
await browser.close()

运行

```

```
await search_and_save()
```

### 9.3.3 同步 API（仅供参考，不在 Notebook 中使用）

#### Warning

以下代码仅适用于普通 Python 脚本，不要在 Jupyter Notebook 中运行。

```
仅在普通 .py 脚本中使用
from playwright.sync_api import sync_playwright

with sync_playwright() as p:
 browser = p.chromium.launch(headless=False)
 page = browser.new_page()
 page.goto("https://playwright.dev")
 print(page.title())
 browser.close()
```

## 9.4 解析 HTML

```
import requests
headers = {'User-Agent':
 'Mozilla/5.0 (Windows NT 10.0; Win64; x64) AppleWebKit/537.36
 ↪ (KHTML, like Gecko) Chrome/79.0.3945.130 Safari/537.36
 ↪ OPR/66.0.3515.115'}
url = 'https://book.douban.com/tag/小说?start=0&type=T'
resp = requests.get(url, headers = headers) # 极少数情况会用到
 ↪ verify=False 这参数
resp
```

<Response [200]>

```
Path("sample.html").write_text(resp.text)
```

53589

```
html_string = Path("sample.html").read_text() # local html
```

```
type(html_string)
```

str

### HTML 解析库选择

常用的 HTML 解析库：

- **Parsel** - 支持 CSS 和 XPath, Scrapy 框架使用的解析库（推荐）
- **lxml** - 速度快，功能强大
- **BeautifulSoup** - 功能全面，语法简单

本教程使用 **Parsel** 库，演示两种选择器用法：CSS 和 XPath。

#### 9.4.1 方法一：使用 **Parsel** + **CSS** 选择器

Parsel 是 Scrapy 框架使用的解析库，同时支持 CSS 选择器和 XPath。

```
from parsel import Selector

创建 Selector 对象
selector = Selector(text=html_string)
print(f"Selector 类型: {type(selector)}")
```

Selector 类型: <class 'parsel.selector.Selector'>

#### **CSS** 选择器语法

为了定位 html 中对应的节点及其属性和含有的信息，我们需要使用选择器。

CSS 选择器	例子	解释
.class	.intro	选出 class="intro" 的节点
#id	#firstname	选出 id="firstname" 的节点
element	p	选出所有 p 标签的节点
element element	div p	选出 div 节点后代所有 p 节点
[attribute]	[target]	选出带有 target 属性所有节点
[attribute=value]	[target=_blank]	选出 target="_blank" 的所有节点

### 💡 SelectorGadget 工具

使用 Chrome 扩展 [SelectorGadget](#) 可以快速获取元素的 CSS 选择器。

### Parsel CSS 选择器示例

```
选择所有书籍条目
items = selector.css('.subject-item')
print(f" 找到 {len(items)} 个书籍条目")
```

找到 20 个书籍条目

```
获取第一个书籍条目
first_item = selector.css('.subject-item')[0]
print(first_item)
```

```
<li class="subject-item">
 <div class="pic">
 <a class="nbg" href="https://book.douban.com/subject/37339619/" onclick="moreur

</div>
<div class="info">
 <h2 class="">

<a href="https://book.douban.com/subject/37339619/" title="桃花源没事儿" onclick="m

桃花源没事儿
```

```

```

```

 </h2>
 <div class="pub">

马伯庸 / 湖南文艺出版社 / 2025-6 / 48.00元
```

```
</div>
```

```
<div class="star clearfix">

 7.6
```



```

 (12983人评价)

</div>
```

```
<p>小道士玄穹是天生穷命，只要一捞横财，必有天雷劈下。他啥钱也不敢挣，只能去桃花源
```

```
<div class="ft">
```

```
<div class="collect-info">
</div>
```

```
<div class="cart-actions">
```

```


 纸质版 35.00元
```

```


```

```
</div>
```

```
<div class="ebook-link">

</div>
```

```
</div>
```

```
</div>

```

```
遍历所有书籍，提取信息
for item in items[:3]: # 只看前 3 个
 # 提取书名（使用 ::text 伪元素获取文本）
 title = item.css('a[title]::attr(title)').get()
 # 提取评分
 rating = item.css('.rating_nums::text').get()
 # 提取评价人数
 pl = item.css('.pl::text').get()

 print(f" 书名: {title}")
 print(f" 评分: {rating}")
 print(f" 评价: {pl}")
```

```
print("-" * 50)
```

书名：桃花源没事儿

评分：7.6

评价：

(12983人评价)

-----

书名：长安的荔枝

评分：8.5

评价：

(261869人评价)

-----

书名：太白金星有点烦

评分：9.0

评价：

(139370人评价)

-----

```
提取图片 URL
```

```
img_url = selector.css('.subject-item img::attr(src)').get()
```

```
print(f" 图片 URL: {img_url}")
```

图片URL: <https://img2.doubanio.com/view/subject/s/public/s35162221.jpg>

```
提取所有书名（返回列表）
```

```
all_titles = selector.css('.subject-item a[title]::attr(title)').getall()
```

```
print(f" 共找到 {len(all_titles)} 本书")
```

```
print(all_titles[:5]) # 显示前 5 本
```

共找到 20 本书

['桃花源没事儿', '长安的荔枝', '太白金星有点烦', '食南之徒', '一句顶一万句']

## 9.4.2 方法二：使用 Parsel + XPath

XPath 是更强大的选择器语言，可以进行复杂的节点查询。

### XPath vs CSS

- **CSS 选择器**：简洁直观，适合简单查询
- **XPath**：功能更强大，支持复杂的逻辑判断和层级关系

推荐：简单场景用 CSS，复杂场景用 XPath。

### XPath 基础语法

XPath 表达式	说明
/	从根节点选取
//	从任意位置选取
.	当前节点
..	父节点
@	选取属性
text()	选取文本内容

```
使用 XPath 选择所有书籍条目
items_xpath = selector.xpath('//li[@class="subject-item"]')
print(f"XPath 找到 {len(items_xpath)} 个书籍条目")
```

XPath 找到 20 个书籍条目

```
使用 XPath 提取第一本书的信息
first_book = items_xpath[0]

提取书名
```

```

title_xpath = first_book.xpath('.//a[@title]/@title').get()
提取评分
rating_xpath =
 ↪ first_book.xpath('.//span[@class="rating_nums"]/text()').get()
提取出版信息
pub_xpath = first_book.xpath('.//div[@class="pub"]/text()').get()

print(f" 书名: {title_xpath}")
print(f" 评分: {rating_xpath}")
print(f" 出版信息: {pub_xpath}")

```

书名: 桃花源没事儿

评分: 7.6

出版信息:

马伯庸 / 湖南文艺出版社 / 2025-6 / 48.00元

```

XPath 高级用法: 条件筛选
选择评分大于等于 8.0 的书籍 (需要将评分转为数字比较)
high_rated_books = []

for item in items_xpath:
 rating = item.xpath('.//span[@class="rating_nums"]/text()').get()
 title = item.xpath('.//a[@title]/@title').get()

 if rating and float(rating) >= 8.0:
 high_rated_books.append({
 'title': title,
 'rating': rating

```

```

 })

print(f" 评分 >= 8.0 的书籍共 {len(high_rated_books)} 本:")
for book in high_rated_books[:5]:
 print(f" {book['title']}: {book['rating']}")

```

评分 >= 8.0 的书籍共 18 本:

长安的荔枝: 8.5  
 太白金星有点烦: 9.0  
 食南之徒: 8.2  
 一句顶一万句: 9.0  
 素食者: 8.1

```

XPath 提取所有图片 URL
img_urls_xpath =
 ↪ selector.xpath('//li[@class="subject-item"]//img/@src').getall()
print(f" 共找到 {len(img_urls_xpath)} 个图片")
print(img_urls_xpath[:3])

```

共找到 20 个图片

['https://img2.doubanio.com/view/subject/s/public/s35162221.jpg', 'https://img3.douba

## CSS vs XPath 对比示例

```

import pandas as pd

创建对比数据
comparison_data = []

for i, item in enumerate(items[:5], 1):
 # CSS 方式
 title_css = item.css('a[title]::attr(title)').get()

```

```

rating_css = item.css('.rating_nums::text').get()

XPath 方式
title_xpath = items_xpath[i-1].xpath('..//a[@title]/@title').get()
rating_xpath =
↪ items_xpath[i-1].xpath('..//span[@class="rating_nums"]/text()').get()

comparison_data.append({
 '序号': i,
 '书名 (CSS)': title_css,
 '评分 (CSS)': rating_css,
 '书名 (XPath)': title_xpath,
 '评分 (XPath)': rating_xpath,
 '结果一致': title_css == title_xpath and rating_css ==
 ↪ rating_xpath
})

df_comparison = pd.DataFrame(comparison_data)
print(df_comparison)

```

	序号	书名 (CSS)	评分 (CSS)	书名 (XPath)	评分 (XPath)	结果一致
0	1	桃花源没事儿	7.6	桃花源没事儿	7.6	True
1	2	长安的荔枝	8.5	长安的荔枝	8.5	True
2	3	太白金星有点烦	9.0	太白金星有点烦	9.0	True
3	4	食南之徒	8.2	食南之徒	8.2	True
4	5	一句顶一万句	9.0	一句顶一万句	9.0	True

### 💡 Parsel 方法速查

**CSS** 选择器方法: - `selector.css('div')` - 选择所有 `div` 元素 -  
`selector.css('div::text').get()` - 获取第一个 `div` 的文本 -  
`selector.css('div::text').getall()` - 获取所有 `div` 的文本 -  
`selector.css('a::attr(href)').get()` - 获取第一个 `a` 标签的 `href` 属性

**XPath 方法:** - `selector.xpath('//div')` - 选择所有 `div` 元素 -  
- `selector.xpath('//div/text()').get()` - 获取第一个 `div` 的文本 -  
- `selector.xpath('//div/text()').getall()` - 获取所有 `div` 的文本 -  
- `selector.xpath('//a/@href').get()` - 获取第一个 `a` 标签的 `href` 属性

### 9.4.3 下载图片示例

```
url = selector.css('.subject-item img::attr(src)').get()
print(f" 图片 URL: {url}")
```

图片 URL: <https://img2.doubanio.com/view/subject/s/public/s35162221.jpg>

```
from urllib.request import urlretrieve
from pathlib import Path

设置本地文件名
local = f"{Path(url).name}"
print(f" 保存路径: {local}")
```

保存路径: s35162221.jpg

```
下载图片
urlretrieve(url, local)
print(f" 图片已下载到: {local}")
```

图片已下载到: s35162221.jpg

## 9.5 总结

本章介绍了网页爬虫的基础知识:

1. **HTTP 请求:** 使用 `requests` 库获取网页内容



## 2. HTML 解析：使用 `parsel` 库的两种方式

- **CSS 选择器**：简洁直观，适合大多数场景
- **XPath**：功能强大，适合复杂查询

## 3. 浏览器自动化：使用 `playwright` 处理 JavaScript 动态内容

### ! 爬虫注意事项

1. 遵守 **robots.txt**：检查网站的爬虫协议
2. 控制请求频率：添加延时，避免给服务器造成压力
3. 尊重版权：仅用于学习和研究，不用于商业用途
4. 数据隐私：不爬取个人隐私信息

### 💡 推荐学习资源

- [Parsel 官方文档](#)
- [XPath 教程](#)
- [CSS 选择器参考](#)
- [Scrapy 框架](#)（基于 `Parsel` 的强大爬虫框架）