统计学（Python实现）

第一次上机课

赵震宇（2120253538）
南开大学 国际经济研究所
zzynankai@outlook.com
xishanyu2.github.io
2025 年 10 月 16 日

参考资料

- 贾俊平，吴翌琳著. 统计学：基于Python. 中国人民大学出版社. 2024
- 贾俊平编著. 统计学：Python实现. 高等教育出版社. 2021
- Python for Data Analysis, 3E
- 鸢尾花书

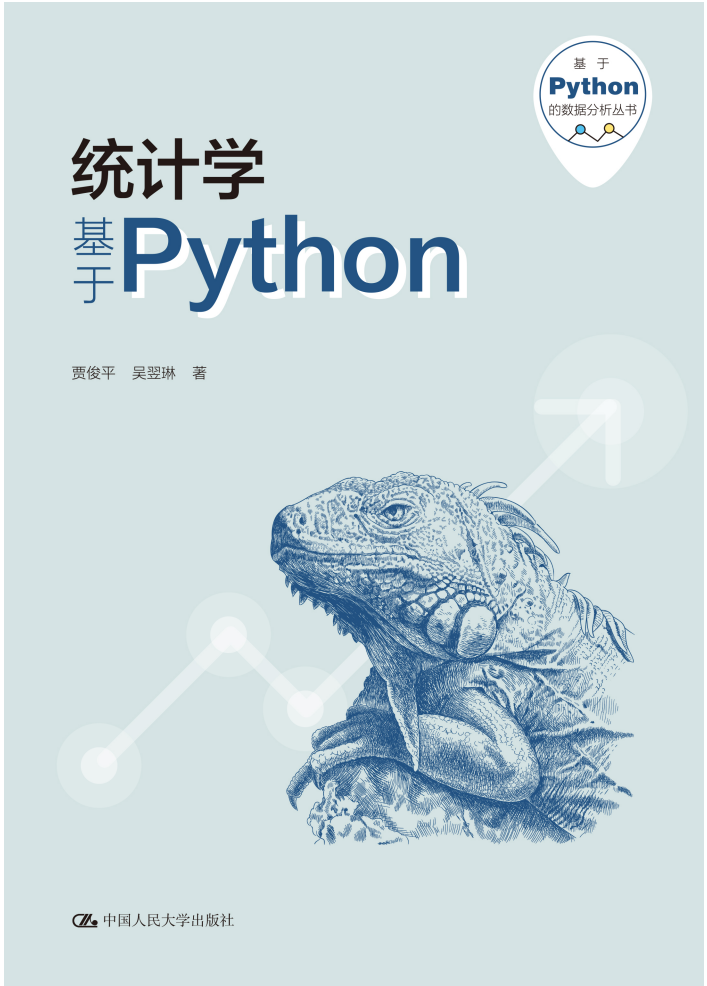


第1章 导论
1.1 统计及其应用领域
1.2 统计数据的类型
1.3 统计中的几个基本概念
第2章 数据的搜集
2.1 数据的来源
2.2 调查方法
2.3 实验方法
2.4 数据的误差
第3章 数据的图表展示
3.1 数据的预处理
3.2 品质数据的整理与展示
3.3 数值型数据的整理与展示
3.4 合理使用图表
第4章 数据的概括性度量
4.1 集中趋势的度量
4.2 离散程度的度量
4.3 偏态与峰态的度量
第5章 概率与概率分布
5.1 随机事件及其概率
5.2 离散型随机变量及其分布
5.3 连续型随机变量的概率分布
第6章 统计量及其抽样分布
6.1 统计量
6.2 由正态分布导出的几个重要分布
6.3 样本均值的分布与中心极限定理
第7章 参数估计
7.1 参数估计的基本原理
7.2 一个总体参数的区间估计
7.3 两个总体参数的区间估计
7.4 样本量的确定
第8章 假设检验
8.1 假设检验的基本问题
8.2 一个总体参数的检验
8.3 两个总体参数的检验
8.4 检验问题的进一步说明


第9章 分类数据分析
9.1 分类数据与统计量
9.2 拟合优度检验
9.3 列联分析：独立性检验
9.4 列联表中的相关测量
9.5 列联分析中应注意的问题
第10章 方差分析
10.1 方差分析引论
10.2 单因素方差分析
10.3 双因素方差分析
第11章 一元线性回归
11.1 变量间关系的度量
11.2 一元线性回归
11.3 利用回归方程进行预测
11.4 残差分析
第12章 多元线性回归
12.1 多元线性回归模型
12.2 回归方程的拟合优度
12.3 显著性检验
12.4 多重共线性
12.5 利用回归方程进行预测
12.6 变量选择与逐步回归
第13章 时间序列分析和预测
13.1 时间序列及其分解
13.2 时间序列的描述性分析
13.3 时间序列预测的程序
13.4 平稳序列的预测
13.5 趋势型序列的预测
13.6 复合型序列的分解预测
第14章 指数
14.1 基本问题
14.2 总指数编制方法
14.3 指数体系
14.4 几种典型的指数
14.5 综合评价指数

CONTENT

目录

1. Python基础（不讲）

1.0 运行环境

- Anaconda Navigator → JupyterLab/Notebook
- Cursor - The AI Code Editor

1.1 遇到问题怎么办？

- 问AI
- Stack Overflow

1.2 数据读取和保存

```
import pandas as pd
table1 = pd.read_csv("F:/pydata/example/chap01/table1.csv")
table1 #默认为“UTF-8”格式
```

```
pip install openpyxl
import pandas as pd
df = pd.read_excel("F:/pydata/example/chap01/table3.xlsx")
df
```

- 保存为新数据时，需要指定文件类型：.csv/.xslx
- 保存为csv类型时还需指定编码格式：utf-8/gbk

```
table1.to_csv("F:/pydata/example/chap01/df1.csv",index=False, encoding='gbk')
```

1.3 6种基本数据结构

1. 数字（number）
2. 字符串（string）
3. 元组（tuple）
4. 列表（list）
5. 字典（dictionary）
6. 集合（set）

> 数字类型：整数型（int）、浮点型（float）、布尔型（bool）、复数型（complex）
> 指定字符串：''、""、''' '''
> 字典内含键（key）值（value）对

名称	列表	元组	集合	字典
表示方式	[a, b, c]	(a, b, c)	{a, b, c}	{a:x, b:y}
空	[]	()	set()	{}或 dict()
其他创建方式	ls=list((1,'one')), 外围()表示 list 的参数列表, 内层()为元组	t=tuple([1,'one']), 外围参列, 内层列表。**单个元素的元组需要在元素后添加,**		用 dict 函数,()中加入元素, 用, 隔开
访问元素	通过下标, 访问单个获得元素, 访问多个获得列表	通过下标, 访问单个获得元素, 访问多个获得列表		通过键进行访问
拼接/重复	+/*	+/*		dMerge=dict(d1,**d2)
元素可否重复	可	可	**不可**	可
修改	通过下标方式通过变量修改列表会导致另一个变量发生改变,可通过列表截取[:]的方式修改单一变量	不可修改		见插入
更改指向对象	通过使用 copy 模块提供的 deepcopy 函数复制变量,可以使两个变量指向不同的对象			浅拷贝 d.copy() 深拷贝 copy,deepcopy(d)

				d.get('键')判断键的存在性
查找	ls.index(元素值)			
插入	ls.insert(指定位置,x)，ls.append(x)则是将x插在列表末端，x可以是元素也可以是列表		s.add(x)x可哈希或s.updaate(x)x可迭代	字典.update(字典)若插入的键名不存在，则可直接字典['键名']='值'
删除	使用del语句,可以类似访问元素的方式进行删除		交集 s1,intersection(s2) 并集 s1.union(s2) 差集 s1.difference(s2) 对称差集 s1.symmetric_differemce(s2) 子集 s1.issubset(s2) 父集 s1.issuperset(s2)	del d['键']或d.pop('键','x')，若不存在名为键的元素，则返回x的值
最大/最小元素	max/min(ls)	max/min(t)		d,clear()可以清除字典中所有元素
统计元素个数	ls.count(统计值)			
计算长度	len(ls)			len(d)
元素排序	ls.sort(key=None,reserve=False)升序F（默认），降序T，None可用lambda函数的定义式(lambda 形参:对象属性)，也可以直接定义新函数			获取键的集合 d.keys()
				获取值的集合 d.values()
				遍历字典 d.items()

```
# 创建列表
ls1 = ['甲', 23, True, [1,2,3]]
ls2 = list(range(10)) #起始为0
ls3 = list(rang(1,20,2)) #左闭右开
```

```
# 列表操作
l1 = [1,2,4]
l1.append(3) #加入元素到列表尾部
l1.sort() #排序
l1.insert(2,5) #在第2个位置插入5（python从第0位开始）
l1.pop(3) #移除第三个位置的元素并返回其值

l2 = ['甲','乙','丙','丁']
l12 = l1 + l2
```

```
# 字典操作
dc1 = {'甲':68,'乙':85,'丙':74,'丁':88}
dc2 = {'甲'=68,'乙'=85,'丙'=74,'丁'=88}
dc1.keys()
dc1.values()
dc1.items()
dc1['甲']
del dc1['甲']
```

```
# 集合操作
set1 = set{2,2,2,1,8,3,3,5,5}
set2 = set{2,2,2,1,4,3,3,5,6,6}
set1&set2 #交集，或写成set1.union(set2)
set1|set2 #并集，或写成set1.intersection(set2)
```

1.4 Python“三驾马车”：数学运算和可视化库

- NumPy
- pandas - Python Data Analysis Library
- Matplotlib — Visualization with Python

1.4.1 numpy中的数组（array）

```
# 一维数组—向量（vector）
import numpy as np
a1 = np.array([5,4,1,2,3])
a2 = np.arange(12)
a3 = np.arange(2,6,0.5)

# 二维数组—矩阵（matrix）
a4 = np.array([[1,2],[3,4],[5,6]])

a5 = a2.reshape(3,4) #改向量为矩阵
a5[2] #元素为向量
```

1.4.2 pandas 中的序列（series）

```
# 创建序列
import pandas as pd
s1 = pd.Series([1,2,3,4]) #默认索引为0 1 2 3
s2 = pd.Series([5,6,7,8], index=['a','b','c','d'])
s2[1]
s2[[1,2]]
s2[['b','c']]
s3 = pd.Series(range()5)
```

```
# 序列操作
print('索引: ',s2.index)
print('数据: ',s2.values)
print('类型: ',s2.dtype)
```

```
s2.name = '序列6'
s2.index.name = '索引名'
s2 = s6.astype(float)
s2[[1,3]] = [2,8]
```

```
# 序列计算
s3 = pd.Series([1,2,3],index=['a','c','e'],dtype=float)
s2 + s3 #有共同索引的才能相加，否则为NaN
c = s2.cumsum() #累计求和
s = s2.sum()
m = s2.mean()
print("累加: ",'\n',c,'\n',"总加=",s,'\n','平均数=', m)
```

1.4.3 pandas 中的数据框（data frame）——类似Excel数据表

```
# 创建数据框
import pandas as pd
d = {"姓名":['甲','乙','丙','丁','戊'],
"统计学":[68,85,74,88,63],
"数学":[85,91,74,100,82],
"经济学":[84,63,61,49,89]}
table1_1 = pd.DataFrame(d)
table1_1
table1_1.head()
table1_1.tail(3)
table1_1.T #转置
```

```
# 数据框操作
import pandas as pd
df = pd.read_csv("F:/pydata/example/chap02/table2_1.csv")
df[['数学']] #为DataFrame，而df['数学']为Series，后者等价于df.数学
df.loc[2]
df.loc[[2,4]]
df.loc[2:4]
dd = df.iloc[[1,3],[0,2,3]]
df[:]
df[2:]
df[::2] #隔行取值: 0 2 4

df["会计学"]=[88,75,92,67,78]
df.insert(2,'会计学',[88,75,92,67,78])
df.drop(labels='数学',axis=1,inplace=True) #axis=1表示列，axis=0表示行
#inplace=True参数用于直接修改原始对象，而不是创建一个新的对象。
df.drop(index=2,inplace=True)

df.rename(columns={'数学':'计算机','经济学':'管理学'})
df.iloc[2,1]=85
```

```
# 数据框排序
import pandas as pd
table2_1 = pd.read_csv("F:/pydata/example/chap02/table2_1.csv")
table2_1.sort_values(by='统计学',ascending=False) #False为降序

# 数据框合并
table_merge = pd.concat([table1,table2]).reset_index(drop=True)
```

2. 数据可视化

2.0 matplotlib绘图

- 两个对象：figure（画布），axes（画像）

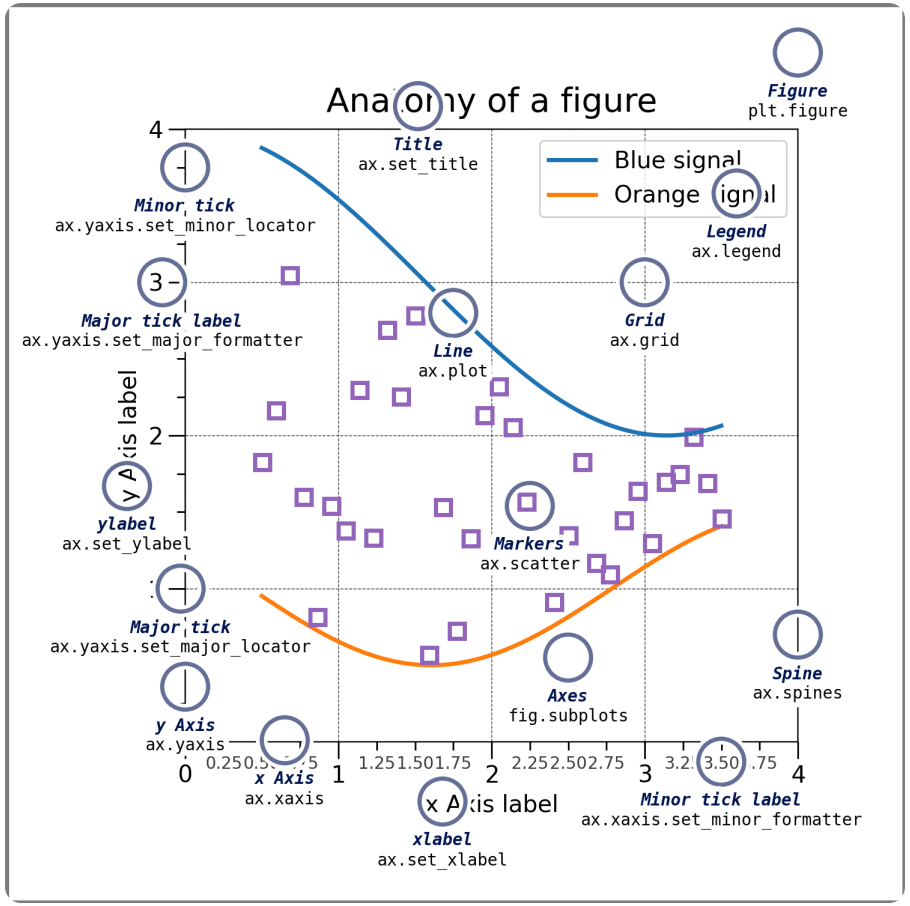

2.1 matplotlib入门

```
# matplotlib通常的引入约定是:
import matplotlib.pyplot as plt
```

- Matplotlib在`Figure`上绘制数据，每个`Figure`可以包含一个或多个`Axes`，`Axes`是一个可以使用x-y坐标（或极坐标中的theta-r，3D图中的x-y-z等）指定点的区域。
- 创建一个包含单个Axes的Figure的最简单方法是使用`plt.subplots`。
- 然后可以使用`ax.plot`在Axes上绘制一些数据，并使用`plot.show`显示图形。

```
fig, ax = plt.subplots()
ax.plot([1, 2, 3, 4], [1, 4, 2, 3])
plt.show()
```

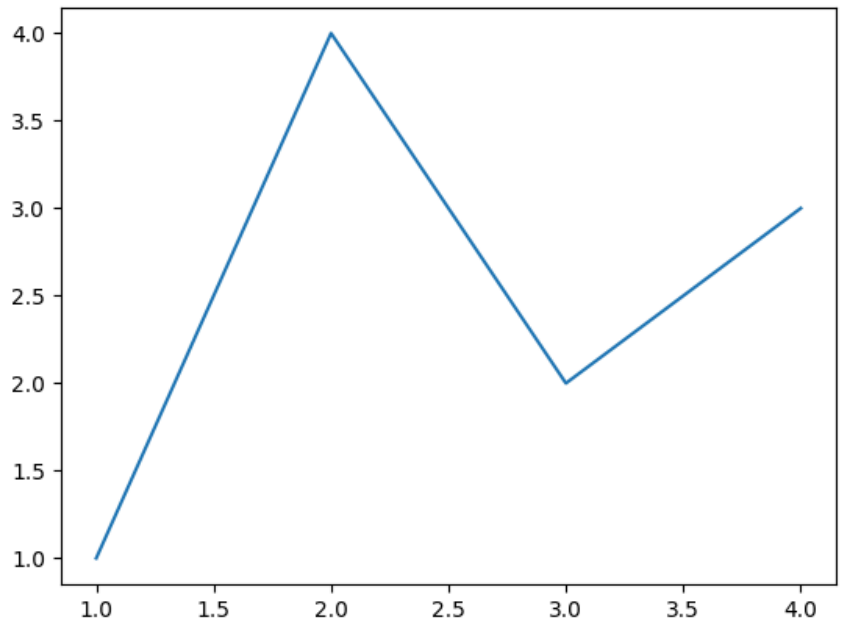

暂停一下：先搞明白plt. /ax./ fig再画图

- 同样一个目标，在matplotlib中有N种不同的方法实现。
- Matplotlib为作图提供了两套可视化接口，分别对应MATLAB的陈述式语法和面向对象写法：
  i. `plt.plot()`系列：适用于快速出图
  ii. `fig, ax = plt.subplots(); ax.plot()`系列：适用于精细绘图
- 在Matplotlib官网搜索，通常能看到两套接口：
  - 结果中的axes.Axes.pie对应`ax.pie()`，pyplot.pie对应`plt.pie()`。

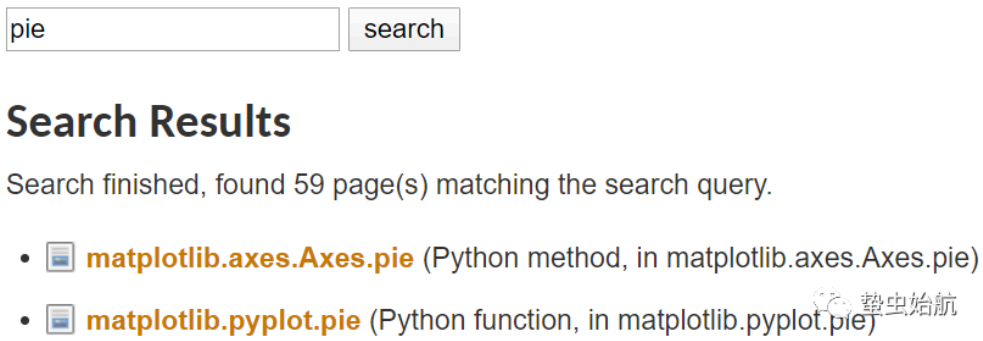

2.1.1 Figure和Subplot

matplotlib的图像都位于Figure对象中，可以用plt.figure创建一个新的Figure：

```
fig = plt.figure()
```

Out: `<Figure size 640x480 with 0 Axes>`

不能通过空Figure绘图，必须用add_subplot创建一个或多个subplot才行：

```
ax1 = fig.add_subplot(2, 2, 1)
```

subplot中参数的意思是：图像应该是2×2的（即最多4张图），且当前选中的是4个subplot中的第一个（编号从1开始）。如果再把后面两个subplot也创建出来，最终得到的图像如下：

```
ax2 = fig.add_subplot(2, 2, 2)
ax3 = fig.add_subplot(2, 2, 3)
```

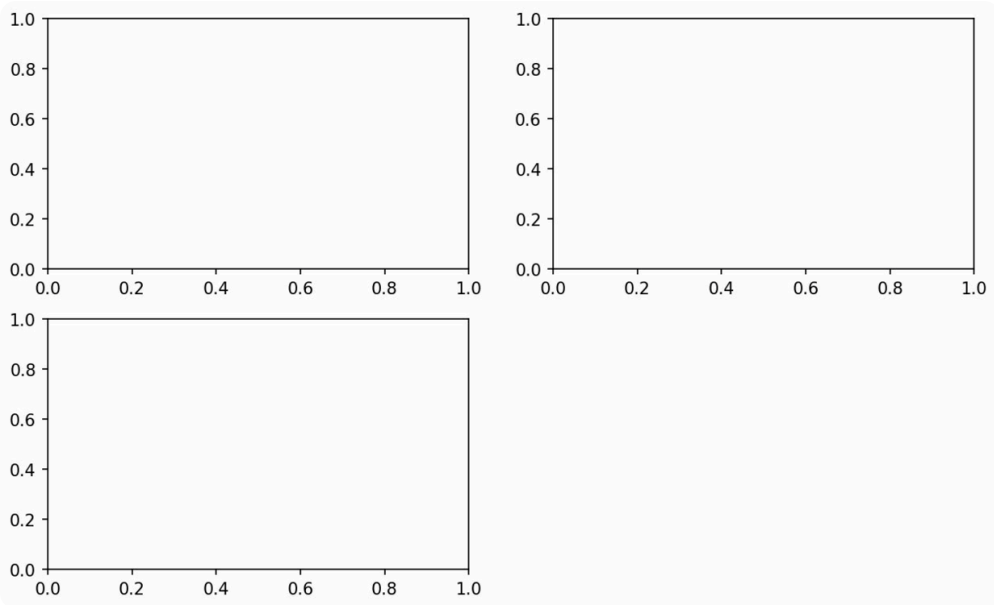

```
ax1.hist(np.random.randn(100), bins=20, color='k', alpha=0.3)
ax2.scatter(np.arange(30), np.arange(30) + 3 * np.random.randn(30))
ax3.plot(np.random.randn(50).cumsum(), 'k--')
```

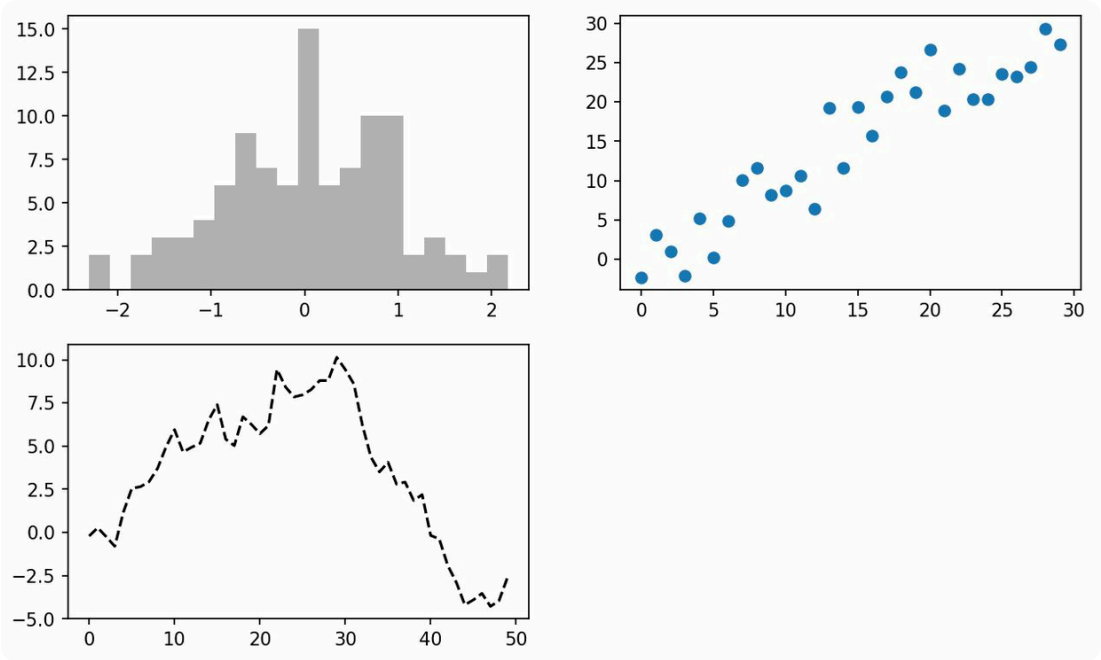

matplotlib中更为方便的方法是plt.subplots，可以创建一个新的Figure，并返回含有已创建的subplot的NumPy数组；就可以轻松地对axes数组进行索引，例如axes[0,1]

```
fig, axes = plt.subplots(2, 3)
axes
```

参数	说明
nrows	subplot的行数
ncols	subplot的列数
sharex	所有subplot应该使用相同的X轴刻度（调节xlim将会影响所有subplot）
sharey	所有subplot应该使用相同的Y轴刻度（调节ylim将会影响所有subplot）
subplot_kw	用于创建各subplot的关键字字典
**fig_kw	创建figure时的其他关键字，如plt.subplots(2,2,figsize=(8,6))

2.1.2 调整subplot周围的间距

默认情况下，matplotlib会在subplot外围留下一定的边距，并在subplot之间留下一定的间距。

利用Figure的subplots_adjust方法可以修改间距，其中wspace和hspace用于控制宽度和高度的百分比，可以用作subplot之间的间距：

```
subplots_adjust(left=None, bottom=None, right=None, top=None,
                wspace=None, hspace=None)
```

```
fig, axes = plt.subplots(2, 2, sharex=True, sharey=True)
for i in range(2):
    for j in range(2):
        axes[i, j].hist(np.random.randn(500), bins=50, color='k', alpha=0.5) # alpha指定直方图的透明度
plt.subplots_adjust(wspace=0, hspace=0)
```

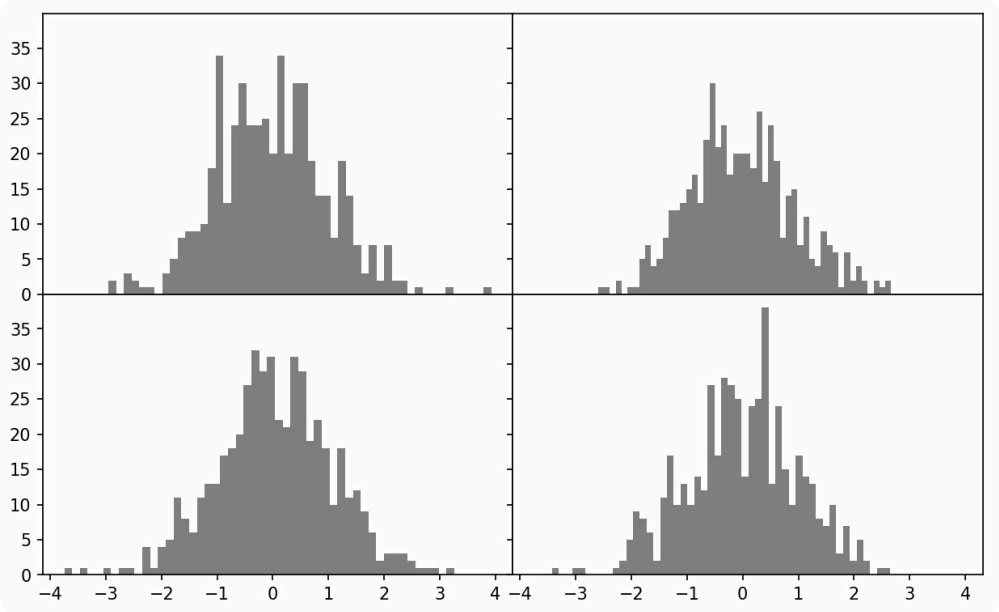

2.1.3 颜色、线型和标记

我们之前看到过`k--`，也可以拆分为`color='k', linestyle='--'`

线的颜色可以使用**color**参数来定义，简写为`c`：

颜色	'r'	'g'	'b'	'c'	'm'	'y'	'k'	'w'
说明	红色	绿色	蓝色	青色	品红	黄色	黑色	白色

线的类型可以使用**linestyle**参数来定义，简写为`ls`：

线型	'solid'（默认）	'dotted'	'dashed'	'dashdot'	'None'
简写	'-'	':'	'--'	'-.'	'' 或 ' '
说明	实线	点虚线	破折线	点划线	不画线

```
from numpy.random import randn
plt.plot(randn(30).cumsum(), 'ko--')
```

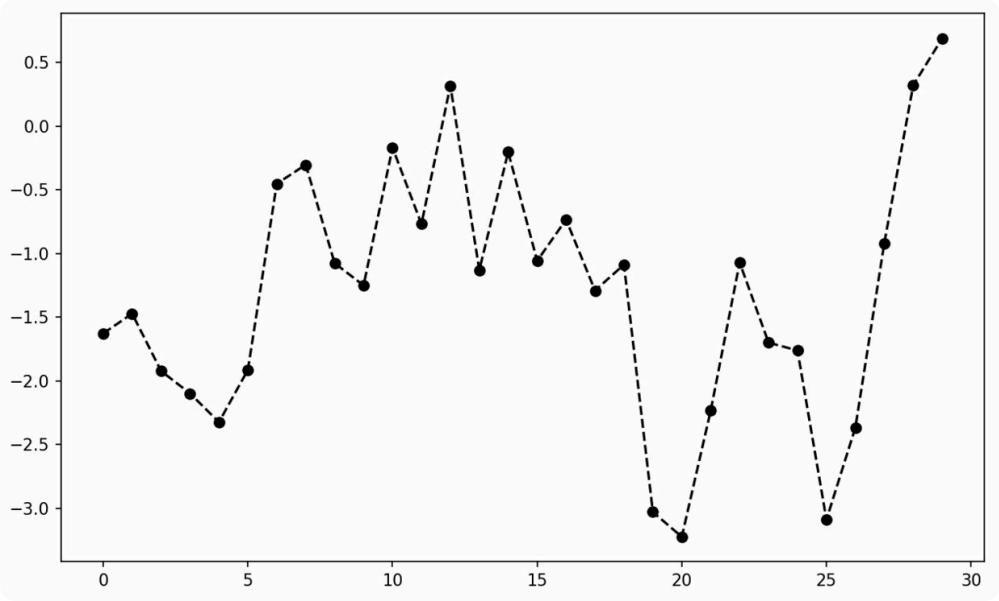

标记也可以放到格式字符串中，但标记类型和线型必须放在颜色后面。

```
plt.plot(randn(30).cumsum(), color='k', linestyle='dashed', marker='o')
```

`marker`部分可以定义的符号如下：

标记	"."	"o"	"v"	"^"	"<"	">"	"s"	"d"	"D"	"*"	"None", " " or ""
说明	点	实心圆	下三角	上三角	左三角	右三角	正方形	瘦菱形	菱形	星号	没有任何标记

Source: Matplotlib 教程 | 菜鸟教程

2.1.4 刻度、标签、标题

```
fig = plt.figure()
ax = fig.add_subplot(1, 1, 1)
ax.plot(np.random.randn(1000).cumsum())
```

使用set_xticks和set_xticklabels改变x轴刻度，前者告诉matplotlib要将刻度放在数据范围中的哪些位置，默认情况下，这些位置也就是刻度标签；通过set_xticklabels将任何其他的值用作标签：

```
ticks = ax.set_xticks([0, 250, 500, 750, 1000])
labels = ax.set_xticklabels(['one', 'two', 'three', 'four', 'five'],
                            rotation=30, fontsize='small') # rotation选项设定x刻度标签倾斜30度
```

用set_xlabel为X轴（Y轴类似）设置一个名称，并用set_title设置一个标题：

```
ax.set_title('My first matplotlib plot')
ax.set_xlabel('Stages')
```

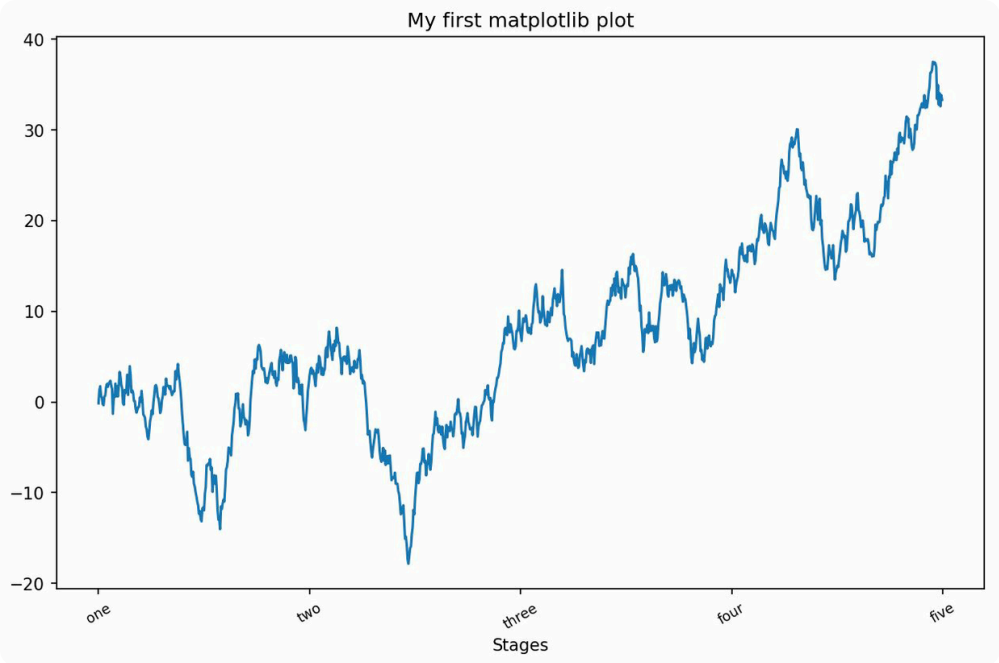

2.1.5 图例

调用ax.legend()或plt.legend()来自动创建图例，loc告诉matplotlib要将图例放在哪。

```
from numpy.random import randn
fig = plt.figure(); ax = fig.add_subplot(1, 1, 1)
ax.plot(randn(1000).cumsum(), 'k', label='one')
ax.plot(randn(1000).cumsum(), 'k--', label='two')
ax.plot(randn(1000).cumsum(), 'k.', label='three')
ax.legend(loc='best')
```

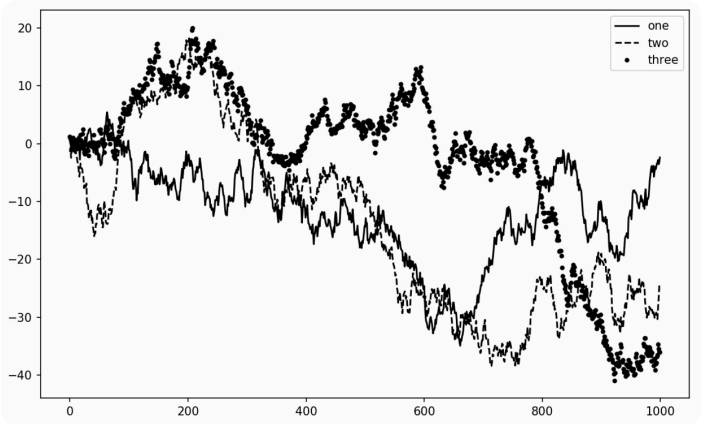

将数据映射为可视图表

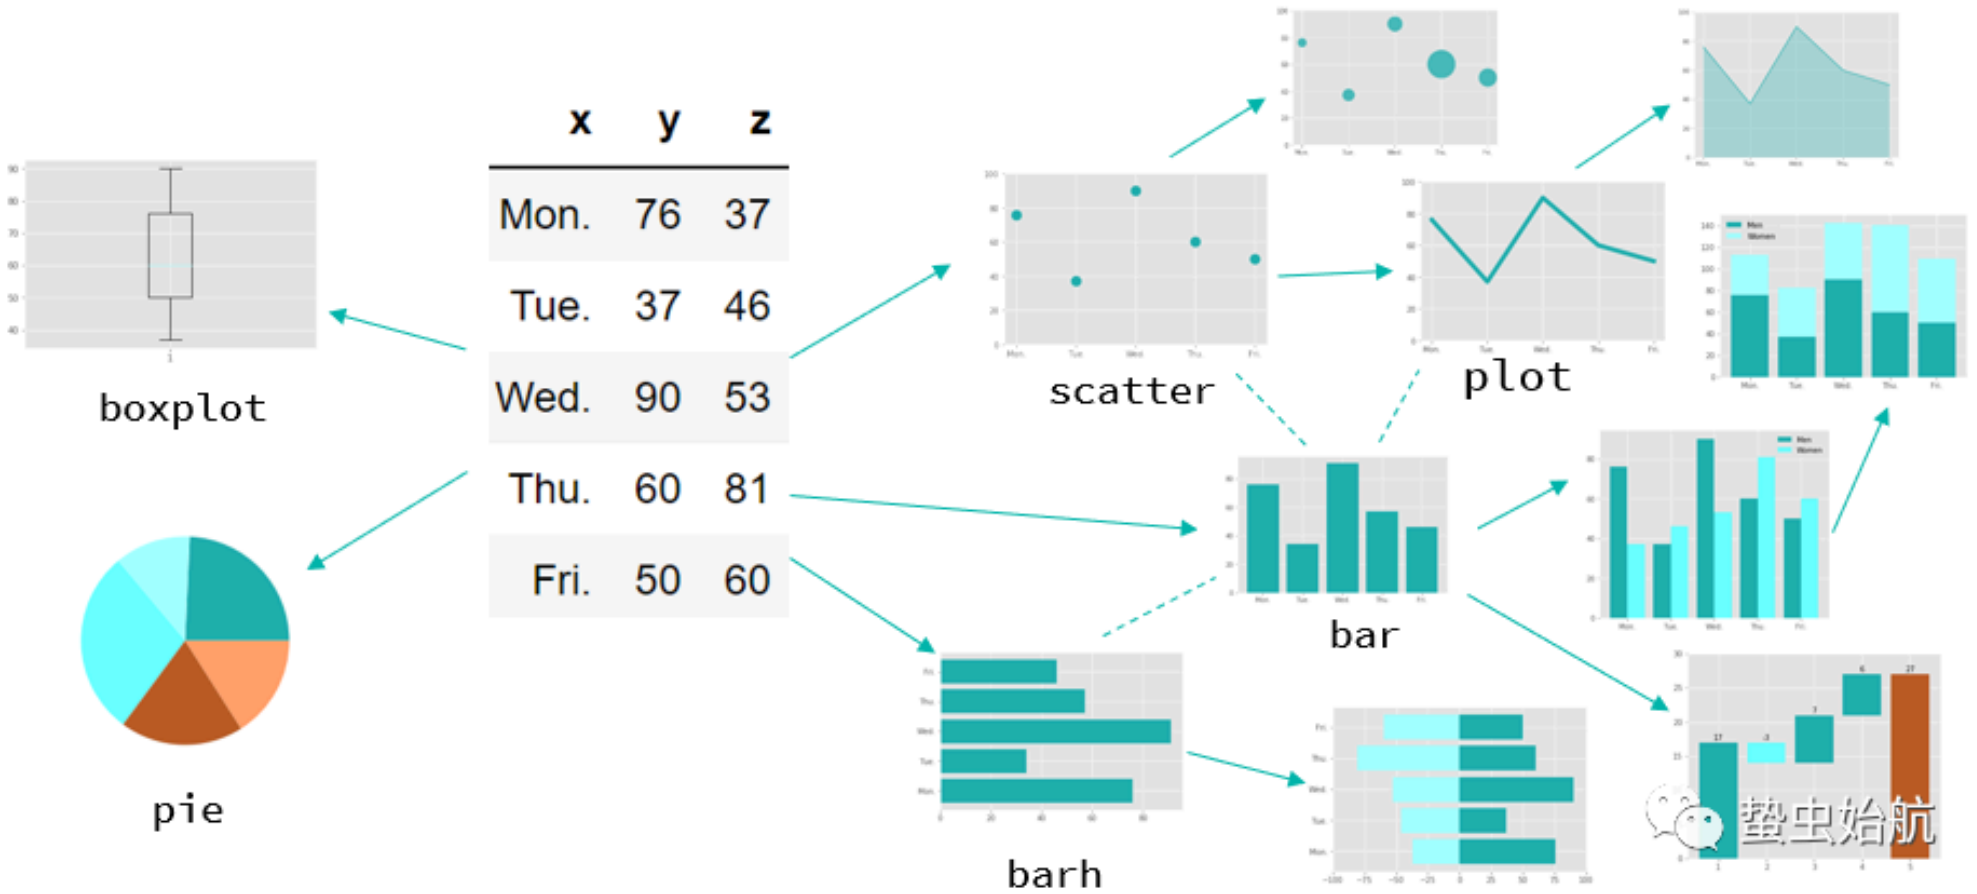

Matplotlib可视化菜鸟教程-CSDN博客

2.2 类别数据可视化

条形图

```
import matplotlib.pyplot as plt
import numpy as np
plt.style.use('_mpl-gallery')
x = 0.5 + np.arange(8)
y = [4.8, 5.5, 3.5, 4.6, 6.5, 6.6, 2.6, 3.0]
fig, ax = plt.subplots()
ax.bar(x, y, width=1, edgecolor="white", linewidth=0.7)
ax.set(xlim=(0, 8), xticks=np.arange(1, 8),
       ylim=(0, 8), yticks=np.arange(1, 8))
plt.show()
```

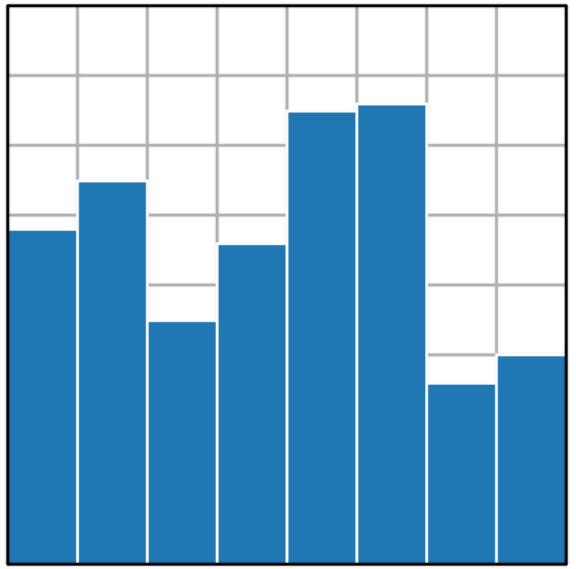

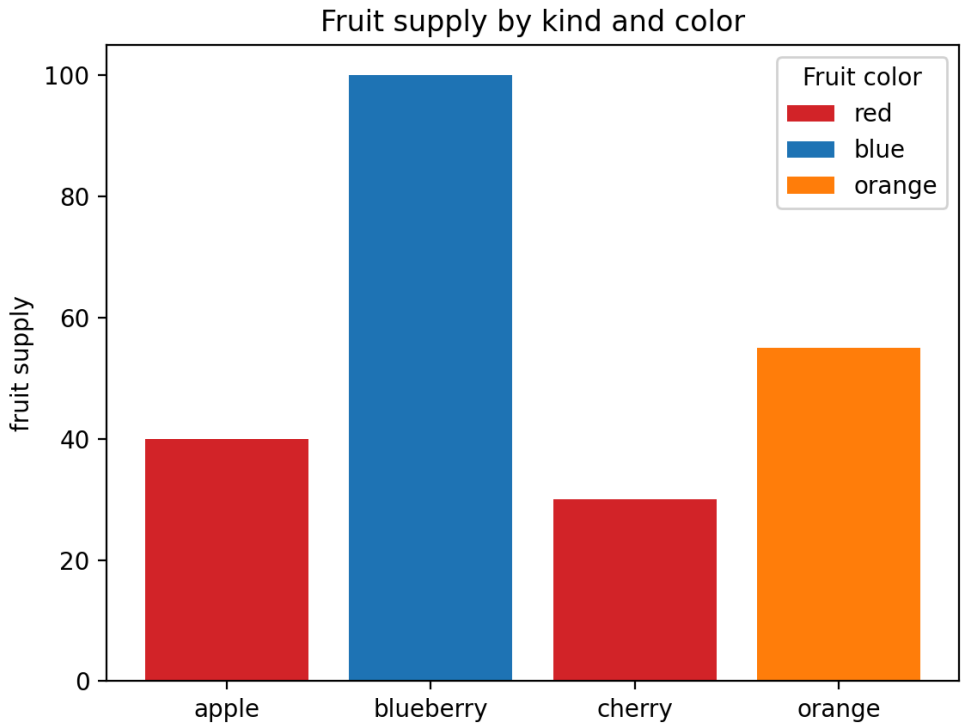
Fruit supply by kind and color
Fruit color
red
blue
orange
fruit supply
100
80
60
40
20
0
apple
blueberry
cherry
orange

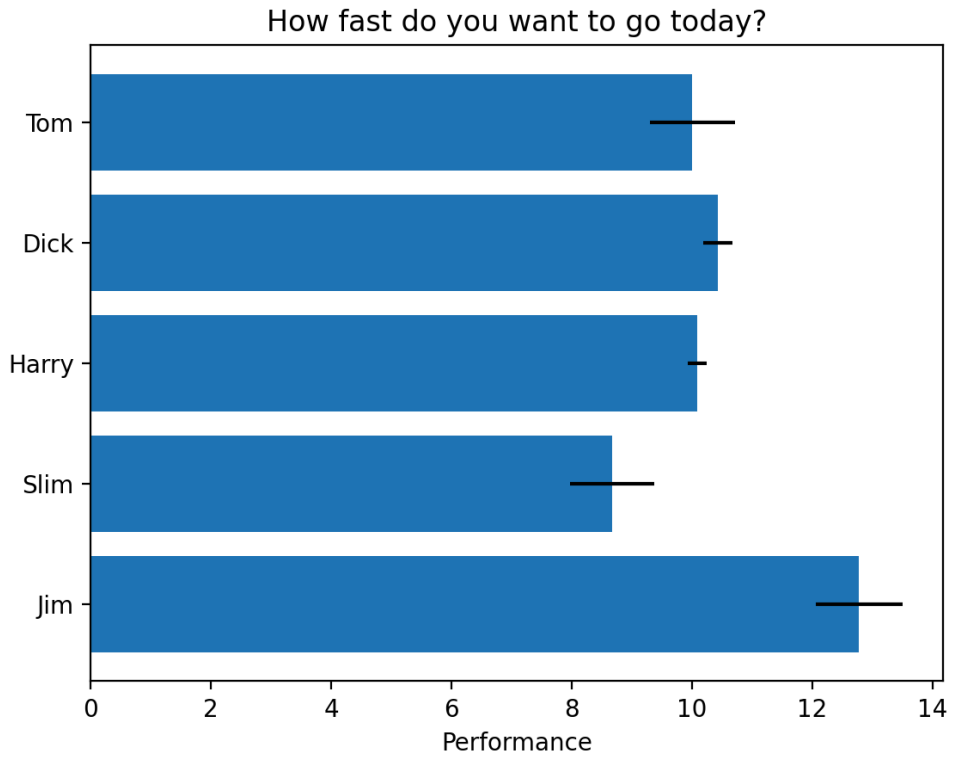
How fast do you want to go today?
Tom
Dick
Harry
Slim
Jim
0
2
4
6
8
10
12
14
Performance

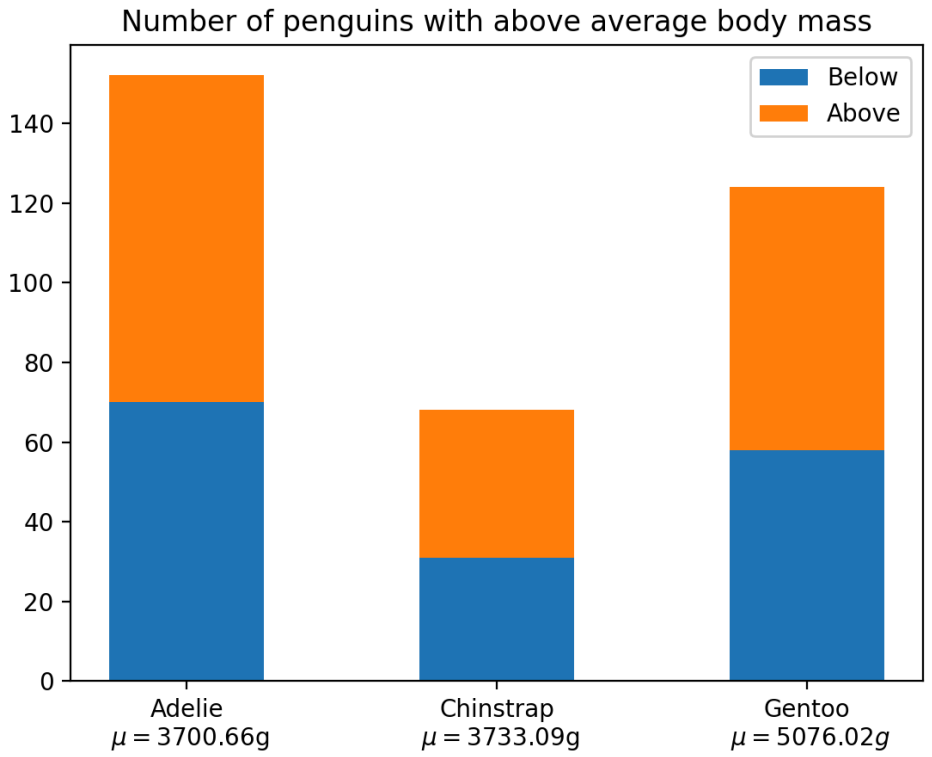
Number of penguins with above average body mass
Below
Above
140
120
100
80
60
40
20
0
Adelie
$\mu = 3700.66$g
Chinstrap
$\mu = 3733.09$g
Gentoo
$\mu = 5076.02g$

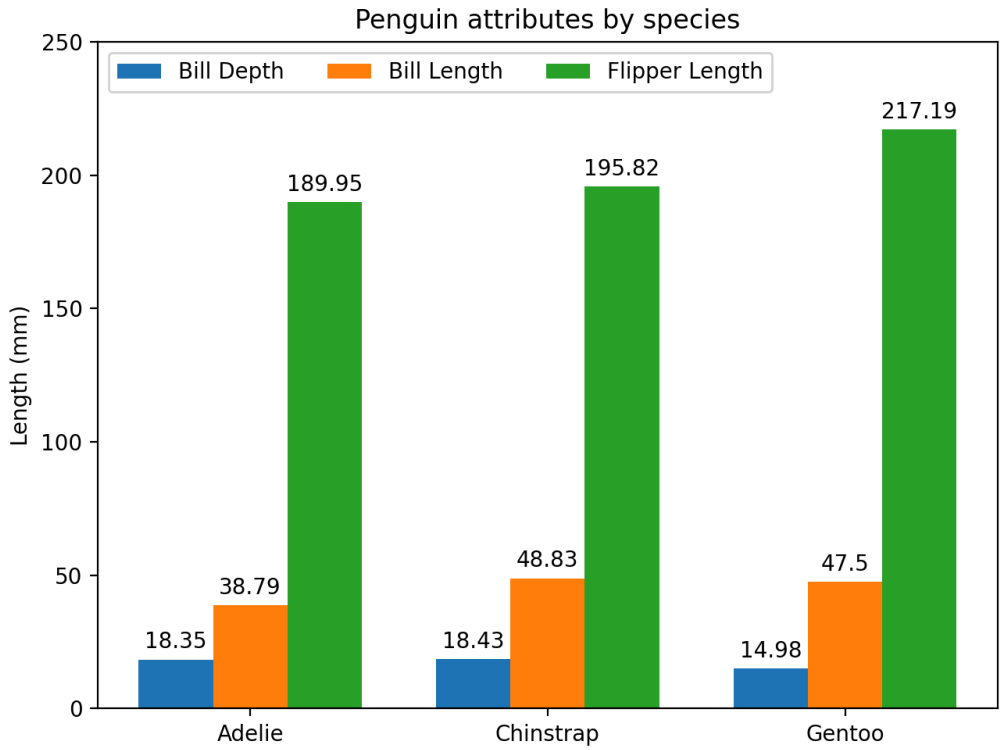
Penguin attributes by species
Bill Depth
Bill Length
Flipper Length
Length (mm)
250
200
150
100
50
0
18.35
38.79
189.95
18.43
48.83
195.82
14.98
47.5
217.19
Adelie
Chinstrap
Gentoo

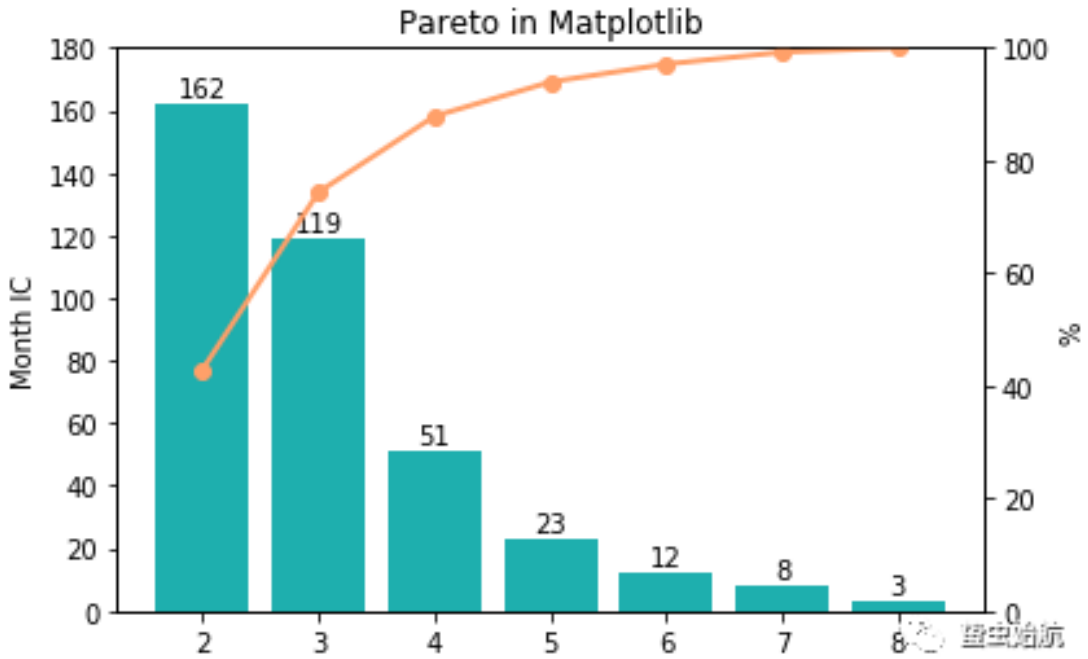
Pareto in Matplotlib
Month IC
%
162
119
51
23
12
8
3

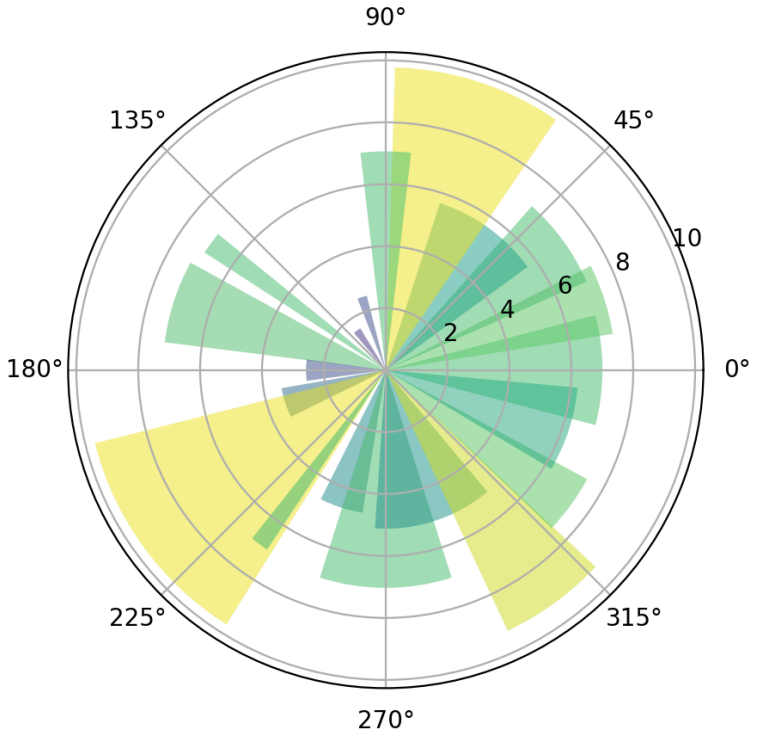
90°
135°
45°
180°
0°
225°
315°
270°
2
4
6
8
10

饼图

```
import matplotlib.pyplot as plt
import numpy as np
plt.style.use('_mpl-gallery-nogrid')
x = [1, 2, 3, 4]
colors = plt.get_cmap('Blues')(np.linspace(0.2, 0.7, len(x)))
fig, ax = plt.subplots()
ax.pie(x, colors=colors, radius=3, center=(4, 4),
       wedgeprops={"linewidth": 1, "edgecolor": "white"},
       frame=True)
ax.set(xlim=(0, 8), xticks=np.arange(1, 8),
       ylim=(0, 8), yticks=np.arange(1, 8))
plt.show()
```

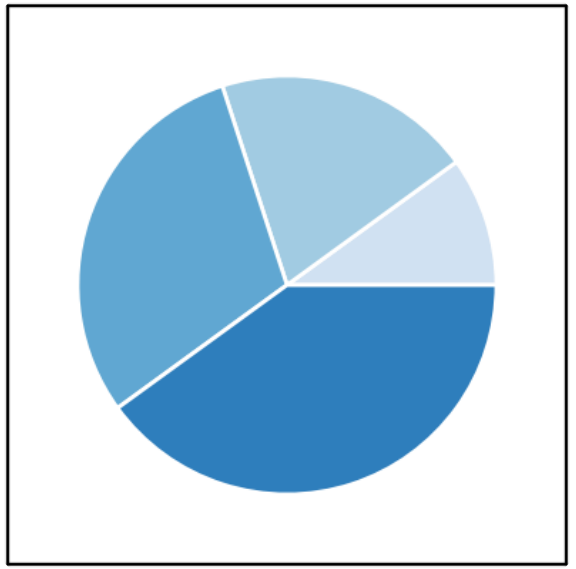

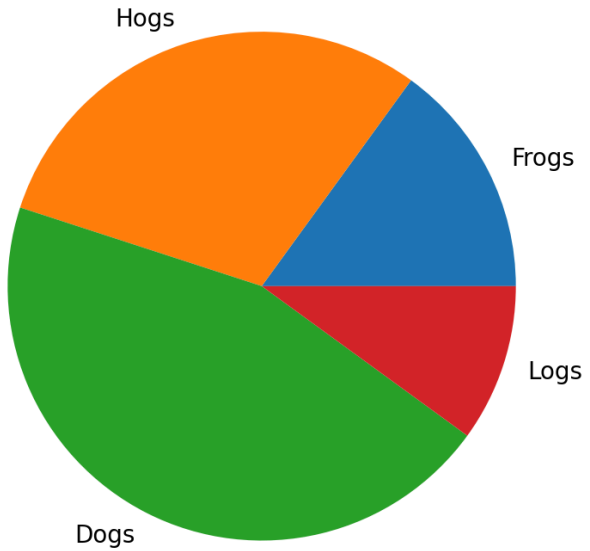
Hogs
Frogs
Logs
Dogs

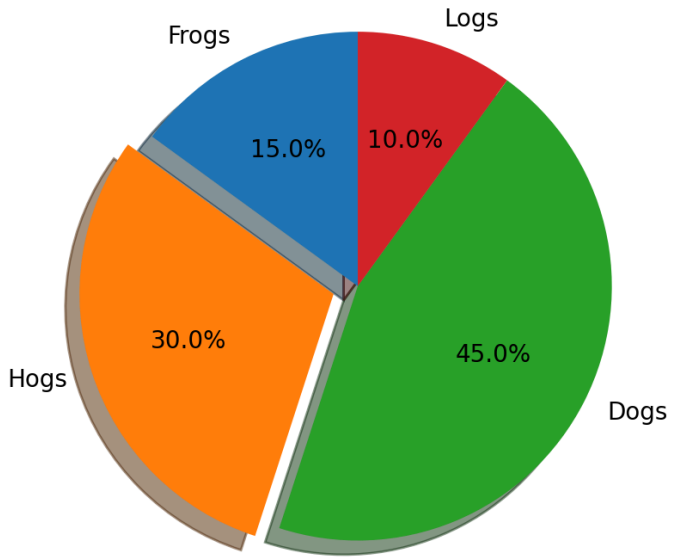
Frogs
Logs
15.0%
10.0%
30.0%
45.0%
Hogs
Dogs

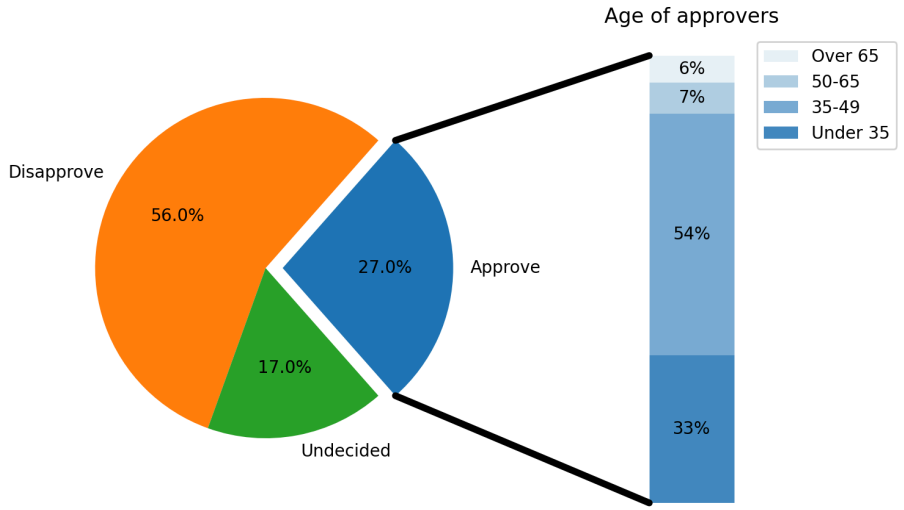
Age of approvers
Over 65
50-65
35-49
Under 35
6%
7%
54%
33%
Disapprove
56.0%
27.0%
Approve
17.0%
Undecided

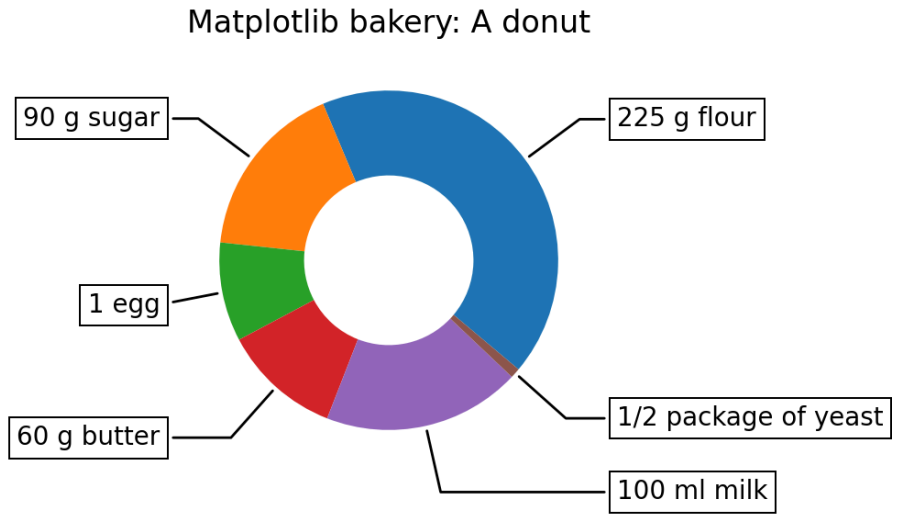
Matplotlib bakery: A donut
90 g sugar
225 g flour
1 egg
1/2 package of yeast
60 g butter
100 ml milk

2.3 数据分布可视化

直方图

```
import matplotlib.pyplot as plt
import numpy as np
plt.style.use('_mpl-gallery')
np.random.seed(1)
x = 4 + np.random.normal(0, 1.5, 200)
fig, ax = plt.subplots()
ax.hist(x, bins=8, linewidth=0.5, edgecolor="white")
ax.set(xlim=(0, 8), xticks=np.arange(1, 8),
       ylim=(0, 56), yticks=np.linspace(0, 56, 9))
plt.show()
```

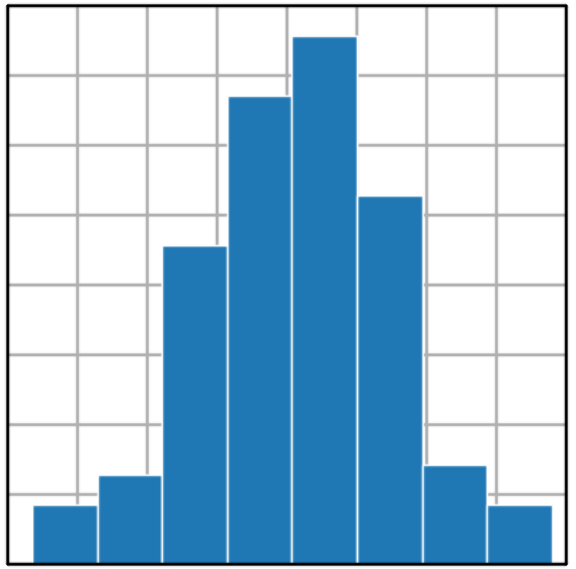

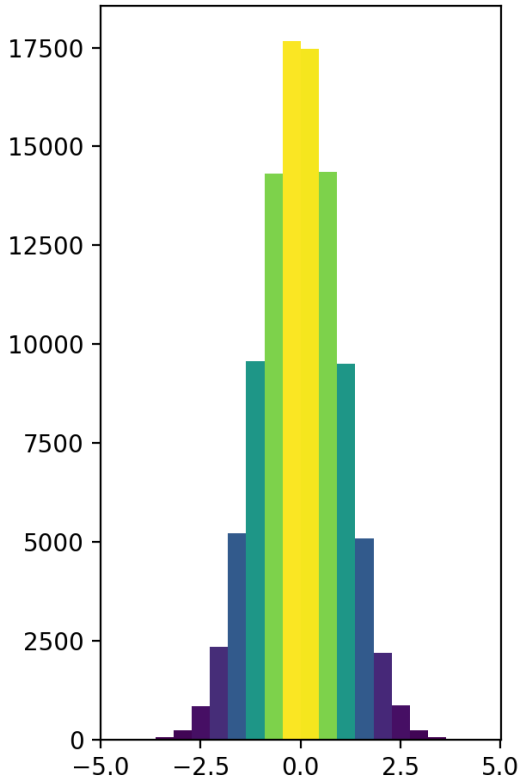
17500
15000
12500
10000
7500
5000
2500
0
−5.0
−2.5
0.0
2.5
5.0

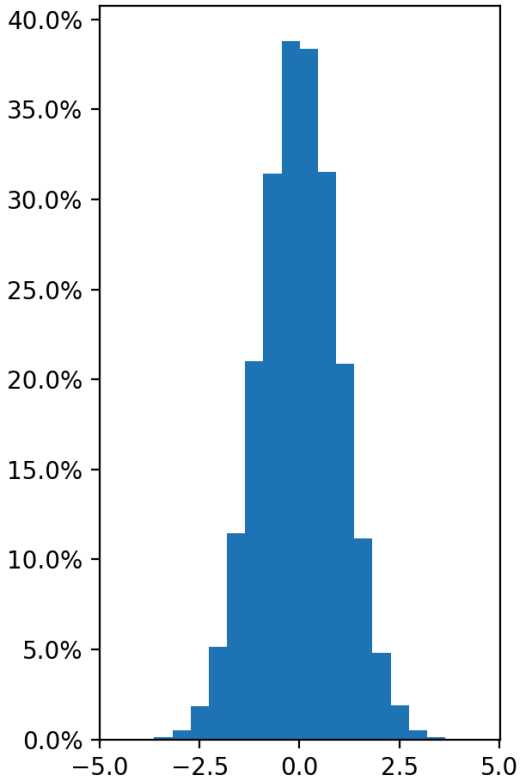
40.0%
35.0%
30.0%
25.0%
20.0%
15.0%
10.0%
5.0%
0.0%
−5.0
−2.5
0.0
2.5
5.0

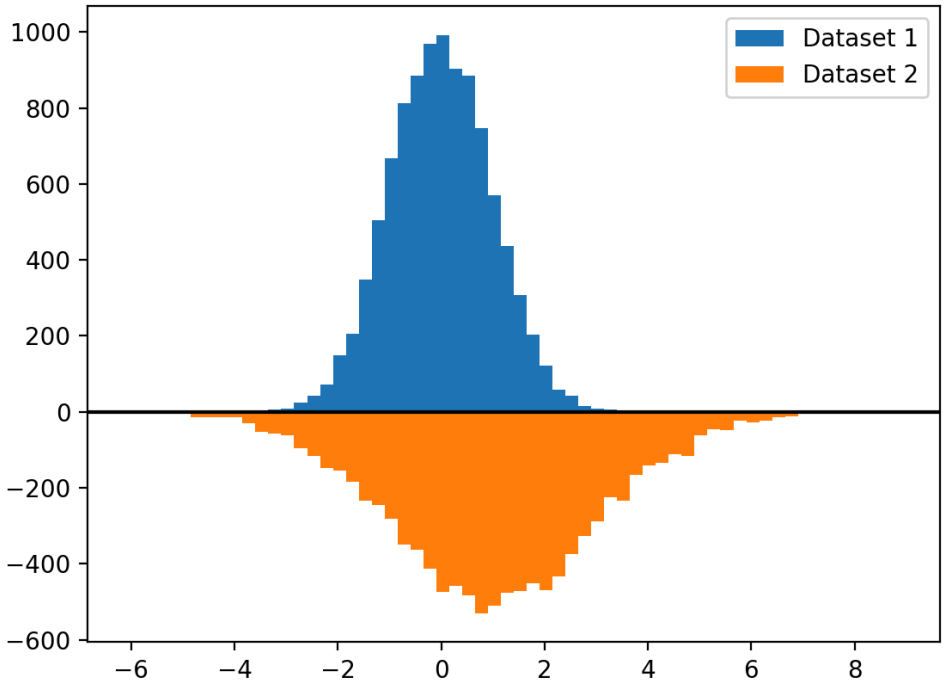
Dataset 1
Dataset 2
1000
800
600
400
200
0
−200
−400
−600
−6
−4
−2
0
2
4
6
8

核密度图

```
import numpy as np
import pandas as pd
import matplotlib.pyplot as plt
plt.style.use('_mpl-gallery')
np.random.seed(42)
data = pd.DataFrame({
    'Group1': np.random.normal(30, 5, 1000),
    'Group2': np.random.normal(40, 8, 1000),
    'Group3': np.random.normal(50, 10, 1000)
})
data.plot.kde()
plt.xlabel('value')
plt.legend(['Group1', 'Group2', 'Group3'], loc="best")
plt.title('KDE Plot')
plt.grid(True)
plt.show()
```

箱线图

```
import matplotlib.pyplot as plt
import numpy as np
plt.style.use('_mpl-gallery')
np.random.seed(10)
D = np.random.normal((3, 5, 4), (1.25, 1.00, 1.25), (100, 3))
fig, ax = plt.subplots()
VP = ax.boxplot(D, positions=[2, 4, 6], widths=1.5,
    patch_artist=True,showmeans=False, showfliers=False,
    medianprops={"color": "white", "linewidth": 0.5},
    boxprops={"facecolor": "C0", "edgecolor": "white", "linewidth": 0.5},
    whiskerprops={"color": "C0", "linewidth": 1.5},
    capprops={"color": "C0", "linewidth": 1.5})
ax.set(xlim=(0, 8), xticks=np.arange(1, 8),
       ylim=(0, 8), yticks=np.arange(1, 8))
plt.show()
```

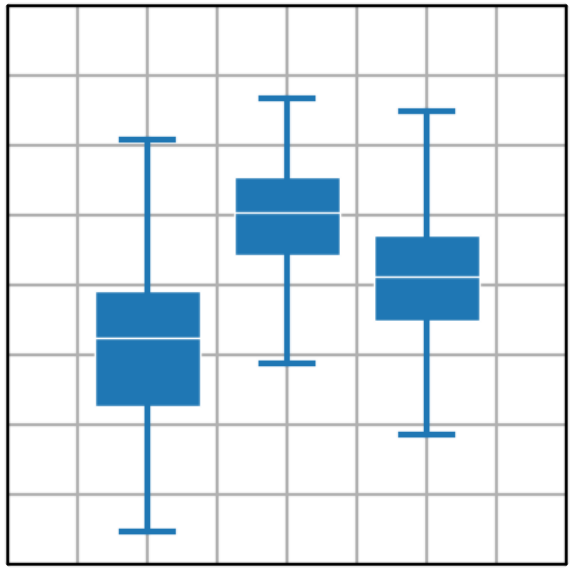

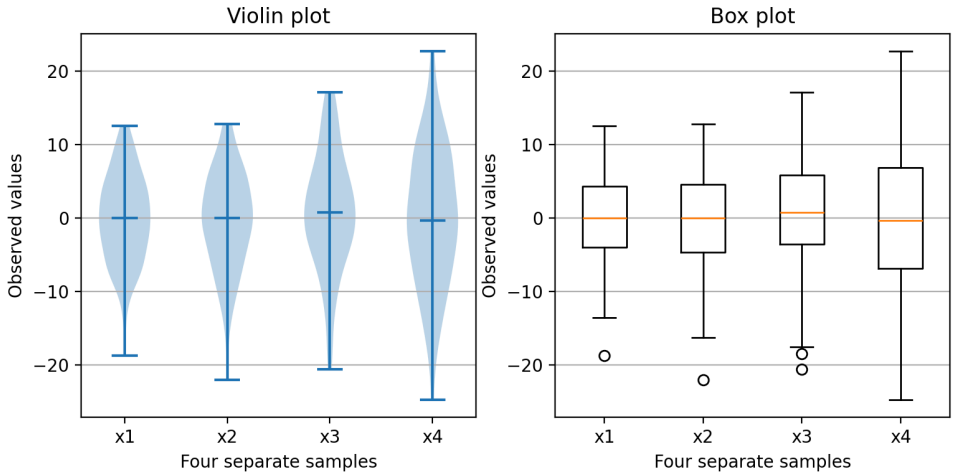
Violin plot
Box plot
Observed values
Four separate samples
x1
x2
x3
x4
20
10
0
−10
−20

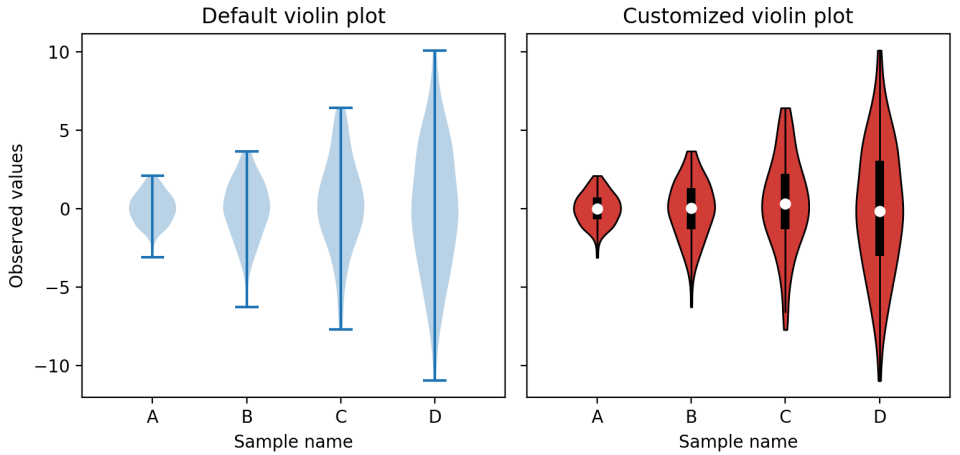
Default violin plot
Customized violin plot
Observed values
Sample name
A
B
C
D
10
5
0
−5
−10

小提琴图

```
import matplotlib.pyplot as plt
import numpy as np
plt.style.use('_mpl-gallery')
np.random.seed(10)
D = np.random.normal((3, 5, 4), (0.75, 1.00, 0.75), (200, 3))
fig, ax = plt.subplots()
vp = ax.violinplot(D, [2, 4, 6], widths=2,
    showmeans=False, showmedians=False, showextrema=False)
for body in vp['bodies']:
    body.set_alpha(0.9)
ax.set(xlim=(0, 8), xticks=np.arange(1, 8),
       ylim=(0, 8), yticks=np.arange(1, 8))
plt.show()
```

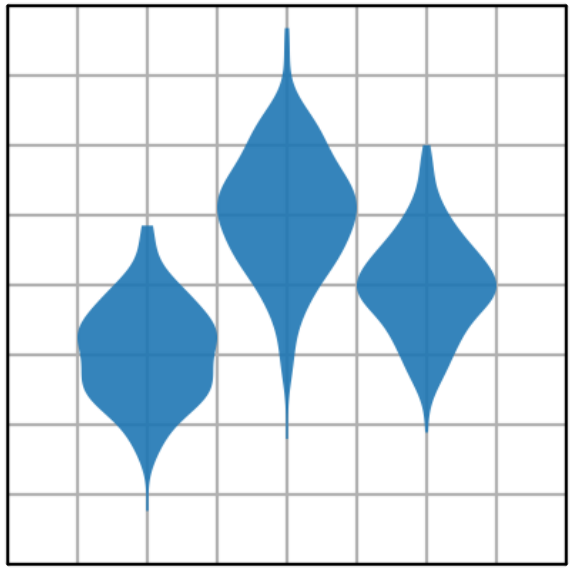

2.4 变量关系可视化

散点图

```
import matplotlib.pyplot as plt
import numpy as np
plt.style.use('_mpl-gallery')
np.random.seed(3)
x = 4 + np.random.normal(0, 2, 24)
y = 4 + np.random.normal(0, 2, len(x))
sizes = np.random.uniform(15, 80, len(x))
colors = np.random.uniform(15, 80, len(x))
fig, ax = plt.subplots()
ax.scatter(x, y, s=sizes, c=colors, vmin=0, vmax=100)
ax.set(xlim=(0, 8), xticks=np.arange(1, 8),
       ylim=(0, 8), yticks=np.arange(1, 8))
plt.show()
```

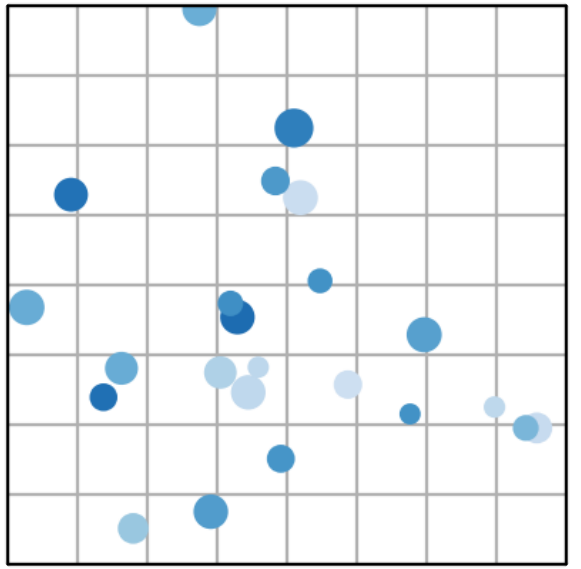

3D散点图

```
import matplotlib.pyplot as plt
import numpy as np
plt.style.use('_mpl-gallery')
np.random.seed(19680801)
n = 100
rng = np.random.default_rng()
xs = rng.uniform(23, 32, n)
ys = rng.uniform(0, 100, n)
zs = rng.uniform(-50, -25, n)
fig, ax = plt.subplots(subplot_kw={"projection": "3d"})
ax.scatter(xs, ys, zs)
ax.set(xticklabels=[],yticklabels=[],zticklabels=[])
plt.show()
```

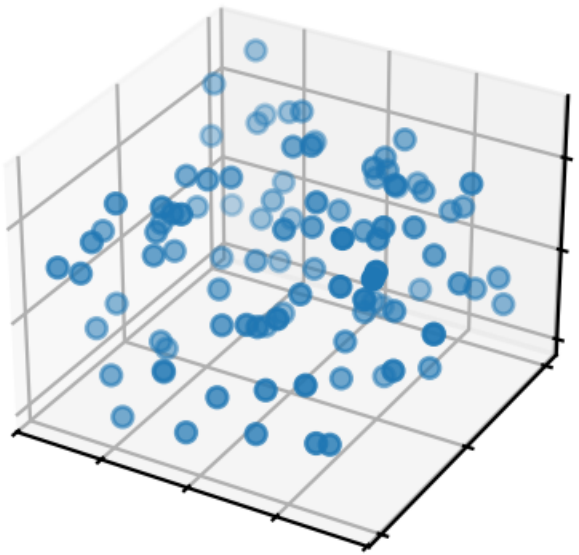

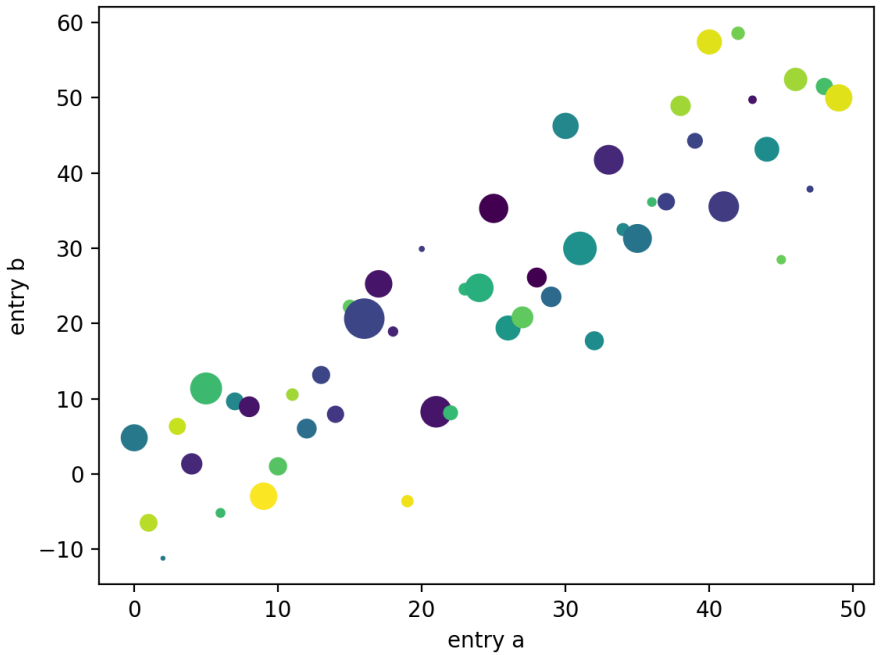
entry b
entry a
60
50
40
30
20
10
0
−10
0
10
20
30
40
50

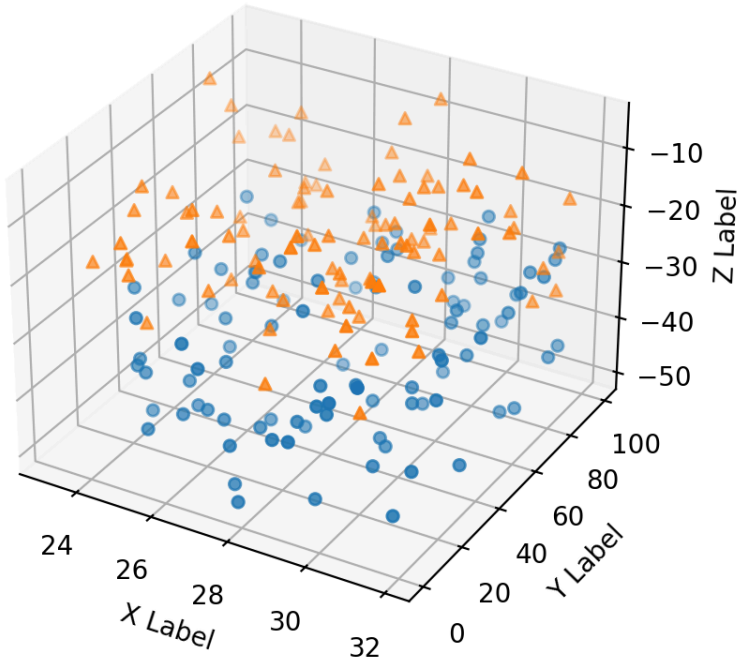
Z Label
−10
−20
−30
−40
−50
X Label
24
26
28
30
32
Y Label
0
20
40
60
80
100

散点图矩阵和相关系数矩阵： Python数据可视化科技图表绘制系列教程（七）-CSDN博客

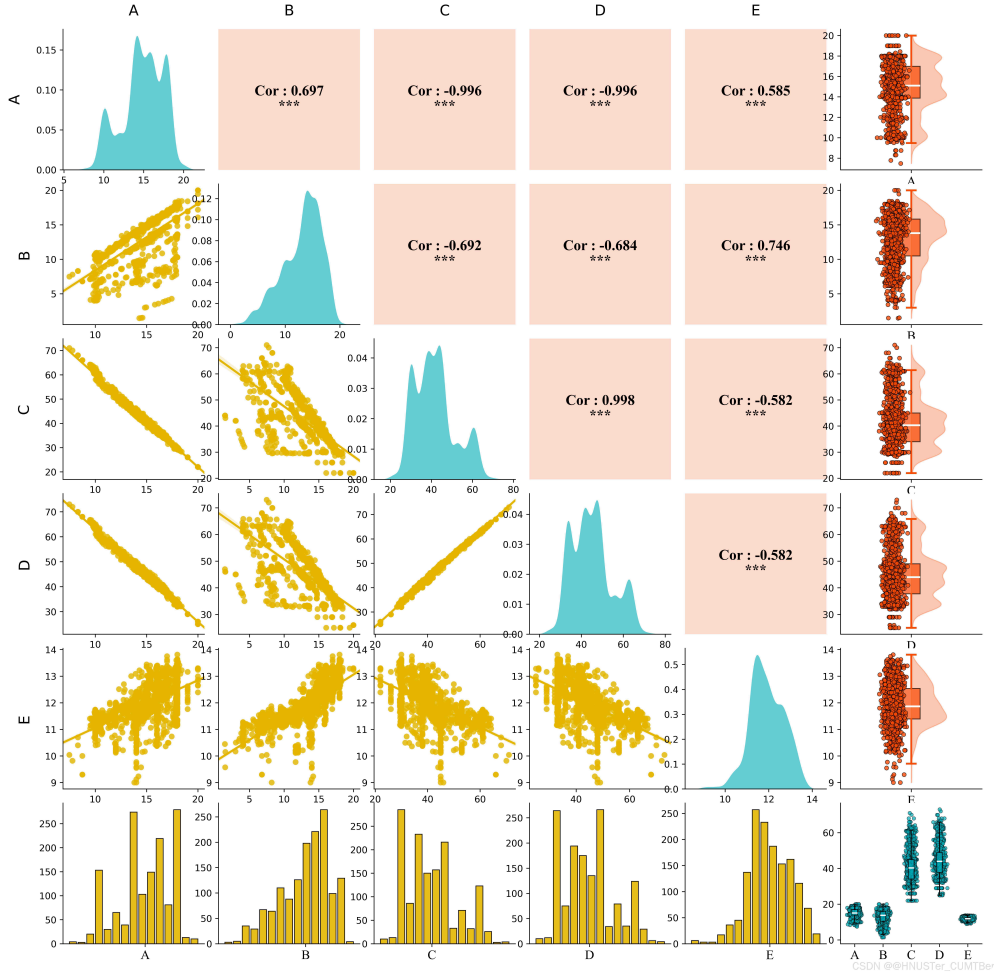

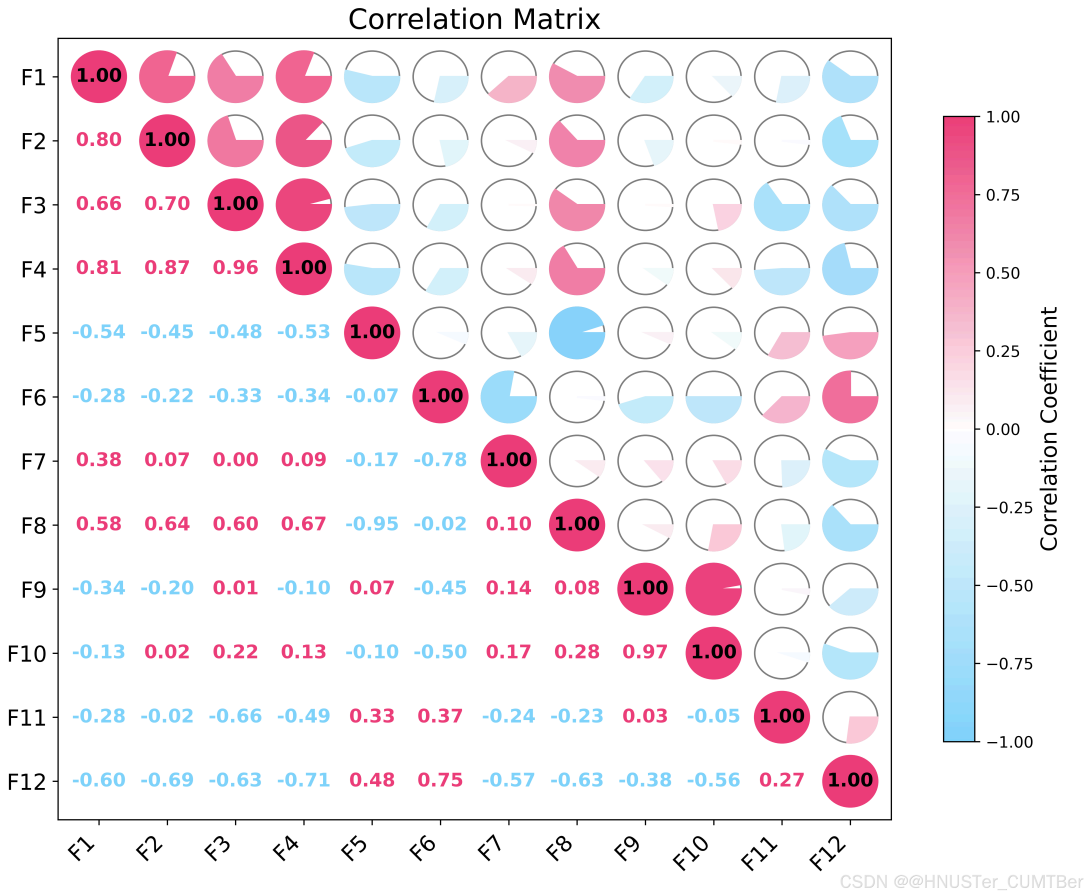

雷达图：Python数据可视化科技图表绘制系列教程（四）-CSDN博客

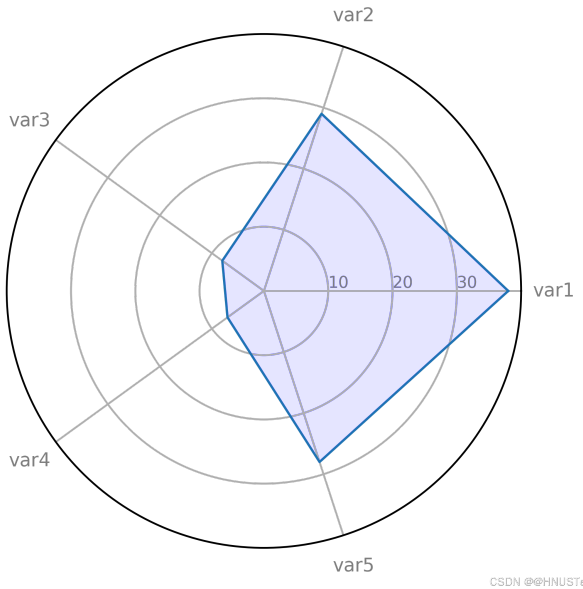

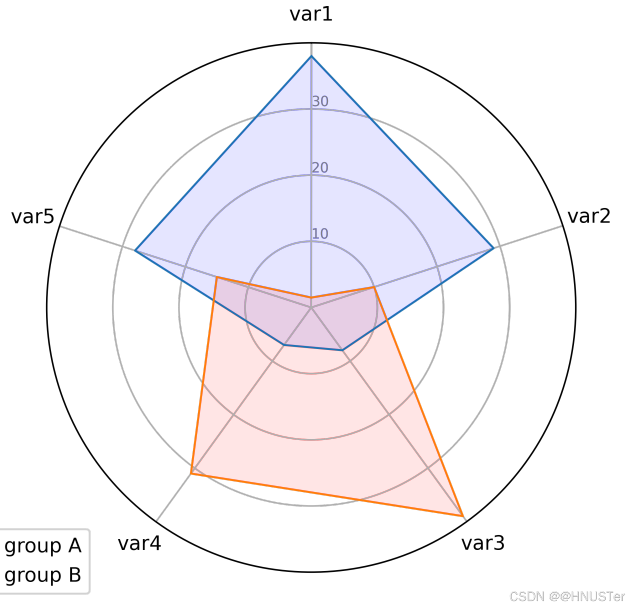

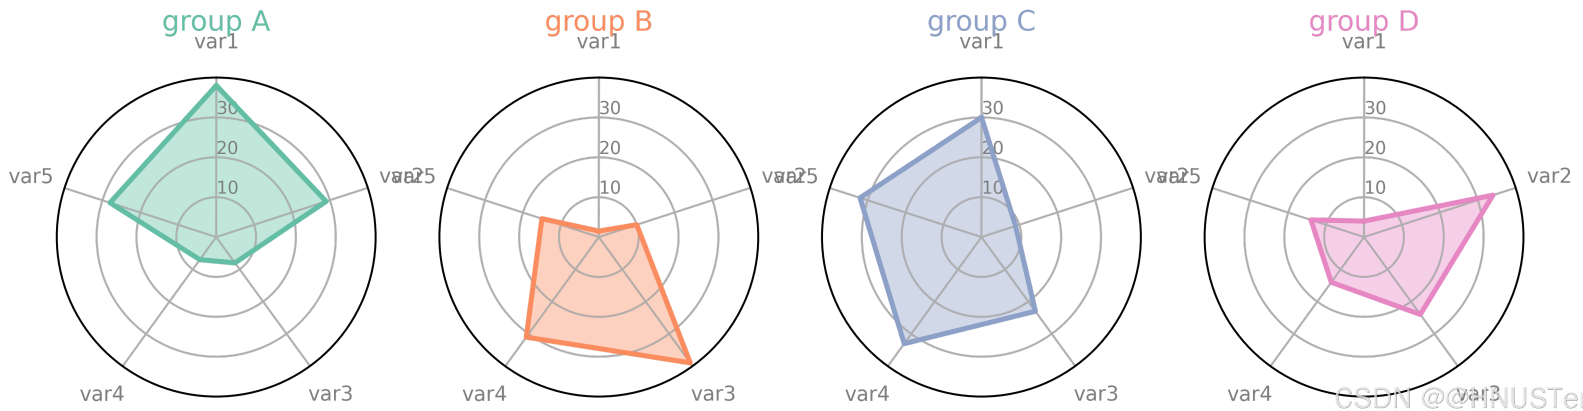

彩蛋：心形线（Cardioid）

```
import numpy as np
theta= np.arange(0, 2*np.pi, 0.05)
r=5*(1-np.sin(theta))
ax = plt.subplot(111, projection='polar')
ax.plot(theta, r, lw=3, c='red')
ax.grid(True)
```

3. 描述性统计

3.1 描述水平的统计量

简单平均数

```
import pandas as pd
example4_1 = pd.read_csv("F:/pydata/example/chap04/example4_1.csv")
example4_1['分数'].mean() # 或写成pd.DataFrame.mean(example4_1)
```

加权平均数

```
import numpy as np
example4_2 = pd.read_csv("F:/pydata/example/chap04/example4_2.csv")
m = example4_2['组中值']
f = example4_2['人数']
x_bar = np.average(a = m, weights = f)
```

中位数

```
example4_1['分数'].median()
```

四分位数

```
np.quantile(example4_1['分数'], q = [0.25,0.75], interpolation = 'linear')
```

百分位数

```
np.quantile(example4_1['分数'], q = [0.1,0.25,0.5,0.75,0.9], interpolation = 'linear')
```

众数

```
example4_1['分数'].mode()
```

```
import scipy
from scipy import stats
mode = stats.mode(example4_1['分数'])
```

3.2 描述差异的统计量

极差

```
R = example4_1['分数'].max() - example4_1['分数'].min()
```

四分位差

```
IQR = np.quantile(example4_1['分数'], q = 0.75) - np.quantile(example4_1['分数'], q = 0.25)
```

方差

```
example4_1['分数'].var()
```

标准差

```
example4_1['分数'].std()
```

加权标准差

```
m = example4_2['组中值']; f = example4_2['人数']
wm = np.average(a = m, weights = f)
var = sum(((m - wm)**2)*f) / (sum(f) - 1)
std = var**(1/2)
```

变异系数

```
example4_10 = pd.read_csv("F:/pydata/example/chap04/example4_10.csv")
mean = example4_10.mean()
std = example4_10.std()
cv = std / mean
np.round(cv,4) # 保留四位小数
```

3.3 描述分布形状的统计量

偏度系数

```
example4_1['分数'].skew()
```

峰度系数

```
example4_1['分数'].kurt()
```

3.4 数据标准化

标准分数

```
z = stats.zscore(example4_1['分数'], ddof = 1) # ddof是自由度
```

极值标准化

```
x = example4_1['分数']
T = (x - min(x))/(max(x) - min(x))
```

4. 课后习题

习题1（数据可视化）

exercise3_3.csv（该数据集来自R语言的mtcars）摘自1974年《美国汽车趋势》杂志，包括32款汽车（1973-1974年款）的油耗、汽车设计和性能等共11个变量。根据该数据集绘制以下图形。

(1)绘制气缸数量(cyl)的直方图，并为直方图叠加核密度曲线。

(2)绘制每加仑油行驶的英里数(mpg)和汽车自重(wt)两个变量的箱线图和小提琴图。

(3)绘制该数据集的散点图矩阵和相关系数矩阵图。

(4)绘制每加仑油行驶的英里数(mpg)、总马力(hp)和汽车自重(wt)3个变量的3D散点图和气泡图。

习题2（描述性统计）

随机抽取50个网络购物的消费者，调查他们某月的网购金额（单位:元），结果见exercise4_1.csv。

(1) 计算平均数、标准差、极差和四分位差。
(2) 计算10%、50%、75%的分位数。
(3) 计算偏度系数和峰度系数，分析网购金额的分布特征。
(4) 计算标准分数和极值标准化值，检测数据的离群点。

作业要求

- 提交代码+对应图形+必要解释，注意标明题号
- 整理成一个pdf文档，命名为学号-姓名如“2410000-张三”
- **DDL**：10月23日24点前发送至助教飞书（2120253538）
- 视代码完整性、作图美观性、答案准确性评分
- 逾期提交、抄袭雷同记0分
- 可以使用AI

欢迎交流~

zzynankai@outlook.com

Bilibili: 西山yu

xishanyu2.github.io