Pandas数据特征分析

DV08

嵩天

www.python123.org

python
弹指之间 · 享受创新

Python数据分析与展示

掌握表示、清洗、统计和展示数据的能力

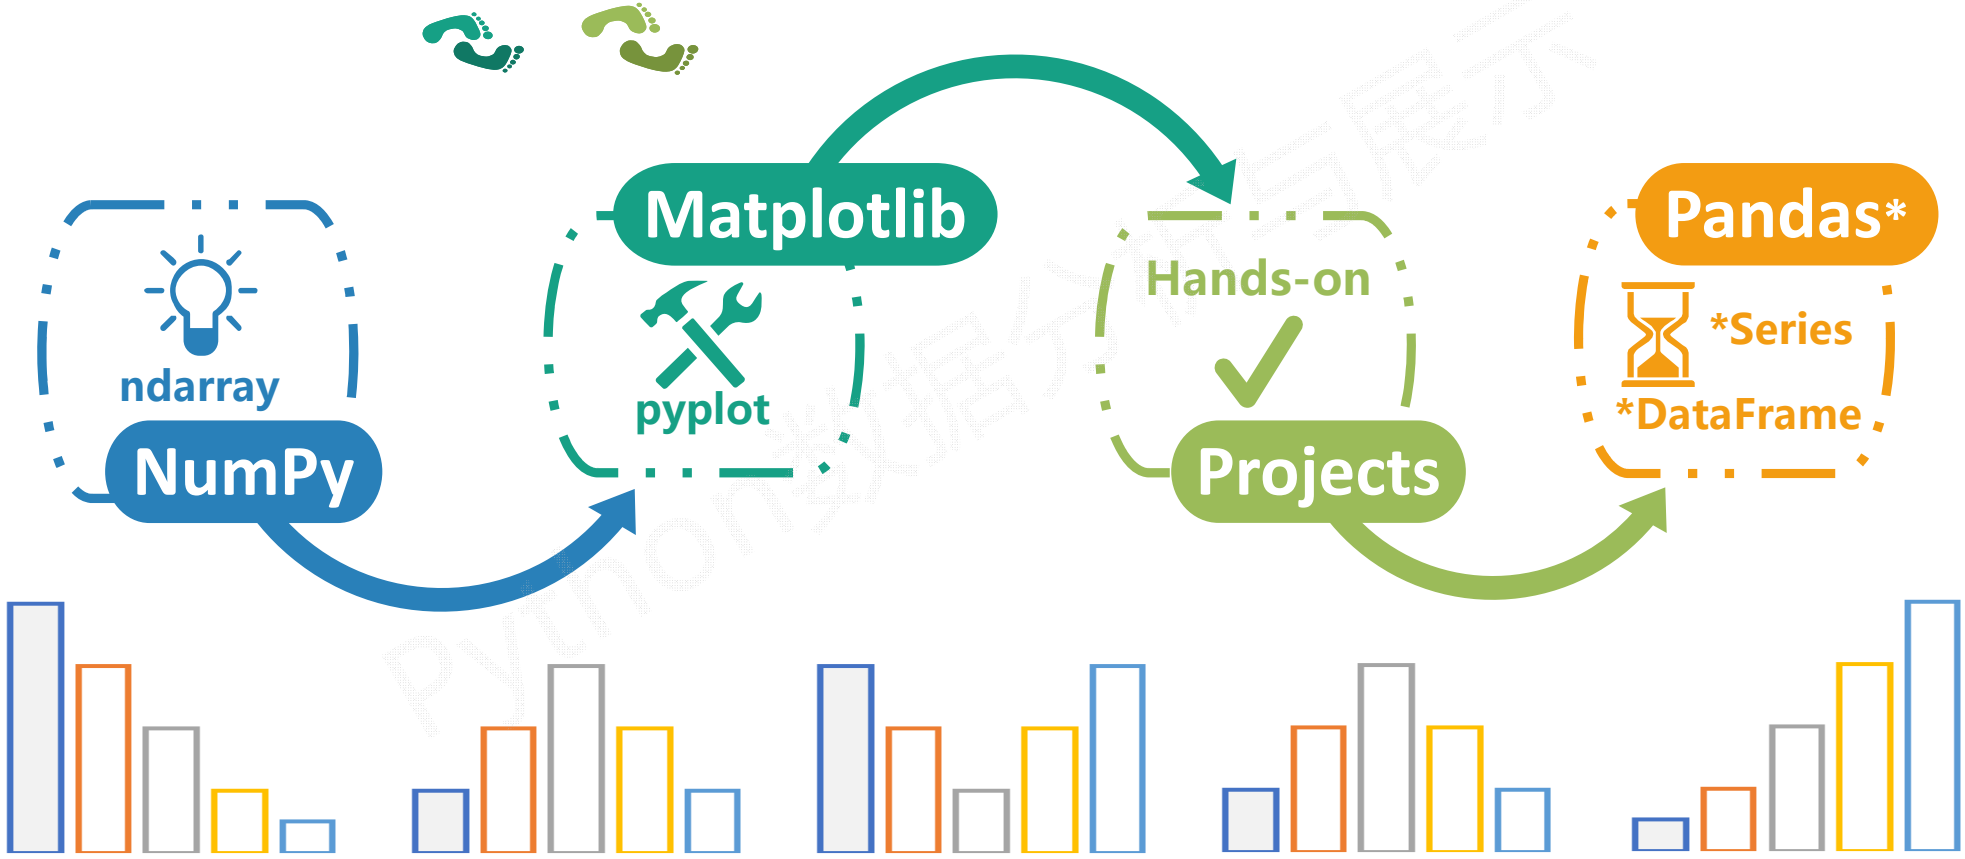

O4X -Tian

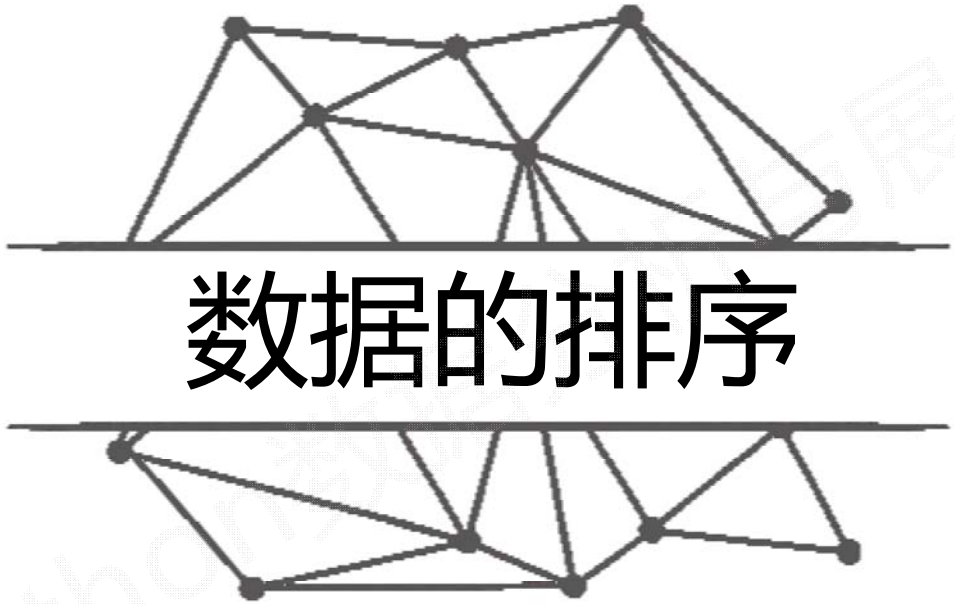

数据的排序

对一组数据的理解

3.1404
3.1413
3.1401 3.1376
3.1398
3.1349

一组数据

表达一个或多个含义

摘要

基本统计（含排序）

分布/累计统计

数据特征

相关性、周期性等

数据挖掘（形成知识）

数据形成有损特征的过程

Pandas库的数据排序

.sort_index()方法在指定轴上根据索引进行排序，默认升序

.sort_index(axis=0, ascending=True)

```
In [358]: import pandas as pd

In [359]: import numpy as np

In [360]: b = pd.DataFrame(np.arange(20).reshape(4,5), index=['c','a','d','b'])

In [361]: b
Out[361]:
    0   1   2   3   4
c   0   1   2   3   4
a   5   6   7   8   9
d  10  11  12  13  14
b  15  16  17  18  19
```

```
In [362]: b.sort_index()
Out[362]:
    0   1   2   3   4
a   5   6   7   8   9
b  15  16  17  18  19
c   0   1   2   3   4
d  10  11  12  13  14

In [363]: b.sort_index(ascending=False)
Out[363]:
    0   1   2   3   4
d  10  11  12  13  14
c   0   1   2   3   4
b  15  16  17  18  19
a   5   6   7   8   9
```

Pandas库的数据排序

.sort_index(axis=0, ascending=True)

```
In [358]: import pandas as pd

In [359]: import numpy as np

In [360]: b = pd.DataFrame(np.arange(20).reshape(4,5), index=['c','a','d','b'])

In [361]: b
Out[361]:
    0   1   2   3   4
c   0   1   2   3   4
a   5   6   7   8   9
d  10  11  12  13  14
b  15  16  17  18  19
```

```
In [366]: c = b.sort_index(axis=1, ascending=False)

In [367]: c
Out[367]:
    4   3   2   1   0
c   4   3   2   1   0
a   9   8   7   6   5
d  14  13  12  11  10
b  19  18  17  16  15

In [368]: c = c.sort_index()

In [369]: c
Out[369]:
    4   3   2   1   0
a   9   8   7   6   5
b  19  18  17  16  15
c   4   3   2   1   0
d  14  13  12  11  10
```

Pandas库的数据排序

.sort_values()方法在指定轴上根据数值进行排序，默认升序

```
Series.sort_values(axis=0, ascending=True)
DataFrame.sort_values(by, axis=0, ascending=True)
```

by : axis轴上的某个索引或索引列表

Pandas库的数据排序

```
.sort_values(by, axis=0, ascending=True)
```

```
In [358]: import pandas as pd

In [359]: import numpy as np

In [360]: b = pd.DataFrame(np.arange(20).reshape(4,5), index=['c','a','d','b'])

In [361]: b
Out[361]:
    0   1   2   3   4
c   0   1   2   3   4
a   5   6   7   8   9
d  10  11  12  13  14
b  15  16  17  18  19
```

```
In [386]: c = b.sort_values(2, ascending=False)

In [387]: c
Out[387]:
    0   1   2   3   4
b  15  16  17  18  19
d  10  11  12  13  14
a   5   6   7   8   9
c   0   1   2   3   4

In [388]: c = c.sort_values('a', axis=1, ascending=False)

In [389]: c
Out[389]:
    4   3   2   1   0
b  19  18  17  16  15
d  14  13  12  11  10
a   9   8   7   6   5
c   4   3   2   1   0
```

Pandas库的数据排序

NaN统一放到排序末尾

```
In [395]: import pandas as pd

In [396]: import numpy as np

In [397]: a = pd.DataFrame(np.arange(12).reshape(3,4), index=['a', 'b', 'c'])

In [398]: a
Out[398]:
   0  1   2   3
a  0  1   2   3
b  4  5   6   7
c  8  9  10  11

In [399]: b = pd.DataFrame(np.arange(20).reshape(4,5), index=['c','a','d','b'])

In [400]: b
Out[400]:
    0   1   2   3   4
c   0   1   2   3   4
a   5   6   7   8   9
d  10  11  12  13  14
b  15  16  17  18  19

In [401]: c = a + b

In [402]: c
Out[402]:
      0     1     2     3   4
a   5.0   7.0   9.0  11.0 NaN
b  19.0  21.0  23.0  25.0 NaN
c   8.0  10.0  12.0  14.0 NaN
d   NaN   NaN   NaN   NaN NaN
```

```
In [403]: c.sort_values(2, ascending = False)
Out[403]:
      0     1     2     3   4
b  19.0  21.0  23.0  25.0 NaN
c   8.0  10.0  12.0  14.0 NaN
a   5.0   7.0   9.0  11.0 NaN
d   NaN   NaN   NaN   NaN NaN

In [404]: c.sort_values(2, ascending = True)
Out[404]:
      0     1     2     3   4
a   5.0   7.0   9.0  11.0 NaN
c   8.0  10.0  12.0  14.0 NaN
b  19.0  21.0  23.0  25.0 NaN
d   NaN   NaN   NaN   NaN NaN
```

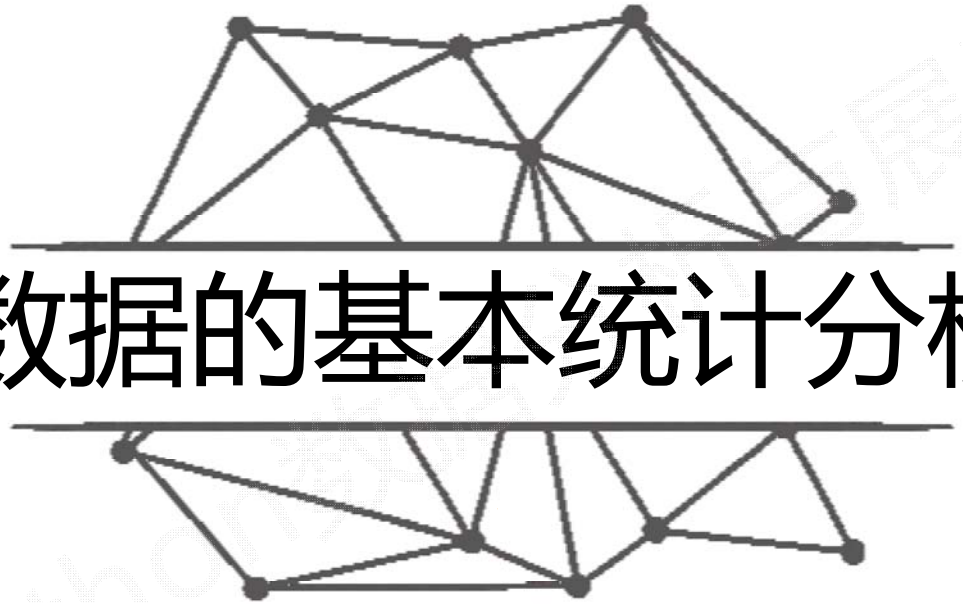

数据的基本统计分析

基本的统计分析函数

适用于Series和DataFrame类型

方法	说明
.sum()	计算数据的总和，按0轴计算，下同
.count()	非NaN值的数量
.mean() .median()	计算数据的算术平均值、算术中位数
.var() .std()	计算数据的方差、标准差
.min() .max()	计算数据的最小值、最大值

基本的统计分析函数

适用于Series类型

方法	说明
.argmin()　.argmax()	计算数据最大值、最小值所在位置的索引位置（自动索引）
.idxmin()　.idxmax()	计算数据最大值、最小值所在位置的索引（自定义索引）

基本的统计分析函数

适用于Series和DataFrame类型

方法	说明
.describe()	针对0轴（各列）的统计汇总

基本的统计分析函数

```
In [425]: import pandas as pd

In [426]: a = pd.Series([9, 8, 7, 6], index=['a','b','c','d'])

In [427]: a
Out[427]:
a    9
b    8
c    7
d    6
dtype: int64

In [428]: a.describe()
Out[428]:
count    4.000000
mean     7.500000
std      1.290994
min      6.000000
25%      6.750000
50%      7.500000
75%      8.250000
max      9.000000
dtype: float64
```

```
In [431]: type(a.describe())
Out[431]: pandas.core.series.Series

In [432]: a.describe()['count']
Out[432]: 4.0

In [433]: a.describe()['max']
Out[433]: 9.0
```

基本的统计分析函数

```
In [434]: import pandas as pd

In [435]: import numpy as np

In [436]: b = pd.DataFrame(np.arange(20).reshape(4,5), index=['c','a','d','b'])

In [437]: b.describe()
Out[437]:
              0          1          2          3          4
count   4.000000   4.000000   4.000000   4.000000   4.000000
mean    7.500000   8.500000   9.500000  10.500000  11.500000
std     6.454972   6.454972   6.454972   6.454972   6.454972
min     0.000000   1.000000   2.000000   3.000000   4.000000
25%     3.750000   4.750000   5.750000   6.750000   7.750000
50%     7.500000   8.500000   9.500000  10.500000  11.500000
75%    11.250000  12.250000  13.250000  14.250000  15.250000
max    15.000000  16.000000  17.000000  18.000000  19.000000
```

```
In [443]: type(b.describe())
Out[443]: pandas.core.frame.DataFrame

In [444]: b.describe().ix['max']
Out[444]:
0    15.0
1    16.0
2    17.0
3    18.0
4    19.0
Name: max, dtype: float64

In [445]: b.describe()[2]
Out[445]:
count     4.000000
mean      9.500000
std       6.454972
min       2.000000
25%       5.750000
50%       9.500000
75%      13.250000
max      17.000000
Name: 2, dtype: float64
```

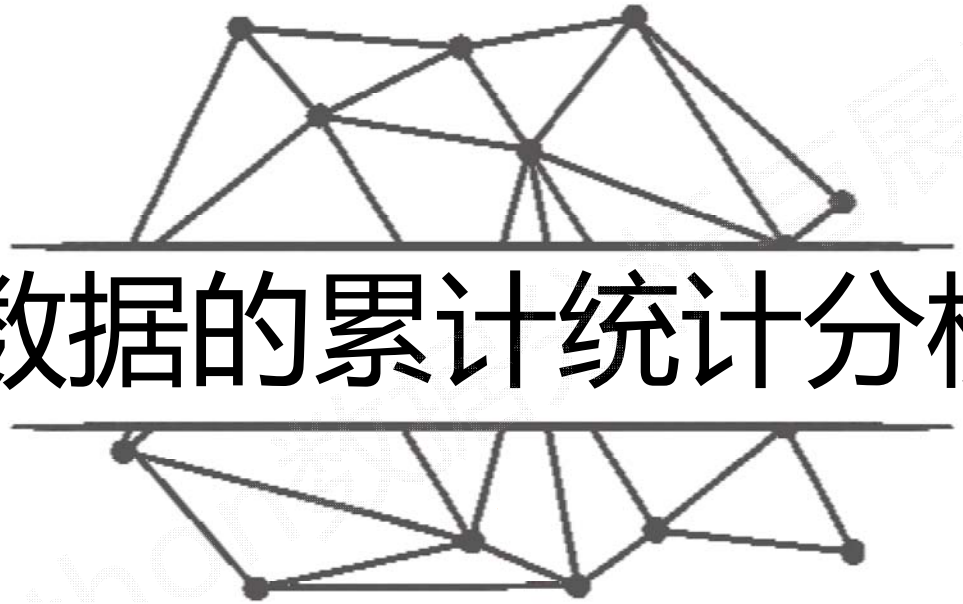

数据的累计统计分析

累计统计分析函数

适用于Series和DataFrame类型，累计计算

方法	说明
.cumsum()	依次给出前1、2、…、n个数的和
.cumprod()	依次给出前1、2、…、n个数的积
.cummax()	依次给出前1、2、…、n个数的最大值
.cummin()	依次给出前1、2、…、n个数的最小值

累计统计分析函数

```
In [448]: import pandas as pd

In [449]: import numpy as np

In [450]: b = pd.DataFrame(np.arange(20).reshape(4,5), index=['c','a','d','b'])

In [451]: b
Out[451]:
    0   1   2   3   4
c   0   1   2   3   4
a   5   6   7   8   9
d  10  11  12  13  14
b  15  16  17  18  19
```

```
In [452]: b.cumsum()
Out[452]:
    0   1   2   3   4
c   0   1   2   3   4
a   5   7   9  11  13
d  15  18  21  24  27
b  30  34  38  42  46
```

```
In [453]: b.cumprod()
Out[453]:
    0     1     2     3     4
c   0     1     2     3     4
a   0     6    14    24    36
d   0    66   168   312   504
b   0  1056  2856  5616  9576
```

```
In [454]: b.cummin()
Out[454]:
   0  1  2  3  4
c  0  1  2  3  4
a  0  1  2  3  4
d  0  1  2  3  4
b  0  1  2  3  4
```

```
In [455]: b.cummax()
Out[455]:
    0   1   2   3   4
c   0   1   2   3   4
a   5   6   7   8   9
d  10  11  12  13  14
b  15  16  17  18  19
```

累计统计分析函数

适用于Series和DataFrame类型，滚动计算（窗口计算）

方法	说明
.rolling(w).sum()	依次计算相邻w个元素的和
.rolling(w).mean()	依次计算相邻w个元素的算术平均值
.rolling(w).var()	依次计算相邻w个元素的方差
.rolling(w).std()	依次计算相邻w个元素的标准差
.rolling(w).min() .max()	依次计算相邻w个元素的最小值和最大值

累计统计分析函数

```
In [448]: import pandas as pd

In [449]: import numpy as np

In [450]: b = pd.DataFrame(np.arange(20).reshape(4,5), index=['c','a','d','b'])

In [451]: b
Out[451]:
    0   1   2   3   4
c   0   1   2   3   4
a   5   6   7   8   9
d  10  11  12  13  14
b  15  16  17  18  19
```

```
In [465]: b.rolling(2).sum()
Out[465]:
      0     1     2     3     4
c   NaN   NaN   NaN   NaN   NaN
a   5.0   7.0   9.0  11.0  13.0
d  15.0  17.0  19.0  21.0  23.0
b  25.0  27.0  29.0  31.0  33.0

In [466]: b.rolling(3).sum()
Out[466]:
      0     1     2     3     4
c   NaN   NaN   NaN   NaN   NaN
a   NaN   NaN   NaN   NaN   NaN
d  15.0  18.0  21.0  24.0  27.0
b  30.0  33.0  36.0  39.0  42.0
```

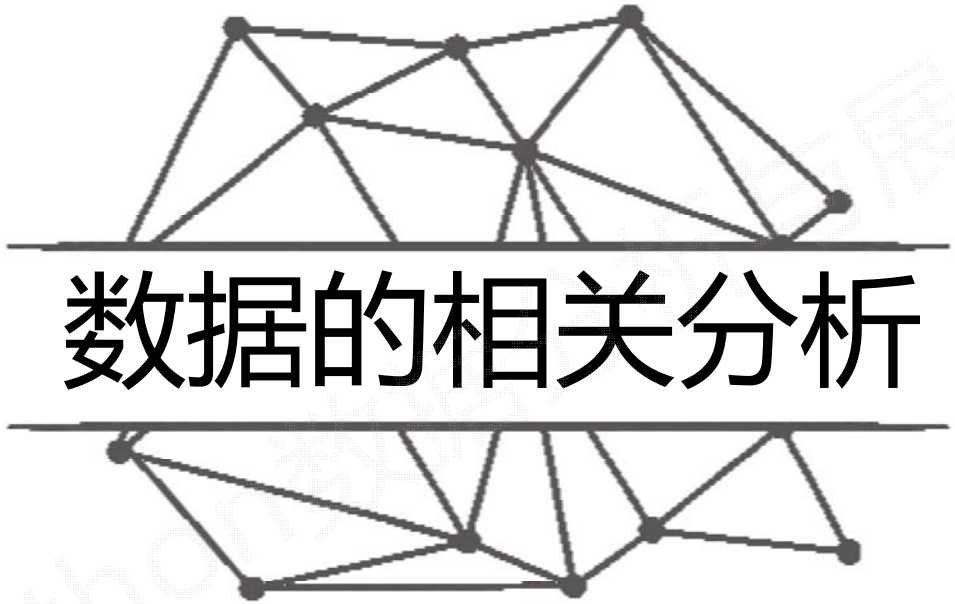

数据的相关分析

相关分析

两个事物，表示为X和Y，如何判断它们之间的存在相关性？

相关性

- X增大，Y增大，两个变量正相关
- X增大，Y减小，两个变量负相关
- X增大，Y无视，两个变量不相关

协方差

两个事物，表示为X和Y，如何判断它们之间的存在相关性？

$$cov(X,Y) = \frac{\sum_{i=1}^{n}(X_i - \bar{X})(Y_i - \bar{Y})}{n-1}$$

- 协方差>0，X和Y正相关
- 协方差<0，X和Y负相关
- 协方差=0，X和Y独立无关

Pearson相关系数

两个事物，表示为X和Y，如何判断它们之间的存在相关性？

$$r = \frac{\sum_{i=1}^{n}(x_i - \bar{x})(y_i - \bar{y})}{\sqrt{\sum_{i=1}^{n}(x_i - \bar{x})^2}\sqrt{\sum_{i=1}^{n}(y_i - \bar{y})^2}}$$

- 0.8-1.0 极强相关
- 0.6-0.8 强相关
- 0.4-0.6 中等程度相关
- 0.2-0.4 弱相关
- 0.0-0.2 极弱相关或无相关

r取值范围[-1,1]

相关分析函数

适用于Series和DataFrame类型

方法	说明
.cov()	计算协方差矩阵
.corr()	计算相关系数矩阵，Pearson、Spearman、Kendall等系数

实例：房价增幅与M2增幅的相关性

```
In [484]: import pandas as pd

In [485]: hprice = pd.Series([3.04, 22.93, 12.75, 22.6, 12.33], index=['2008',
'2009', '2010', '2011', '2012'])

In [486]: m2 = pd.Series([8.18, 18.38, 9.13, 7.82, 6.69], index=['2008', '2009',
'2010', '2011', '2012'])

In [487]: hprice.corr(m2)

Out[487]: 0.5239439145220387
```

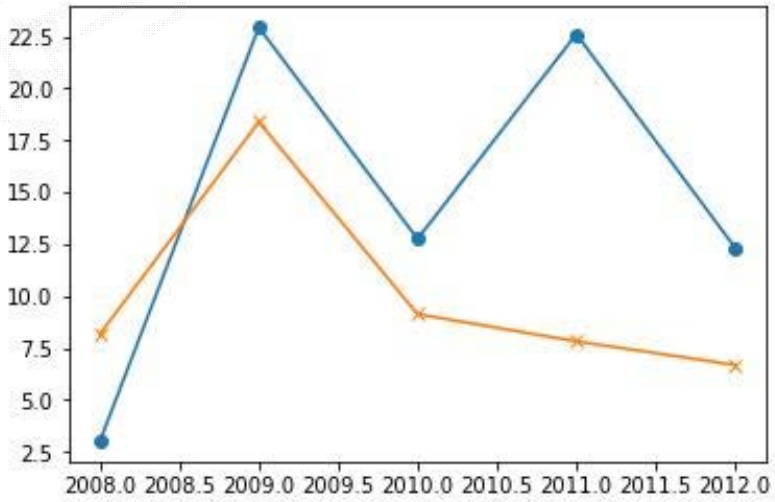

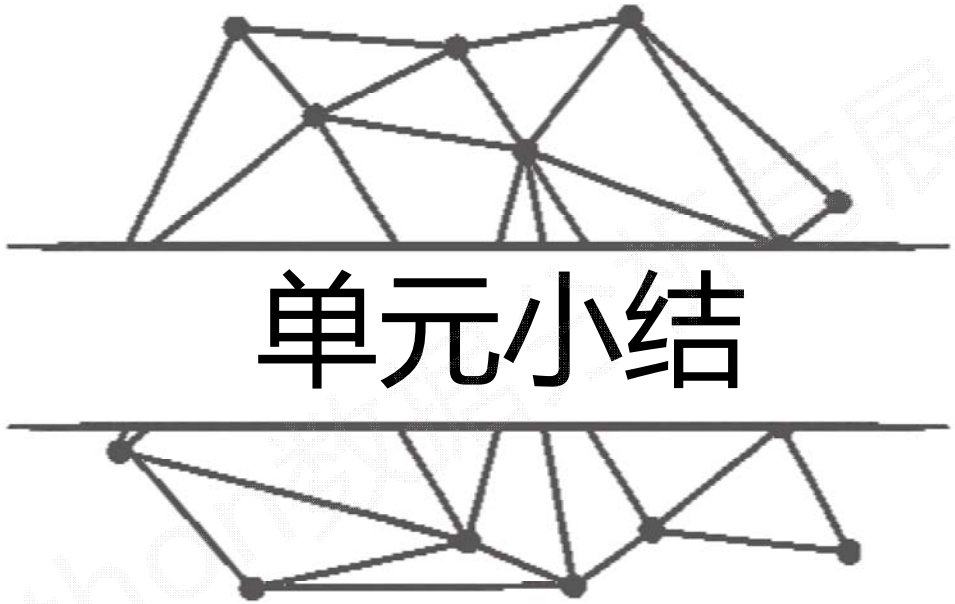

单元小结

Pandas数据特征分析

一组数据的摘要

排序	.sort_index()	.sort_values()
基本统计函数	.describe()	
累计统计函数	.cum*()	.rolling().*()
相关性分析	.corr()	.cov()