Python 数据科学导论
Data Science Introduction with Python

数据分析基础 (下)
Data Analytics Introduction - Part 2

范叶亮

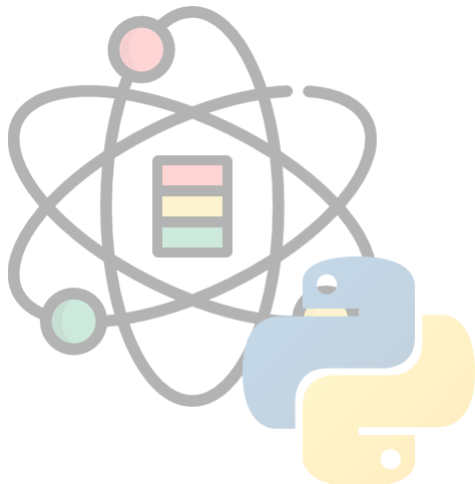

目录

pandas 简介

pandas 简介

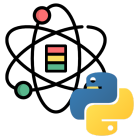

pandas 所包含的数据结构和数据处理工具的设计使得在 Python 中进行数据清洗和分析非常便捷。尽管 pandas 采用了很多 NumPy 的代码风格，但最大的不同在于 pandas 是用来处理表格型或异质类型数据的，而 NumPy 则相反，它更适合处理同质类型的数据。

在后续内容中，我们会使用如下的快捷方式导入 pandas：

```
import pandas as pd
from pandas import Series, DataFrame
```

pandas 中的两个常用的工具数据结构：Series 和 DataFrame 可以为大多数应用提供一个有效易用的基础。

Series

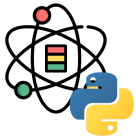

Series 是一种一维的数据型对象，它包含了一个值序列（与 NumPy 中的类型相似），并且包含了数据标签，称之为索引（index），最简单的序列可以仅由一个数组构成：

```
s = pd.Series([1, 2, 3])
s
```

```
## 0    1
## 1    2
## 2    3
## dtype: int64
```

交互式环境中 Series 的表示左边为索引，右边为值。由于我们不为数据指定索引，默认生成的索引是从 0 到 N-1（N 是数据的长度）。可以通过 values 属性和 index 属性分别获取 Series 对象的值和索引。

通过添加索引为每个数据点添加标识：

```
s = pd.Series([1, 2, 3], index=['a', 'b', 'c'])
s
```

```
## a    1
## b    2
## c    3
## dtype: int64
```

```
s.index
```

```
## Index(['a', 'b', 'c'], dtype='object')
```

```
s.values
```

```
## array([1, 2, 3])
```

Series

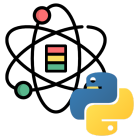

与 NumPy 相比，可以在数据中选取数据时使用标签：

```
s['a']
```

```
## 1
```

```
s['b'] = 6
s[['c', 'b', 'a']]
```

```
## c    3
## b    6
## a    1
## dtype: int64
```

使用 NumPy 函数或 NumPy 风格操作：

```
s[s > 1]
```

```
## b    6
## c    3
## dtype: int64
```

```
s * 2
```

```
## a     2
## b    12
## c     6
## dtype: int64
```

Series

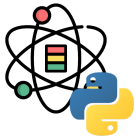

Series 可以被看做是一个长度固定且有序的字典，因为它将索引值和数据值按位置配对。

```
'b' in s
```

```
## True
```

```
'e' in s
```

```
## False
```

可以使用字典生成一个 Series：

```
d = {'Ohio': 35000, 'Texas': 71000,
     'Oregon': 16000, 'Utah': 5000}
```

```
s1 = pd.Series(d)
s1
```

```
## Ohio      35000
## Texas     71000
## Oregon    16000
## Utah       5000
## dtype: int64
```

当把字典传递给 Series 时，产生的 Series 的索引将是排序好的字典键。也可以将字典键按照所需的顺序传递给构造函数参数 index，从而生成的 Series 的索引顺序将与传入的字典键相符。

```
states = ['California', 'Ohio', 'Oregon', 'Texas']
s2 = pd.Series(d, index=states)
```

Series

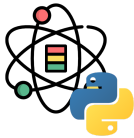

因为 California 没有出现在 d 的键中，它对应的值是 NaN（Not a number），这是 pandas 中用于标记缺失值的方式。因为 Utah 不在 d 中，它被排除在结果外。

pandas 使用 isnull 和 notnull 函数检查缺失值：

```
pd.isnull(s2)
```

```
## California     True
## Ohio          False
## Oregon        False
## Texas         False
## dtype: bool
```

```
pd.notnull(s2)
```

```
## California    False
## Ohio           True
## Oregon         True
## Texas          True
## dtype: bool
```

isnull 和 notnull 也是 Series 实例方法。

自动对齐索引是 Series 的一个重要特性：

```
s1 + s2
```

```
## California         NaN
## Ohio           70000.0
## Oregon         32000.0
## Texas         142000.0
## Utah               NaN
## dtype: float64
```

该特性与数据库中的 join 操作非常类似。

DataFrame

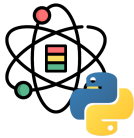

DataFrame 表示的是矩阵的数据表，它包含已排序的列集合，每一列可以是不同的值类型（数值、字符串、布尔值等）。DataFrame 既有行索引也有列索引，它可以被视为一个共享相同索引的 Series 的字典。在 DataFrame 中，数据被存储为一个以上的二维块，而不是列表、字典或其他一维数组的结合。

有多种方式可以构建 DataFrame，其中最常用的方式是利用包含等长度列表或 NumPy 数组的字典来构建 DataFrame：

```
data = {'state': ['Ohio', 'Ohio', 'Ohio', 'Nevada', 'Nevada', 'Nevada'],
        'year': [2000, 2001, 2002, 2000, 2001, 2002],
        'pop': [1.5, 1.7, 3.6, 2.4, 2.9, 3.2]}
df = pd.DataFrame(data)
df
```

```
##     state  year  pop
## 0    Ohio  2000  1.5
## 1    Ohio  2001  1.7
## 2    Ohio  2002  3.6
## 3  Nevada  2000  2.4
## 4  Nevada  2001  2.9
## 5  Nevada  2002  3.2
```

DataFrame

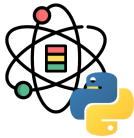

对于大型 DataFrame，head 方法将会选出头部的 n 行：

```
df.head(2)
```

```
##   state  year  pop
## 0  Ohio  2000  1.5
## 1  Ohio  2001  1.7
```

DataFrame 可以按照指定列的顺序排序：

```
pd.DataFrame(data, columns=['year', 'state', 'pop'])
```

```
##    year   state  pop
## 0  2000    Ohio  1.5
## 1  2001    Ohio  1.7
## 2  2002    Ohio  3.6
## 3  2000  Nevada  2.4
## 4  2001  Nevada  2.9
## 5  2002  Nevada  3.2
```

DataFrame 中的一列可以按照字典型标记或属性检索为 Series：

```
df['state']
```

```
## 0      Ohio
## 1      Ohio
## 2      Ohio
## 3    Nevada
## 4    Nevada
## 5    Nevada
## Name: state, dtype: ob
ject
```

```
df.year
```

```
## 0    2000
## 1    2001
## 2    2002
## 3    2000
## 4    2001
## 5    2002
## Name: year, dtype: int
64
```

请注意，返回的 Series 与原 DataFrame 有相同的索引，且 Series 的 names 属性也会被合理的设置。

DataFrame

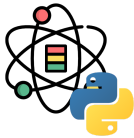

当将列表或数组赋值给一个列时，值的长度必须和 DataFrame 匹配。如果将 Series 赋值给一列时，Series 的索引将会按照 DataFrame 的索引重新排序，并在空缺的地方填充缺失值：

```
val = pd.Series([-1.2, -1.5, -1.7], index=[1, 3, 4])
df['debt'] = val
df
```

```
##     state  year  pop  debt
## 0    Ohio  2000  1.5   NaN
## 1    Ohio  2001  1.7  -1.2
## 2    Ohio  2002  3.6   NaN
## 3  Nevada  2000  2.4  -1.5
## 4  Nevada  2001  2.9  -1.7
## 5  Nevada  2002  3.2   NaN
```

del 方法可以用于移除之前新建的列：

```
del df['debt']
df
```

```
##     state  year  pop
## 0    Ohio  2000  1.5
## 1    Ohio  2001  1.7
## 2    Ohio  2002  3.6
## 3  Nevada  2000  2.4
## 4  Nevada  2001  2.9
## 5  Nevada  2002  3.2
```

从 DataFrame 中选取的列是数据的视图，不是拷贝。因此，对 Series 的修改会映射到 DataFrame 中。如果需要复制，则应当显示地使用 Series 的 copy 方法。

DataFrame

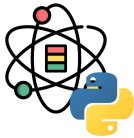

可以用嵌套字典生成 DataFrame：

```
d = {'Neveda': {2001: 2.4, 2002: 2.9},
     'Ohio': {2000: 1.5, 2001: 1.7, 2002: 3.6}}
df = pd.DataFrame(d)
df
```

```
##       Neveda  Ohio
## 2001     2.4   1.7
## 2002     2.9   3.6
## 2000     NaN   1.5
```

可以使用类似 NumPy 的方法对 DataFrame 进行转置：

```
df.T
```

```
##         2001  2002  2000
## Neveda   2.4   2.9   NaN
## Ohio     1.7   3.6   1.5
```

如果 DataFrame 索引和列有 name 属性，也会被显示：

```
df.index.name = 'year'
df.columns.name = 'staste'
df
```

```
## staste  Neveda  Ohio
## year
## 2001       2.4   1.7
## 2002       2.9   3.6
## 2000       NaN   1.5
```

DataFrame 的 values 属性会返回二维的 ndarray：

```
df.values
```

```
## array([[2.4, 1.7],
##        [2.9, 3.6],
##        [nan, 1.5]])
```

索引对象

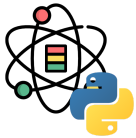

pandas 中的索引对象是用于储存轴标签和其他元数据的（例如：轴名称或标签），在构造 Series 或 DataFrame 时，所使用的任意数组或标签序列都可以在内部转换为索引对象。

```
s = pd.Series(range(3), index=['a', 'b', 'c'])
index = s.index
index
```

```
## Index(['a', 'b', 'c'], dtype='object')
```

```
index[1:]
```

```
## Index(['b', 'c'], dtype='object')
```

索引对象是不可变的，因此用户是无法修改索引对象的，这使得在多种数据结构中分享索引对象是安全的。

与 Python 集合不同，pandas 索引对象可以包含重复标签：

```
dup_idx = pd.Index(['a', 'a', 'b', 'b'])
dup_idx
```

```
## Index(['a', 'a', 'b', 'b'], dtype='object')
```

根据重复标签筛选，会选取所有重复标签对应的数据。

索引对象

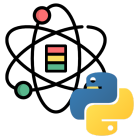

方法	描述	方法	描述
append	将额外的索引对象粘贴到原索引后，产生一个新的索引	difference	计算两个索引的差集
intersection	计算两个索引的交集	union	计算两个索引的并集
isin	计算表示每一个值是否在传值容器中的布尔数组	delete	将位置 i 的元素删除，并产生新的索引
drop	根据传参删除指定索引值，并产生新的索引	insert	在位置 i 插入元素，并产生新的索引
is_monotonic	如果索引序列递增则返回 True	is_unique	如果索引序列唯一则返回 True
unique	计算索引的唯一值序列		

重建索引

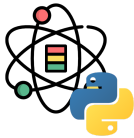

reindex 用于创建一个符合新索引的新对象：

```
s = pd.Series(
    [2, 4, 1, 3], index=['d', 'b', 'a', 'c'])
s
```

```
## d    2
## b    4
## a    1
## c    3
## dtype: int64
```

在 DataFrame 中，reindex 可以改变行索引，列索引，也可以同时改变二者。当仅传入一个序列时，结果中的行会重建索引，列可以使用 columns 关键字重建索引。

```
df = pd.DataFrame(
    np.arange(9).reshape((3, 3)),
    index=['a', 'b', 'c'],
    columns=['Ohio', 'Texas', 'California'])
df.reindex(['a', 'b', 'c', 'd'])
```

```
##    Ohio  Texas  California
## a   0.0    1.0         2.0
## b   3.0    4.0         5.0
## c   6.0    7.0         8.0
## d   NaN    NaN         NaN
```

```
df.reindex(columns=['Texas', 'Utah', 'California'])
```

```
##    Texas  Utah  California
## a      1   NaN           2
## b      4   NaN           5
## c      7   NaN           8
```

重建索引

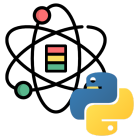

reindex 方法的参数详见下表：

参数	描述
index	新建作为索引的序列，可以是索引示例或任意其他序列型 Python 数据结构，索引使用时无需复制
method	插值方法，ffill 为向前填充，bfill 为向后填充
fill_value	通过重新索引引入缺失数据时使用的替代值
limit	当前向或后向填充时，所需填充的最大尺寸间隔
tolerance	当前向或后向填充时，所需填充的不精确匹配下的最大尺寸间隔
level	匹配 MultiIndex 级别的简单索引
copy	如果为 True，即使新索引等于旧索引，也总是复制底层数据

删除条目

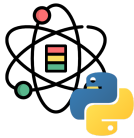

drop 方法返回含有指示值或轴向上删除值的新对象：

```
s = pd.Series(np.arange(3.), index=['a', 'b', 'c'])
s
```

```
## a    0.0
## b    1.0
## c    2.0
## dtype: float64
```

```
new_s = s.drop('b')
new_s
```

```
## a    0.0
## c    2.0
## dtype: float64
```

在 DataFrame 中，索引值可以从轴向上删除：

```
df = pd.DataFrame(
    np.arange(16).reshape((4, 4)),
    index=['Ohio', 'Colorado', 'Utah', 'New York'],
    columns=['one', 'two', 'three', 'four'])
df
```

```
##           one  two  three  four
## Ohio        0    1      2     3
## Colorado    4    5      6     7
## Utah        8    9     10    11
## New York   12   13     14    15
```

删除条目

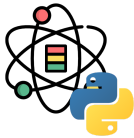

drop 会根据行标签删除值（轴 0）：

```
df.drop(['Colorado', 'Ohio'])
```

```
##           one  two  three  four
## Utah        8    9     10    11
## New York   12   13     14    15
```

可以通过传递 axis=1 或 axis='columns' 删除列：

```
df.drop(['two'], axis=1)
```

```
##           one  three  four
## Ohio        0      2     3
## Colorado    4      6     7
## Utah        8     10    11
## New York   12     14    15
```

```
df.drop(['two', 'four'], axis='columns')
```

```
##           one  three
## Ohio        0      2
## Colorado    4      6
## Utah        8     10
## New York   12     14
```

通过 inplace 可以直接修改原对象而不返回新对象：

```
df.drop('Utah', inplace=True)
df
```

```
##           one  two  three  four
## Ohio        0    1      2     3
## Colorado    4    5      6     7
## New York   12   13     14    15
```

索引，选择和过滤

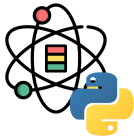

Series 的索引与 NumPy 数组索引类似：

```
s = pd.Series(
    np.arange(4.), index=['a', 'b', 'c', 'd'])
s
```

```
## a    0.0
## b    1.0
## c    2.0
## d    3.0
## dtype: float64
```

```
s['b']
```

```
## 1.0
```

```
s[1]
```

```
## 1.0
```

```
s[2:4]
```

```
## c    2.0
## d    3.0
## dtype: float64
```

索引，选择和过滤

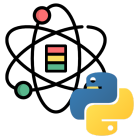

```
s[['b', 'a']]
```

```
## b    1.0
## a    0.0
## dtype: float64
```

```
s[s < 2]
```

```
## a    0.0
## b    1.0
## dtype: float64
```

普通的 Python 切片中是不包含尾部的，Series 的切片与之不同：

```
s['b':'c']
```

```
## b    1.0
## c    2.0
## dtype: float64
```

使用这些方法设置值是会修改 Series 相应的部分：

```
s['b':'c'] = 6
s
```

```
## a    0.0
## b    6.0
## c    6.0
## d    3.0
## dtype: float64
```

索引，选择和过滤

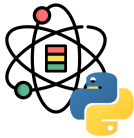

使用单个值或序列，可以从 DataFrame 中索引出一个或多个列：

```
df = pd.DataFrame(
    np.arange(16).reshape((4, 4)),
    index=['Ohio', 'Colorado', 'Utah', 'New York'],
    columns=['one', 'two', 'three', 'four']
)
df
```

```
##           one  two  three  four
## Ohio        0    1      2     3
## Colorado    4    5      6     7
## Utah        8    9     10    11
## New York   12   13     14    15
```

```
df['two']
```

```
## Ohio         1
## Colorado     5
## Utah         9
## New York    13
## Name: two, dtype: int64
```

```
df[['three', 'one']]
```

```
##           three  one
## Ohio          2    0
## Colorado      6    4
## Utah         10    8
## New York     14   12
```

索引，选择和过滤

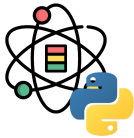

可以根据一个布尔值数组切片或选择数据：

```
df[:2]
```

```
##           one  two  three  four
## Ohio        0    1      2     3
## Colorado    4    5      6     7
```

```
df[df['three'] > 5]
```

```
##           one  two  three  four
## Colorado    4    5      6     7
## Utah        8    9     10    11
## New York   12   13     14    15
```

行选择语法 `df[:2]` 非常方便，传递单个元素或一个列表到 `[]` 中可以选择列。

通过布尔值也可以对 DataFrame 进行索引，布尔值 DataFrame 可以是对标量值进行比较产生：

```
df[df < 6] = 0
df
```

```
##           one  two  three  four
## Ohio        0    0      0     0
## Colorado    0    0      6     7
## Utah        8    9     10    11
## New York   12   13     14    15
```

索引，选择和过滤

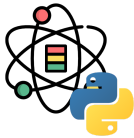

使用 loc 和 iloc 可以对 DataFrame 在行上的标签索引，轴标签（loc）或整数标签（iloc）以 NumPy 风格的语法从 DataFrame 中选出数组的行和列的子集。

```
df.loc['Colorado', ['two', 'three']]
```

```
## two      0
## three    6
## Name: Colorado, dtype: int64
```

```
df.iloc[2, [3, 0, 1]]
```

```
## four    11
## one      8
## two      9
## Name: Utah, dtype: int64
```

除了单个标签或标签列表之外，索引功能还可以用于切片：

```
df.loc[:'Utah', 'two']
```

```
## Ohio        0
## Colorado    0
## Utah        9
## Name: two, dtype: int64
```

```
df.iloc[:, :3][df.three > 5]
```

```
##           one  two  three
## Colorado    0    0      6
## Utah        8    9     10
## New York   12   13     14
```

索引选项

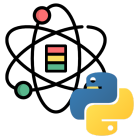

类型	描述
`df[val]`	从 DataFrame 中选择单列或列序列；特殊情况的便利：布尔数组（过滤行），切片（切片行）或布尔值 DataFrame（根据某些标准设置的值）
`df.loc[val]`	根据标签选择 DataFrame 的单行或多行
`df.loc[:, val]`	根据标签选择单列或多列
`df.loc[val1, val2]`	同时选择行和列的一部分
`df.iloc[where]`	根据整数位置选择单行或多行
`df.iloc[:, where]`	根据整数位置选择单列或多列
`df.iloc[where_i, where_j]`	根据整数位置选择行和列
`df.at[label_i, label_j]`	根据行、列标签选择单个标量值
`df.iat[i, j]`	根据行、列整数位置选择单个标量值

算术和数据对齐

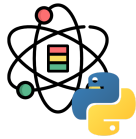

不同索引对象之间的算术行为是 pandas 提供的一项重要特性，将对象相加时，如果存在某个索引对不同，则返回结果的索引将是索引对的并集。

```
s1 = pd.Series(
  [1, 2, 3, 4], index=['a', 'c', 'd', 'e'])
s2 = pd.Series(
  [5, 6, 7, 8, 9], index=['a', 'c', 'e', 'f', 'g'])
```

```
s1
```

```
## a    1
## c    2
## d    3
## e    4
## dtype: int64
```

```
s2
```

```
## a    5
## c    6
## e    7
## f    8
## g    9
## dtype: int64
```

将这些对象相加则会产生：

```
s1 + s2
```

```
## a     6.0
## c     8.0
## d     NaN
## e    11.0
## f     NaN
## g     NaN
## dtype: float64
```

没有交叠的标签位置上，内部数据对齐会产生缺失值。缺失值会在后续的算数操作上产生影响。

算术和数据对齐

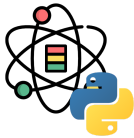

在 DataFrame 中，行和列上都会执行对齐：

```
df1 = pd.DataFrame(
    np.arange(9).reshape(3, 3), columns=list('bcd'),
    index=['Ohio', 'Texas', 'Colorado'])
df2 = pd.DataFrame(
    np.arange(12).reshape(4, 3), columns=list('bde')
,
    index=['Utah', 'Ohio', 'Texas', 'Oregon'])
```

```
df1
```

```
##           b  c  d
## Ohio      0  1  2
## Texas     3  4  5
## Colorado  6  7  8
```

```
df2
```

```
##         b   d   e
## Utah    0   1   2
## Ohio    3   4   5
## Texas   6   7   8
## Oregon  9  10  11
```

将这些对象加在一起，返回一个 DataFrame，它的索引和列是每个 DataFrame 的索引和列的并集。

```
df1 + df2
```

```
##              b   c     d   e
## Colorado   NaN NaN   NaN NaN
## Ohio       3.0 NaN   6.0 NaN
## Oregon     NaN NaN   NaN NaN
## Texas      9.0 NaN  12.0 NaN
## Utah       NaN NaN   NaN NaN
```

由于 c 和 e 列并不是两个 DataFrame 共有的列，这两列中产生了缺失值。对于行标签不同的 DataFrame 对象也是如此。

算术和数据对齐

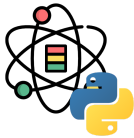

在 df1 上使用 add 方法，我们将 df2 和一个 fill_value 作为参数传入：

```
df1.add(df2, fill_value=0)
```

```
##             b    c     d     e
## Colorado  6.0  7.0   8.0   NaN
## Ohio      3.0  1.0   6.0   5.0
## Oregon    9.0  NaN  10.0  11.0
## Texas     9.0  4.0  12.0   8.0
## Utah      0.0  NaN   1.0   2.0
```

每个方法都有一个以 r 开头的副本，副本方法的参数是翻转的，例如：1 / df1 和 df1.rdiv(1) 是等价的。

方法	描述
add, radd	加法（+）
sub, rsub	减法（-）
div, rdiv	除法（/）
floordiv, rfloordiv	整除（//）
mul, rmul	乘法（*）
pow, rpow	幂次方（**）

算术和数据对齐

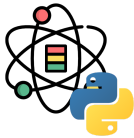

DataFrame 和 Series 间的算数操作与 NumPy 中不同维度数组间的操作类似。

```
df = pd.DataFrame(
    np.arange(12).reshape(4, 3), columns=list('bde')
,
    index=['Utah', 'Ohio', 'Texas', 'Oregon'])
s = df.iloc[0]
```

```
df
```

```
##         b   d   e
## Utah    0   1   2
## Ohio    3   4   5
## Texas   6   7   8
## Oregon  9  10  11
```

```
s
```

```
## b    0
## d    1
## e    2
## Name: Utah, dtype: int
64
```

默认情况下，DataFrame 和 Series 数学操作中会将 Series 索引和 DataFrame 的列进行匹配，并广播到各行：

```
df - s
```

```
##         b  d  e
## Utah    0  0  0
## Ohio    3  3  3
## Texas   6  6  6
## Oregon  9  9  9
```

如果索引值不在 DataFrame 的列中，也不再 Series 的索引中，则对象会重建索引并形成联合。如果想改为在列上进行广播，在行上匹配，则必须使用算法方法中的一种，通过 `axis` 参数进行轴匹配，`axis='index'` 或 `axis=0` 为行匹配。

函数应用和映射

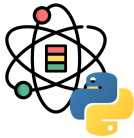

NumPy 的通用函数（逐元素数组方法）对 pandas 对象也有效：

```
df = pd.DataFrame(
    np.random.randn(4, 3), columns=list('bde'),
    index=['Utah', 'Ohio', 'Texas', 'Oregon'])
df
```

```
##                b         d         e
## Utah   -1.748339  0.496195  1.008826
## Ohio    1.654255  0.507529  0.299743
## Texas  -0.243452 -0.805092 -0.412260
## Oregon  0.298319 -2.184280 -0.560191
```

```
np.abs(df)
```

```
##                b         d         e
## Utah    1.748339  0.496195  1.008826
## Ohio    1.654255  0.507529  0.299743
## Texas   0.243452  0.805092  0.412260
## Oregon  0.298319  2.184280  0.560191
```

一个常用的操作是将函数应用到一行或一列的一维数组上，DataFrame 的 `apply` 方法可以实现该功能：

```
f = lambda x: x.max() - x.min()
df.apply(f)
```

```
## b    3.402594
## d    2.691809
## e    1.569017
## dtype: float64
```

函数应用和映射

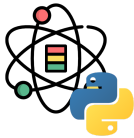

通过传递 axis='columns' 给 apply 函数，函数会被每行调用一次：

```
df.apply(f, axis='columns')
```

```
## Utah      2.757165
## Ohio      1.354511
## Texas     0.561641
## Oregon    2.482599
## dtype: float64
```

逐元素的 Python 函数也可以，例如对 df 中的每个值计算一个格式化的字符串，可以使用 applymap 方法：

```
f = lambda x: '{:2f}'.format(x)
df.applymap(f)
```

```
##                b         d         e
## Utah    -1.748339  0.496195  1.008826
## Ohio     1.654255  0.507529  0.299743
## Texas   -0.243452 -0.805092 -0.412260
## Oregon   0.298319 -2.184280 -0.560191
```

使用 applymap 作为函数名是因为 Series 有 map 方法，可以将一个逐元素的函数应用到 Series 上：

```
df['e'].map(f)
```

```
## Utah       1.008826
## Ohio       0.299743
## Texas     -0.412260
## Oregon    -0.560191
## Name: e, dtype: object
```

排序和排名

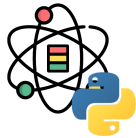

如需按照行或列索引进行字典型排序，需要使用 sort_index 方法，其返回一个新的、排序好的对象：

```
s = pd.Series(range(4), index=list('dabc'))
s.sort_index()
```

```
## a    1
## b    2
## c    3
## d    0
## dtype: int64
```

在 DataFrame 中，可以在各个轴上按索引排序：

```
df = pd.DataFrame(
  np.arange(8).reshape((2, 4)), index=['two', 'one']
,
  columns=['d', 'a', 'b', 'c'])
df.sort_index()
```

```
##      d  a  b  c
## one  4  5  6  7
## two  0  1  2  3
```

```
df.sort_index(axis=1)
```

```
##      a  b  c  d
## two  1  2  3  0
## one  5  6  7  4
```

数据默认会使用升序排序，也可以使用降序：

```
df.sort_index(axis=1, ascending=False)
```

```
##      d  c  b  a
## two  0  3  2  1
## one  4  7  6  5
```

排序和排名

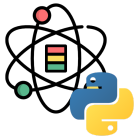

如果根据 Series 的值进行排序，可使用 sort_values：

```
s = pd.Series([4, 7, -3, 2])
s.sort_values()
```

```
## 2   -3
## 3    2
## 0    4
## 1    7
## dtype: int64
```

默认情况下，所有缺失值会排序到尾部：

```
s = pd.Series([4, np.nan, 7, np.nan, -3, 2])
s.sort_values()
```

```
## 4   -3.0
## 5    2.0
## 0    4.0
## 2    7.0
## 1    NaN
## 3    NaN
## dtype: float64
```

排序和排名

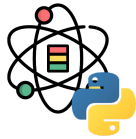

对 DataFrame 排序时，可以使用一列或多列作为排序键，通过设置 sort_values 的参数 by 实现：

```
df = pd.DataFrame({'b': [7, 4, -3], 'a': [0, 1, 0]})
df
```

```
##    b  a
## 0  7  0
## 1  4  1
## 2 -3  0
```

```
df.sort_values(by='b')
```

```
##    b  a
## 2 -3  0
## 1  4  1
## 0  7  0
```

```
df.sort_values(by=['a', 'b'])
```

```
##    b  a
## 2 -3  0
## 0  7  0
## 1  4  1
```

排名函数 rank 可以对数据点从 1 分配名次：

```
s = pd.Series([2, 1, 4, 2])
```

```
s.rank()
```

```
## 0    2.5
## 1    1.0
## 2    4.0
## 3    2.5
## dtype: float64
```

```
s.rank(method='first')
```

```
## 0    2.0
## 1    1.0
## 2    4.0
## 3    3.0
## dtype: float64
```

排序和排名

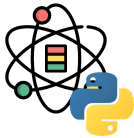

DataFrame 可以对行或列计算排名：

```
df = pd.DataFrame({'b': [4.3, 7, -3, 2],
                   'a': [0, 1, 0, 1],
                   'c':[-2, 5, 8, -2.5]})
```

```
df
```

```
##      b  a    c
## 0  4.3  0 -2.0
## 1  7.0  1  5.0
## 2 -3.0  0  8.0
## 3  2.0  1 -2.5
```

```
df.rank(axis='columns')
```

```
##      b    a    c
## 0  3.0  2.0  1.0
## 1  3.0  1.0  2.0
## 2  1.0  2.0  3.0
## 3  3.0  2.0  1.0
```

在排名中打破评级关系的方法如下：

方法	描述
average	默认：在每个组中分配平均排名
min	对整个组使用最小排名
max	对整个组使用最大排名
first	按照值在数据中出现的次序分配排名
dense	类似 min，但组间排名总是增加 1 而非组元素数量

描述性统计

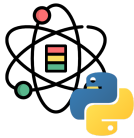

pandas 装配了一个常用数学、统计学方法的集合，与 NumPy 中类似方法相比，其内建了处理缺失值的功能。

```
df = pd.DataFrame(
    [[1.4, np.nan], [7.1, -4.5],
    [np.nan, np.nan], [0.75, -1.3]],
    index=['a', 'b', 'c', 'd'],
    columns=['one', 'two'])
df
```

```
##     one  two
## a  1.40  NaN
## b  7.10 -4.5
## c   NaN  NaN
## d  0.75 -1.3
```

调用 sum 方法返回一个包含列上加和的 Series：

```
df.sum()
```

```
## one    9.25
## two   -5.80
## dtype: float64
```

传入 axis='columns' 或 axis=1 则沿着行求和：

```
df.sum(axis='columns')
```

```
## a    1.40
## b    2.60
## c    0.00
## d   -0.55
## dtype: float64
```

通过 skipna=False 可以不排除 NA 值。

描述性统计

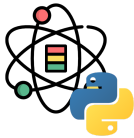

idmax 和 idmin 返回的是间接统计信息，除了归约方法外，有的方法是积累型方法：

```
df.idxmax()
```

```
## one    b
## two    d
## dtype: object
```

```
df.cumsum()
```

```
##     one  two
## a  1.40  NaN
## b  8.50 -4.5
## c   NaN  NaN
## d  9.25 -5.8
```

还有一类方法不是归约型方法也不是积累型方法，describe 即其中之一，它一次性产生多个汇总统计：

```
df.describe()
```

```
##             one       two
## count  3.000000  2.000000
## mean   3.083333 -2.900000
## std    3.493685  2.262742
## min    0.750000 -4.500000
## 25%    1.075000 -3.700000
## 50%    1.400000 -2.900000
## 75%    4.250000 -2.100000
## max    7.100000 -1.300000
```

对于非数值类型数据，则产生另一种汇总统计：

```
pd.Series(['a', 'a', 'b', 'c'] * 4).describe()
```

```
## count     16
## unique     3
## top        a
## freq       8
## dtype: object
```

描述性统计

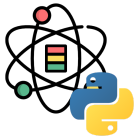

方法	描述	方法	描述
count	非 NA 值个数	describe	各列汇总值
min, max	计算最小/大值	argmin, argmax	计算最小/大值的索引位置
idxmin, idmax	计算最小/大值的索引标签	quantile	计算样本的分位数
sum	加和	mean	均值
median	中位数	mad	平均值的平均绝对偏差
prod	连乘	var, std	样本方差/标准差
skew, kurt	偏度/峰度	cumsum	累加
cummin, cummax	累积值的最小/大值	cumprod	累积
diff	计算第一个算术差值	pct_change	计算百分比

相关性和协方差

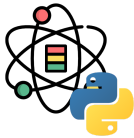

```
import yfinance as yf
d = {ticker: yf.download(ticker, progress=False)
     for ticker in ['AAPL', 'IBM', 'MSFT']}
p = pd.DataFrame({ticker: data['Adj Close']
                  for ticker, data in d.items()})
v = pd.DataFrame({ticker: data['Volume']
                  for ticker, data in d.items()})
```

Series 的 corr 计算的是两个 Series 中的重叠的，非 NA 的，按索引对齐的值的相关性，cov 计算协方差：

```
p['MSFT'].corr(p['IBM'])
```

```
## 0.6625987512744043
```

```
p['MSFT'].cov(p['IBM'])
```

```
## 2271.417584001133
```

DataFrame 的 corr 和 cov 方法会分别以 DataFrame 形式返回相关性和协方差矩阵：

```
p.corr()
```

```
##           AAPL       IBM      MSFT
## AAPL  1.000000  0.664073  0.989356
## IBM   0.664073  1.000000  0.662599
## MSFT  0.989356  0.662599  1.000000
```

```
p.cov()
```

```
##              AAPL          IBM         MSFT
## AAPL  1793.045766  1213.584262  3571.756562
## IBM   1213.584262  1849.656368  2271.417584
## MSFT  3571.756562  2271.417584  6579.436747
```

相关性和协方差

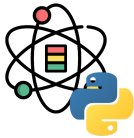

DataFrame 的 `corrwith` 方法可以计算出 DataFrame 行或列与另一个序列或 DataFrame 的相关性。当传入一个 Series 时，会返回一个含有为每列计算相关性值的 Series：

```
p.corrwith(p.IBM)
```

```
## AAPL    0.664073
## IBM     1.000000
## MSFT    0.662599
## dtype: float64
```

传入一个 DataFrame 时，会计算匹配到列名的相关性数值：

```
p.corrwith(v)
```

```
## AAPL   -0.246097
## IBM     0.154202
## MSFT   -0.334653
## dtype: float64
```

传入 `axis='colums'` 会逐行地进行计算。

唯一值、计数和成员属性

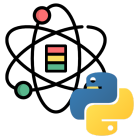

unique 函数可以给出 Series 中的唯一值：

```
s = pd.Series(['c', 'a', 'd', 'a', 'a',
               'b', 'b', 'c', 'c'])
s.unique()
```

```
## array(['c', 'a', 'd', 'b'], dtype=object)
```

sort 方法可以对其进行排序，value_counts 可以计算 Series 包含的值的个数：

```
s.value_counts()
```

```
## c    3
## a    3
## b    2
## d    1
## Name: count, dtype: int64
```

为了方便，返回的 Series 会按照数量降序排序，value_counts 也是有效的 pandas 顶层方法，也可以用于任意数组或序列：

```
pd.value_counts(s.values, sort=False)
```

```
## c    3
## a    3
## d    1
## b    2
## Name: count, dtype: int64
```

唯一值、计数和成员属性

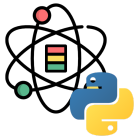

isin 执行向量化的成员属性检查，还可以将数据集以 Series 或 DataFrame 一列的形式过滤为数据集的值子集：

```
s
```

```
## 0    c
## 1    a
## 2    d
## 3    a
## 4    a
## 5    b
## 6    b
## 7    c
## 8    c
## dtype: object
```

```
s.isin(['b', 'c'])
```

```
## 0     True
## 1    False
## 2    False
## 3    False
## 4    False
## 5     True
## 6     True
## 7     True
## 8     True
## dtype: bool
```

与 isin 相关的 Index.get_indexer 方法，可以提供一个索引数组，这个索引数组可以将可能非唯一值数组转换为另一个唯一值数组：

```
to_match = pd.Series(['c', 'a', 'b', 'b', 'c', 'a'])
unique_vals = pd.Series(['c', 'b', 'a'])
pd.Index(unique_vals).get_indexer(to_match)
```

```
## array([0, 2, 1, 1, 0, 2])
```

数据载入和存储

数据读取

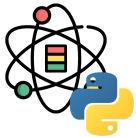

将表格型数据读取为 DataFrame 对象是 pandas 的重要特性，下表为常用的数据读取函数：

函数	描述
read_csv	从文件、URL 或文件型对象读取分隔好的数据，默认分隔符为 ,
read_table	从文件、URL 或文件型对象读取分隔符的数据，默认分隔符为 \t
read_fwf	从特定宽度格式的文件中读取数据（无分隔符）
read_clipboard	read_table 的剪切板版本
read_excel	从 Excel 的 XLS 或 XLSX 文件中读取表格数据
read_hdf	读取用 pandas 存储的 HDF5 文件
read_html	从 HTML 文件中读取所有表格数据

(接下表)

数据读取

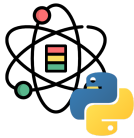

(接上表)

函数	描述
read_json	从 JSON 字符串中读取数据
read_msgpack	读取 MessagePackage 二进制格式的 pandas 数据
read_pickle	读取以 Python pickle 格式存储的任意对象
read_sas	读取存储在 SAS 系统中定制存储格式的 SAS 数据集
read_sql	将 SQL 查询的结果读取为 pandas 的 DataFrame
read_stata	读取 Stata 格式的数据集
read_feather	读取 Feather 二进制格式

数据读取

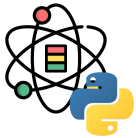

read_csv / read_table 的函数参数如下表所示：

参数	描述
path	表明文件系统位置的字符串，URL 或文件型对象
sep, delimiter	用于分割每行字段的字符序列或正则表达式
header	用作列名的行号，默认是 0，如果没有列名则为 None
index_col	用作结果中行索引的列号或列名，可以是一个单一的名称/数字，也可以是一个分层索引
names	结果的列名列表，和 header=None 一起用
skiprows	从文件开头处起，需要跳过的行数或行号列表
comment	在行结尾处分隔注释的字符

(接下表)

数据读取

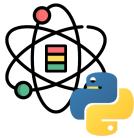

(接上表)

参数	描述
parse_dates	尝试将数据解析为 datetime，默认是 False，如果为 True，将尝试解析所有的列。也可以指定列号或列名列表来进行解析。如果列表的元素是元组或列表，将会把多个列组合在一起进行解析（例如：日期/时间将拆分为两列）
keep_date_col	如果连接列到解析日期上，保留被连接的列，默认是 False
converters	包含列名称映射到函数的字典（例如：{'foo': f} 会把函数 f 应用到 foo 列
dayfirst	解析非明确日期时，按照国际格式处理（例如：7/6/2012 -> June 7, 2012），默认为 False
date_parser	用于解析日期的函数

(接下表)

数据读取

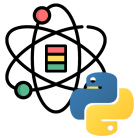

(接上表)

参数	描述
nrows	从文件开头处理读入的行数
iterator	返回一个 TextParser 对象，用于零散地读入文件
chunksize	用于迭代的块大小
skip_footer	忽略文件尾部的行数
verbose	打印各种解析器输出的信息，比如位于非数值列中的缺失值数量
encoding	Unicode 文本编码（例如：utf-8 用于表示 UTF-8 编码的文本）
squeeze	如果解析数据只包含一列，返回一个 Series
thousands	千位分隔符（例如：，或 .）

数据写入

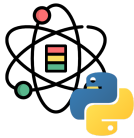

使用 DataFrame 的 to_csv 方法，我们可以将数据导出为逗号分隔符文件：

```
df = pd.DataFrame([['one', 'two', 'three'],
                   [1, 2, 3], [3.0, np.nan, 6.6]],
                  columns=['a', 'b', 'c'])
```

```
df.to_csv('tmp.csv')
# ,a,b,c
# 0,one,two,three
# 1,1,2,3
# 2,3.0,,6.6
```

通过 sep 可是设置分隔符：

```
import sys
df.to_csv(sys.stdout, sep='|')
```

```
## |a|b|c
## 0|one|two|three
## 1|1|2|3
## 2|3.0||6.6
```

na_rep 可以对缺失值进行标注，index 和 header 用于控制是否显示行号和列名：

```
df.to_csv(sys.stdout, na_rep='NULL',
          index=False, header=False)
```

```
## one,two,three
## 1,2,3
## 3.0,NULL,6.6
```

CSV 分隔格式

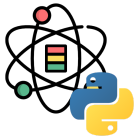

参数	描述
delimiter	一般用于分隔字段的字符，默认是 ,
lineterminator	行终止符，默认是 \r\n，读取器会忽略行终止符并识别跨平台行终止符
quotechar	用在含有特殊字符字段中的引号，默认是 "
quoting	引用惯例。选项包括 csv.QUOTE_ALL（引用所有的字段），csv.QUOTE_MINIMAL（只是用特殊字符，如分隔符），csv.QUOTE_NONMUERIC 和 csv.QUOTE_NONE（不引用），默认为 QUOTE_MINIMAL。
skipinitialspace	忽略每个分隔符后的空白，默认是 False
doublequote	如何处理字段内部的引号，如果为 True，则是双引号
escapechar	当引用设置为 csv.QUOTE_NONE 时用于转义分隔符的字符串，默认是禁用的

JSON 数据

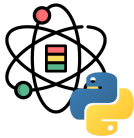

JSON（JavaScript Object Notation）是一种常用的数据格式，其基本类型包括：对象（字典）、数组（列表）、字符串、数字、布尔值和空值，对象中的所有键必须是字符串。在 Python 中可以利用内建的 `json` 模块处理 JSON。

```
js = '''
{
  "name": "Wes",
  "place_lived": ["United States", "Spain", "Germany"],
  "pet": null,
  "siblings": [{"name": "Scott", "age": 30, "pets": ["Zeus", "Zuko"]},
               {"name": "Katie", "age": 38, "pets": ["Sixes", "Stache", "Cisco"]}]
}
'''
```

JSON 数据

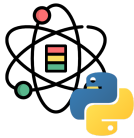

利用 `json.loads` 可以将 JSON 字符串转换为 Python 对象：

```
import json

res = json.loads(js)
res
# {
#   'name': 'Wes',
#   'place_lived': ['United States', 'Spain', 'Germany'],
#   'pet': None,
#   'siblings': [{'name': 'Scott', 'age': 30, 'pets': ['Zeus', 'Zuko']},
#                {'name': 'Katie', 'age': 38, 'pets': ['Sixes', 'Stache', 'Cisco']}]
# }
```

利用 `json.dumps` 可以将 Python 对象装换回 JSON 字符串。

JSON 数据

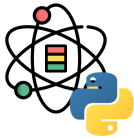

pandas.read_json 可以自动将 JSON 数据集按照指定次序转换为 Series 或 DataFrame，example.json 数据内容如下：

```
[
  {"a": 1, "b": 2, "c": 3},
  {"a": 4, "b": 5, "c": 6},
  {"a": 7, "b": 8, "c": 9},
]
```

```
df = pd.read_json('example.json')
df
#    a  b  c
# 0  1  2  3
# 1  4  5  6
# 2  7  8  9
```

同样，从 pandas 数据中导出 JSON 可以使用 Series 和 DataFrame 的 to_json 方法。

二进制数据

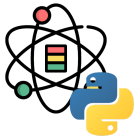

使用 Python 内建的 pickle 序列化模块进行二进制格式操作是存储数据（序列化）最高效，最方便的方法之一。pandas 对象拥有一个 to_pickle 方法可以将数据以 pickle 格式写入文件。使用 read_pickle 可以方便的读入 pickle 序列化后的文件。

HDF5 是一个备受好评的文件格式，用于存储大量的科学数组数据。每个 HDF5 文件可以存储多个数据集并支持元数据，与更简单的格式相比，HDF5 支持多种压缩模式的即时压缩，使得重复模式的数据可以更高效地存储。HDF5 适用于处理不适合在内存中存储的超大型数据，可以使你高效读写大型数组的一小块。

pandas 提供一个高阶的接口，可以简化 Series 和 DataFrame 的存储。HDFStore 类像字典一样工作并处理低级别细节：

```
df = pd.DataFrame({'a': np.random.randn(100)})
store = pd.HDFStore('tmp.h5')
store['obj1'] = df
store['ojb1_col'] = df['a']
```

```
store
```

```
## <class 'pandas.io.pytables.HDFStore'>
## File path: tmp.h5
```

to_hdf 和 read_hdf 函数提供了便捷的操作方法。

数据规整

分层索引

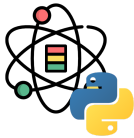

分层索引是 pandas 的重要特性，允许在一个轴向上拥有多个索引层级。分层索引提供了一种在更低维度的形式中处理更高维度数据的方式。

```
s = pd.Series(
  np.random.randn(9),
  index=[['a', 'a',
          'a', 'b',
          'b', 'c',
          'c', 'd',
          'd'],
         [1, 2, 3,
          1, 3, 1,
          2, 2, 3]])
```

```
s
```

```
## a  1   -0.281958
##    2   -0.633780
##    3    0.160485
## b  1    0.094933
##    3   -0.931031
## c  1   -1.278985
##    2   -0.981513
## d  2   -0.178224
##    3    1.130722
## dtype: float64
```

通过分层索引对象，允许简洁地选择出数据的子集：

```
s['b']
```

```
## 1    0.094933
## 3   -0.931031
## dtype: float64
```

```
s['b':'c']
```

```
## b  1    0.094933
##    3   -0.931031
## c  1   -1.278985
##    2   -0.981513
## dtype: float64
```

```
s.loc[['b', 'd']]
```

```
## b  1    0.094933
##    3   -0.931031
## d  2   -0.178224
##    3    1.130722
## dtype: float64
```

```
s.loc[:, 2]
```

```
## a   -0.633780
## c   -0.981513
## d   -0.178224
## dtype: float64
```

分层索引

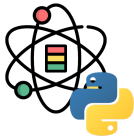

分层索引在重塑数据和数组透视表等分组操作中扮演重要角色，例如：使用 unstack 方法将数据在 DataFrame 中重新排列：

```
s.unstack()
```

```
##           1         2         3
## a -0.281958 -0.633780  0.160485
## b  0.094933       NaN -0.931031
## c -1.278985 -0.981513       NaN
## d       NaN -0.178224  1.130722
```

unstack 的反操作是 stack

```
s.unstack().stack()
```

在 DataFrame 中，每个轴都可以拥有分层索引：

```
df = pd.DataFrame(
  np.arange(12).reshape((4, 3)),
  index=[['a', 'a', 'b', 'b'],
         [1, 2, 1, 2]],
  columns=[['Ohio', 'Ohio', 'Colorado'],
           ['Green', 'Red', 'Green']])
df
```

```
##      Ohio     Colorado
##     Green Red    Green
## a 1     0   1        2
##   2     3   4        5
## b 1     6   7        8
##   2     9  10       11
```

分层索引

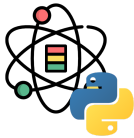

分层的层级可以有名称（可以是字符串或 Python 对象），如果层级有名称，这些名称会在控制台中显示：

```
df.index.names = ['key1', 'key2']
df.columns.names = ['state', 'color']
df
```

```
## state      Ohio     Colorado
## color     Green Red    Green
## key1 key2
## a    1        0   1        2
##      2        3   4        5
## b    1        6   7        8
##      2        9  10       11
```

通过部分列索引，可以选出列中的组：

```
df['Ohio']
```

```
## color      Green  Red
## key1 key2
## a    1         0    1
##      2         3    4
## b    1         6    7
##      2         9   10
```

重排序和层级排序

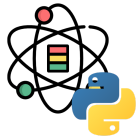

有时需要重新排列轴上的层级顺序，或者按照特定层级的值对数据进行排序。swaplevel 接受两个层级序号或层级名称，返回一个进行了层级变更的新对象：

```
df.swaplevel('key1', 'key2')
```

```
## state      Ohio     Colorado
## color     Green Red    Green
## key2 key1
## 1    a        0   1        2
## 2    a        3   4        5
## 1    b        6   7        8
## 2    b        9  10       11
```

sort_index 只能在单一层级上对数据进行排序，在进行层级变换时，使用 sort_index 以使得结果按照层级进行字典排序：

```
df.sort_index(level=1)
```

```
## state      Ohio     Colorado
## color     Green Red    Green
## key1 key2
## a    1        0   1        2
## b    1        6   7        8
## a    2        3   4        5
## b    2        9  10       11
```

```
df.swaplevel(0, 1).sort_index(level=0)
```

```
## state      Ohio     Colorado
## color     Green Red    Green
## key2 key1
## 1    a        0   1        2
##      b        6   7        8
## 2    a        3   4        5
##      b        9  10       11
```

按层级进行汇总统计

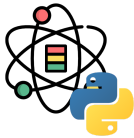

DataFrame 和 Series 中很多统计性和汇总性统计可以通过 groupby 函数和 level 参数可以指定想要在某个特定的轴上进行聚合，按照层级在行上进行聚合：

```
df.groupby(level='key2').sum()
```

```
## state  Ohio     Colorado
## color Green Red    Green
## key2
## 1         6   8        10
## 2        12  14        16
```

按照层级在列上进行聚合：

```
df.groupby(level='color', axis=1).sum()
```

```
## color      Green  Red
## key1 key2
## a    1         2    1
##      2         8    4
## b    1        14    7
##      2        20   10
```

使用列进行索引

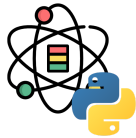

DataFrame 的 set_index 会生成一个新的 DataFrame，新的 DataFrame 使用一个或多个列作为索引：

```
df = pd.DataFrame(
  {'a': range(7), 'b': range(7, 0, -1),
   'c': ['one', 'one', 'one', 'two',
         'two', 'two', 'two'],
   'd': [0, 1, 2, 0, 1, 2, 3]})
df
```

```
##     a  b    c  d
## 0   0  7  one  0
## 1   1  6  one  1
## 2   2  5  one  2
## 3   3  4  two  0
## 4   4  3  two  1
## 5   5  2  two  2
## 6   6  1  two  3
```

```
df.set_index(['c', 'd'], drop=False)
```

```
##         a  b    c  d
## c   d
## one 0   0  7  one  0
##     1   1  6  one  1
##     2   2  5  one  2
## two 0   3  4  two  0
##     1   4  3  two  1
##     2   5  2  two  2
##     3   6  1  two  3
```

默认情况下这些列会从 DataFrame 中移除，通过 drop=False 可以将其保留在 DataFrame 中。

数据库风格的连接

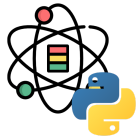

合并或连接操作通过一个或多个键来联合数据集，这些操作是关系型数据库的核心内容。pandas 中的 merge 函数主要用于将各种 join 操作应用到数据上：

```
df1 = pd.DataFrame(
  {'key': ['b', 'b', 'a', 'c', 'a', 'a', 'b'],
   'data1': range(7)})
```

```
df1
```

```
##   key  data1
## 0   b      0
## 1   b      1
## 2   a      2
## 3   c      3
## 4   a      4
## 5   a      5
## 6   b      6
```

```
df2 = pd.DataFrame(
  {'key': ['a', 'b', 'd
'],
   'data2': range(3)})
df2
```

```
##   key  data2
## 0   a      0
## 1   b      1
## 2   d      2
```

df1 的数据多个行的标签为 a 和 b，而 df2 在 key 列中每个值仅有一行。调用 merge 处理获取连接的对象：

```
pd.merge(df1, df2)
```

```
##   key  data1  data2
## 0   b      0      1
## 1   b      1      1
## 2   a      2      0
## 3   a      4      0
## 4   a      5      0
## 5   b      6      1
```

上例中并没有指定在哪一列上进行连接，如果没有指定 merge 会自动将重叠的列名作为连接的键。

数据库风格的连接

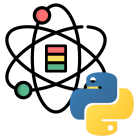

可以显式的的指定连接键：

```
pd.merge(df1, df2, on='key')
```

```
##   key  data1  data2
## 0   b      0      1
## 1   b      1      1
## 2   a      2      0
## 3   a      4      0
## 4   a      5      0
## 5   b      6      1
```

如果对象的列名是不同的，可以分别为他们指定列名：

```
df3 = pd.DataFrame({
  'lkey': ['b', 'b', 'a', 'c', 'a', 'a', 'b'],
  'data1': range(7)})
```

```
df4 = pd.DataFrame({
  'rkey': ['a', 'b', 'd'],
  'data2': range(3)})
pd.merge(df3, df4, left_on='lkey', right_on='rkey')
```

```
##   lkey  data1 rkey  data2
## 0    b      0    b      1
## 1    b      1    b      1
## 2    a      2    a      0
## 3    a      4    a      0
## 4    a      5    a      0
## 5    b      6    b      1
```

默认情况下 merge 做的是内连接 inner，其他可选项有左连接 left、右连接 right 和外连接 outer。

数据库风格的连接

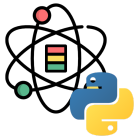

使用多个键进行合并时，需传入一个列名的列表：

```
left = pd.DataFrame({
  'key1': ['foo', 'foo', 'bar'],
  'key2': ['one', 'two', 'one'], 'lval': [1, 2, 3]})
right = pd.DataFrame({
  'key1': ['foo', 'foo', 'bar', 'bar'],
  'key2': ['one', 'one', 'one', 'two'],
  'rval': [4, 5, 6, 7]})
pd.merge(left, right,
         on=['key1', 'key2'], how='outer')
```

```
##   key1 key2  lval  rval
## 0  bar  one   3.0   6.0
## 1  bar  two   NaN   7.0
## 2  foo  one   1.0   4.0
## 3  foo  one   1.0   5.0
## 4  foo  two   2.0   NaN
```

```
pd.merge(left, right, on='key1')
```

```
##   key1 key2_x  lval key2_y  rval
## 0  foo    one     1    one     4
## 1  foo    one     1    one     5
## 2  foo    two     2    one     4
## 3  foo    two     2    one     5
## 4  bar    one     3    one     6
## 5  bar    one     3    two     7
```

```
pd.merge(left, right, on='key1', suffixes=('_l', '_r
'))
```

```
##   key1 key2_l  lval key2_r  rval
## 0  foo    one     1    one     4
## 1  foo    one     1    one     5
## 2  foo    two     2    one     4
## 3  foo    two     2    one     5
## 4  bar    one     3    one     6
## 5  bar    one     3    two     7
```

数据库风格的连接

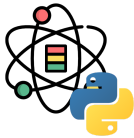

`merge` 函数的参数如下表所示：

参数	描述
`left`	合并时操作中左边的 DataFrame
`right`	合并时操作中右边的 DataFrame
`how`	`inner`，`outer`，`left`，`right` 之一，默认为 `inner`
`on`	需要连接的列名，需要在两边的 DataFrame 中都存在。
`left_on`	左 DataFrame 中用作连接的键
`right_on`	右 DataFrame 中用作连接的键

(接下表)

数据库风格的连接

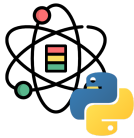

(接上表)

参数	描述
left_index	使用 left 的行索引作为它的连接键（如果是 MultiIndex，则为多个键）
right_index	使用 right 的行索引作为它的连接键（如果是 MultiIndex，则为多个键）
sort	通过连接键按字母顺序对合并的数据进行排序，默认为 True
suffixes	在重叠情况下，添加到列名后的字符串元组，默认为 ('_x', '_y')
copy	如果为 False，则在某些特殊情况下避免将数据复制到结果数据结构中，默认情况下总是复制
indicator	添加一个特殊的列 _merge，指示每一行的来源。值将根据每行中连接数据的来源分别为 left_only，right_only，both

数据库风格的连接

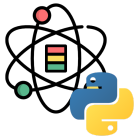

DataFrame 有一个方便的 join 实例方法，用于按照索引合并。该方法也可以用于合并多个索引相同或相似但没有重叠列的 DataFrame 对象：

```
left = pd.DataFrame(
  [[1., 2.], [3., 4.], [5., 6.]],
  index=['a', 'c', 'e'], columns=['Ohio', 'Nevada'])
right = pd.DataFrame(
  [[7., 8.], [9., 10.], [11., 12.], [13., 14.]],
  index=['b', 'c', 'd', 'e'],
  columns=['Missouri', 'Alabama'])
left.join(right, how='outer')
```

```
##    Ohio  Nevada  Missouri  Alabama
## a   1.0     2.0       NaN      NaN
## b   NaN     NaN       7.0      8.0
## c   3.0     4.0       9.0     10.0
## d   NaN     NaN      11.0     12.0
## e   5.0     6.0      13.0     14.0
```

可以向 join 方法传递一个 DataFrame 列表：

```
another = pd.DataFrame(
  [[7.], [8.], [9.], [10.]],
  index=['a', 'c', 'e', 'f'], columns=['New York'])
left.join([right, another], how='outer')
```

```
##    Ohio  Nevada  Missouri  Alabama  New York
## a   1.0     2.0       NaN      NaN       7.0
## c   3.0     4.0       9.0     10.0       8.0
## e   5.0     6.0      13.0     14.0       9.0
## b   NaN     NaN       7.0      8.0       NaN
## d   NaN     NaN      11.0     12.0       NaN
## f   NaN     NaN       NaN      NaN      10.0
```

沿轴向连接

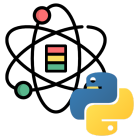

另一种数据组合操作可互换地称为拼接、绑定或堆叠。NumPy 的 concatenate 函数可以在 NumPy 数组上实现该该功能：

```
arr = np.arange(12).reshape((3, 4))
arr
```

```
## array([[ 0,  1,  2,  3],
##        [ 4,  5,  6,  7],
##        [ 8,  9, 10, 11]])
```

```
np.concatenate([arr, arr], axis=1)
```

```
## array([[ 0,  1,  2,  3,  0,  1,  2,  3],
##        [ 4,  5,  6,  7,  4,  5,  6,  7],
##        [ 8,  9, 10, 11,  8,  9, 10, 11]])
```

在 Series 和 DataFrame 等 pandas 对象上下文中，使用标记的轴可以进一步泛化数据连接。尤其是你还有需要考虑的事情：

- 如果对象在其他轴上的索引不同，我们是否应该将不同的元素组合在这些轴上，还是只使用共享的值（交集）？
- 连接的数据块是否需要在结果对象中被识别?
- “连接轴”是否包含需要保存的数据?

pandas 的 concat 函数提供了一种一致性的方式来解决以上问题。

沿轴向连接

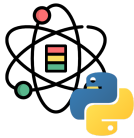

```
s1 = pd.Series([0, 1], index=['a', 'b'])
s2 = pd.Series([2, 3, 4], index=['c', 'd', 'e'])
s3 = pd.Series([5, 6], index=['f', 'g'])
```

调用 concat 方法会将值和索引连在一起：

```
pd.concat([s1, s2, s3])
```

```
## a    0
## b    1
## c    2
## d    3
## e    4
## f    5
## g    6
## dtype: int64
```

默认情况下，concat 方法是沿着 axis=0 的轴向生效的，生成另一个 Series。如果设置 axis=1，返回的结果则是一个 DataFrame：

```
pd.concat([s1, s2, s3], axis=1)
```

```
##      0    1    2
## a  0.0  NaN  NaN
## b  1.0  NaN  NaN
## c  NaN  2.0  NaN
## d  NaN  3.0  NaN
## e  NaN  4.0  NaN
## f  NaN  NaN  5.0
## g  NaN  NaN  6.0
```

沿轴向连接

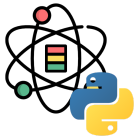

拼接在一起的各部分无法在结果中区分是一个潜在的问题。假设你想在连接轴向上创建一个多层索引，可以使用 keys 参数来实现：

```
res = pd.concat(
  [s1, s1, s3], keys=['one', 'two', 'three'])
res
```

```
## one    a    0
##        b    1
## two    a    0
##        b    1
## three  f    5
##        g    6
## dtype: int64
```

```
res.unstack()
```

```
##          a    b    f    g
## one    0.0  1.0  NaN  NaN
## two    0.0  1.0  NaN  NaN
## three  NaN  NaN  5.0  6.0
```

axis=1 连接 Series 时，keys 为 DataFrame 的列头：

```
pd.concat([s1, s2], axis=1, keys=['one', 'two'])
```

```
##    one  two
## a  0.0  NaN
## b  1.0  NaN
## c  NaN  2.0
## d  NaN  3.0
## e  NaN  4.0
```

沿轴向连接

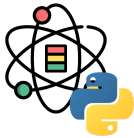

对于 DataFrame 对象：

```
df1 = pd.DataFrame(
  np.arange(6).reshape((3, 2)),
  index=['a', 'b', 'c'], columns=['one', 'two'])
df2 = pd.DataFrame(
  np.arange(4).reshape((2, 2)),
  index=['a', 'c'], columns=['three', 'four'])
```

```
df1
```

```
##    one  two
## a    0    1
## b    2    3
## c    4    5
```

```
df2
```

```
##    three  four
## a      0     1
## c      2     3
```

```
pd.concat([df1, df2], axis=1, keys=['l1', 'l2'])
```

```
##    l1        l2
##   one two three four
## a   0   1   0.0  1.0
## b   2   3   NaN  NaN
## c   4   5   2.0  3.0
```

如果传递的是对象的字典而不是列表的话，则字典的键会用于 keys 选项：

```
pd.concat({'l1': df1, 'l2': df2}, axis=1)
```

```
##    l1        l2
##   one two three four
## a   0   1   0.0  1.0
## b   2   3   NaN  NaN
## c   4   5   2.0  3.0
```

沿轴向连接

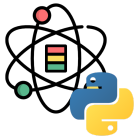

参数	描述
objs	需要连接的 pandas 对象列表或字典
axis	连接的轴向，默认是 0（沿着行方向）
join	用于指定连接方式（inner 或 outer）
keys	与要连接的对象关联的值，沿着连接轴形成分层索引。
levels	在键值传递时，该参数用于指定多层索引的层级
names	传入 keys 或 levels 时用于多层索引的层级名称
verify_integrity	检查连接对象中的新轴是否重复，如果是，则发生异常，默认为 False
ignore_index	不沿着连接轴保留索引，而产生一段新的索引

联合重叠数据

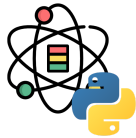

另一种数据联合场景，既不是合并，也不是连接。两个数据集的索引全部或部分重叠，考虑 NumPy 的 where 函数，这个函数可以进行面向数组的 if-else 等价操作：

```
a = pd.Series([np.nan, 2.5, 0.0, np.nan],
              index=['d', 'c', 'b', 'a'])
b = pd.Series([0, np.nan, 2, 3],
              index=['a', 'b', 'c', 'd'])
```

```
a
```

```
## d    NaN
## c    2.5
## b    0.0
## a    NaN
## dtype: float64
```

```
b
```

```
## a    0.0
## b    NaN
## c    2.0
## d    3.0
## dtype: float64
```

```
np.where(pd.isnull(a), b, a)
```

```
## array([0. , 2.5, 0. , 3. ])
```

Series 的 combine_first 方法等基于上述操作：

```
b.combine_first(a)
```

```
## a    0.0
## b    0.0
## c    2.0
## d    3.0
## dtype: float64
```

联合重叠数据

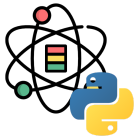

在 DataFrame 中，`combine_first` 逐列进行相同的操作，可以理解为利用传入的数值替换对象的缺失值：

```
df1 = pd.DataFrame(
  {'a': [1., np.nan, 5., np.nan],
   'b': [np.nan, 2., np.nan, 6.],
   'c': range(2, 18, 4)})
df2 = pd.DataFrame(
  {'a': [5., 4., np.nan, 3., 7.],
   'b': [np.nan, 3., 4., 6., 8.]})
```

```
df1
```

```
##      a    b   c
## 0  1.0  NaN   2
## 1  NaN  2.0   6
## 2  5.0  NaN  10
## 3  NaN  6.0  14
```

```
df2
```

```
##      a    b
## 0  5.0  NaN
## 1  4.0  3.0
## 2  NaN  4.0
## 3  3.0  6.0
## 4  7.0  8.0
```

```
df1.combine_first(df2)
```

```
##      a    b     c
## 0  1.0  NaN   2.0
## 1  4.0  2.0   6.0
## 2  5.0  4.0  10.0
## 3  3.0  6.0  14.0
## 4  7.0  8.0   NaN
```

重塑和透视

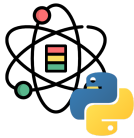

多层索引在 DataFrame 中提供了一种一致性方式用于重排列数据，包含两个基础操作：

- stack（堆叠），“旋转”或将列中的数据透视到行
- unstack（拆堆），将行中的数据透视到列

```
df = pd.DataFrame(
  np.arange(6).reshape((2, 3)),
  index=pd.Index(['Ohio', 'Colorado'], name='state')
,
  columns=pd.Index(['one', 'two', 'three'], name='nu
m'))
df
```

```
## num       one  two  three
## state
## Ohio        0    1      2
## Colorado    3    4      5
```

利用 stack 方法将数据透视到行，产生新的 Series：

```
res = df.stack()
res
```

```
## state     num
## Ohio      one      0
##           two      1
##           three    2
## Colorado  one      3
##           two      4
##           three    5
## dtype: int64
```

重塑和透视

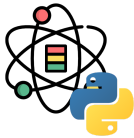

如果层级中的所有值并未包含于每个子分组中，拆分可能会引入缺失值：

```
s1 = pd.Series([0, 1, 2, 3],
               index=['a', 'b', 'c', 'd'])
s2 = pd.Series([4, 5, 6],
               index=['c', 'd', 'e'])
df = pd.concat([s1, s2], keys=['one', 'two'])
df
```

```
## one  a    0
##      b    1
##      c    2
##      d    3
## two  c    4
##      d    5
##      e    6
## dtype: int64
```

默认情况下，堆叠会过滤出缺失值：

```
df.unstack()
```

```
##         a    b    c    d    e
## one  0.0  1.0  2.0  3.0  NaN
## two  NaN  NaN  4.0  5.0  6.0
```

```
df.unstack().stack()
```

```
## one  a    0.0
##      b    1.0
##      c    2.0
##      d    3.0
## two  c    4.0
##      d    5.0
##      e    6.0
## dtype: float64
```

重塑和透视

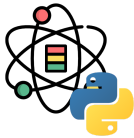

在 DataFrame 中拆堆时，被拆堆的层级会变为结果中最低的层级：

```
df = pd.DataFrame(
  {'left': res, 'right': res + 5},
  columns=pd.Index(['left', 'right'], name='side'))
df
```

```
## side            left  right
## state    num
## Ohio     one       0      5
##          two       1      6
##          three     2      7
## Colorado one       3      8
##          two       4      9
##          three     5     10
```

调用 stack 方法时，可以指明需要堆叠的轴向名称：

```
df.unstack('state')
```

```
## side  left          right
## state Ohio Colorado  Ohio Colorado
## num
## one      0        3     5        8
## two      1        4     6        9
## three    2        5     7       10
```

```
df.unstack('state').stack('side')
```

```
## state        Ohio  Colorado
## num   side
## one   left      0         3
##       right     5         8
## two   left      1         4
##       right     6         9
## three left      2         5
##       right     7        10
```

重塑和透视

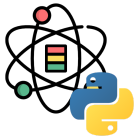

从一个多层索引序列中，可以使用 unstack 方法将数据重排列后放入一个 DataFrame 中：

```
res.unstack()
```

```
## num       one  two  three
## state
## Ohio        0    1      2
## Colorado    3    4      5
```

默认情况下，最内层是已拆堆的（与 stack 方法一样），传入层级序号或名称来拆分一个不同的层级：

```
res.unstack(0)
```

```
## state  Ohio  Colorado
## num
## one       0         3
## two       1         4
## three     2         5
```

```
res.unstack('state')
```

```
## state  Ohio  Colorado
## num
## one       0         3
## two       1         4
## three     2         5
```

重塑和透视

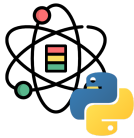

DataFrame 中的 pivot 和 melt 方法提供了将数据“由长到宽”和“由宽到长”变换的支持。

```
df = pd.DataFrame({
  'key': ['foo', 'bar', 'baz'] * 3,
  'var': ['A', 'A', 'A', 'B', 'B', 'B', 'C', 'C', 'C
'],
  'val': range(9),
})
```

```
##    key var  val
## 0  foo   A    0
## 1  bar   A    1
## 2  baz   A    2
## 3  foo   B    3
## 4  bar   B    4
## 5  baz   B    5
## 6  foo   C    6
## 7  bar   C    7
## 8  baz   C    8
```

```
pivoted = df.pivot(index='key', columns='var', value
s='val').reset_index()
pivoted
```

```
## var  key  A  B  C
## 0    bar  1  4  7
## 1    baz  2  5  8
## 2    foo  0  3  6
```

```
pd.melt(pivoted, ['key'])
```

```
##    key var  value
## 0  bar   A      1
## 1  baz   A      2
## 2  foo   A      0
## 3  bar   B      4
## 4  baz   B      5
## 5  foo   B      3
## 6  bar   C      7
## 7  baz   C      8
## 8  foo   C      6
```

感谢倾听