

第 3 章



Python常用机器学习库

本章概要

Python 的标准库包括 `math`、`random`、`datetime`、`os` 等。此外,Python 还拥有强大的第三方库资源,为开发者提供了大量的开发资源。这些库使 Python 保持活力和高效。丰富的开源生态系统也是 Python 成功和流行的原因之一。

借助常用的机器学习库,Python 可以解决多种问题,例如科学计算、数据分析、图像处理等。Python 及其生态系统使它成为全世界用户优先选择的开发工具。

本章会介绍常见的用于数据科学任务和机器学习处理的 Python 库,包括通用的 NumPy、Pandas、Scikit learn 和 Matplotlib 等,也包含 OpenCV、jieba、wordcloud 等专门库。这些库提供了机器学习任务中经常使用的基本功能。

学习目标

当完成本章的学习后,要求:

- (1) 了解常用第三方库的调用方法。
- (2) 熟悉机器学习库的使用步骤。
- (3) 掌握 NumPy、Pandas 的数据处理功能。
- (4) 掌握 Matplotlib 的绘图方法。
- (5) 熟悉 Scikit learn 机器学习库的使用。
- (6) 熟悉其他常用库的使用。

3.1 NumPy

NumPy 是 Numerical Python 的简称,是高性能计算和数据分析的基础包,是 Python 的一个重要扩充库。NumPy 支持高维度数组与矩阵运算,也针对数组运算提供了大量

的数学函数库。NumPy 运算效率极好,是大量机器学习框架的基础库。

NumPy 中主要包含一个强大的 N 维数组对象 ndarray、整合了 C/C++ 和 FORTRAN 代码的工具包,以及丰富的数学函数库,尤其是实用的线性代数、傅里叶变换和随机数生成函数。

使用 NumPy,开发人员可以很方便地执行数组运算、逻辑运算、傅里叶变换和图形图像操作。NumPy 数组的运算效率优于 Python 的标准 List 类型。而且在代码中使用 NumPy 可以省去很多烦琐的处理语句,代码更为简洁。

研究人员经常将 NumPy 和稀疏矩阵运算包 SciPy(Scientific Python)配合使用,来解决矩阵运算问题。将 NumPy 与 SciPy、Matplotlib 绘图库相组合是一个流行的计算框架,这个组合可以作为 MATLAB 的替代方案。



视频讲解

3.1.1 ndarray 对象

NumPy 的强大功能主要基于底层的一个 ndarray 结构,其可以生成 N 维数组对象。

ndarray 对象是一系列同类型数据的集合,下标索引从 0 开始,是一个用于存放同类型元素的多维数组。ndarray 中的每个元素在内存中都具有相同大小的存储区域。

与 Python 中的其他容器对象一样,ndarray 可以通过对数组建立索引或切片来访问数组内容,也可以使用 ndarray 的方法和属性来访问和修改 ndarray 的内容。

1. ndarray 的内部结构

相对标准的数组,ndarray 本质上是一个数据结构。如图 3.1 所示,ndarray 内部主要由以下内容构成。




图 3.1 ndarray 的数据结构

(1) 数组形状 shape: 是一个表示数组各维大小的整数元组。

(2) 数据类型 dtype: 是一个描述数组的类型对象。对象类型为 NumPy 内置的 24 种数组标量类型中的一种。

(3) 数组数据 data: 是一个指向内存中数据的指针。

(4) 跨度 strides: 一个元组,是当前维度的宽,表示当前维度移动到下一个位置需要跨越的字节数。跨度可以是负数,这样会使数组在内存中后向移动。

(5) 数组顺序 order: 访问数组元素的主顺序,如“C”为行主序,“F”为列主序等。

2. 创建 ndarray

在 NumPy 模块中,提供了 `ndarray()` 和 `array()` 两个函数,都可以用来建立一个 `ndarray`。其中 `ndarray()` 函数属于底层的方法,一般情况下,建立数组使用的是更为便捷的 `array()` 函数,其一般格式如下。

```
numpy.array(object, dtype = None, copy = True, order = None, subok = False,
            ndmin = 0)
```

主要参数:

`object`: 数组或嵌套的数列。

`dtype`: 数组元素的数据类型,可选。

`order`: 创建数组的样式,C 为行方向,F 为列方向,A 为任意方向(默认)。

`ndmin`: 指定所生成数组应具有的最小维度。

【例 3.1】 建立一个一维 `ndarray` 数组。

```
import numpy as np
a = np.array([1,2,3])
print(a)
```

【例 3.2】 创建二维数组。

```
import numpy as np
a = np.array([[1,2], [3,4]])
print(a)
```

【例 3.3】 使用 `ndmin` 参数设置数组的最小维度。

```
import numpy as np
a = np.array([1,2,3,4,5], ndmin=2)
print(a)
```

【例 3.4】 使用 `dtype` 参数设置数组类型为复数。

```
import numpy as np
a = np.array([1,2,3], dtype = np.complex)
print(a)
```

在内存中,`ndarray` 对象的存放形式是连续的一维数列。在访问时,通过索引获取内存块中的对应元素位置。内存块以行顺序(C 样式)或列顺序(F 样式,即 FORTRAN 或 MATLAB 风格)来保存元素。

NumPy 还提供了 `asarray()` 函数,可以将其他类型的结构数据转换为 `ndarray`。

3.1.2 NumPy 数据类型

NumPy 内置了 24 种数组标量(Array Scler)类型,也支持 Python 的基本数据类型,某种程度上可以和 C 语言的数据类型相对应,如表 3.1 所示。

表 3.1 NumPy 的基本数据类型

名 称	描 述
bool_	布尔型, True 或 False
int8	有符号字节类型, 范围为 $-128 \sim 127$
int16	有符号 16 位整数, 范围为 $-32\,768 \sim 32\,767$
int32	有符号 32 位整数, 范围为 $-2^{31} \sim 2^{31} - 1$
int64	有符号 64 位整数, 范围为 $-2^{63} \sim 2^{63} - 1$
uint8	无符号字节类型, 范围为 $0 \sim 255$
uint16	无符号 16 位整数, 范围为 $0 \sim 65\,535$
uint32	无符号 32 位整数, 范围为 $0 \sim 2^{32} - 1$
uint64	无符号 64 位整数, 范围为 $0 \sim 2^{64} - 1$
float_	64 位浮点数, 同 float64
float16	16 位浮点数
float32	32 位浮点数
float64	64 位(双精度)浮点数, 同 float_
complex_	128 位复数*, 同 complex128
complex64	64 位复数
complex128	128 位复数, 同 complex_

* 复数: 形如 $z=a+bi$ (a, b 均为实数) 的数称为复数, 其中, a 称为实部, b 称为虚部, i 称为虚数单位 (i 表示 -1 的平方根)。

当虚部 $b=0$ 时, 复数 z 是实数;

当虚部 $b \neq 0$ 且实部 $a=0$ 时, 复数 z 是纯虚数。

对于每种数据类型, NumPy 还提供了同名的类型函数, 例如 `float16()`、`int32()` 等, 可以用来创建该类型的数据对象, 也可以用来转换数据对象的数据类型。

【例 3.5】 NumPy 数据类型的使用。

```
import numpy as np
x=np.float32(5)
print('x 为:', x)
print('x 对象的 data 属性:', x.data)
print('x 对象的 size 属性:', x.size)
print('x 对象的维数:', x.ndim)
y=np.bool_(x)
print('转换为 bool 类型的 x 为:', y)
z=np.float16(y)
print('True 值转换为 float16 类型为:', z)
```

运行结果为：

```
x 为: 5.0
x 对象的 data 属性: <memory at 0x000002D11F41FDC8>
x 对象的 size 属性: 1
x 对象的维数: 0
转换为 bool 类型的 x 为: True
True 值转换为 float16 类型为: 1.0
```

上面的函数能够设置、修改对象数据类型。不过通常情况下,建议使用 NumPy 中的 dtype 对象指定数据类型。

1. 数据类型对象 (dtype)

NumPy 中的 dtype(data type object)是由 numpy.dtype 类产生的数据类型对象,其作用是描述数组元素对应的内存区域的各部分的使用。其内部结构包括数据类型、数据的字节数、各组成部分的顺序、各字段的名称等。

构造 dtype 对象的语法如下。

```
numpy.dtype(object, align, copy)
```

主要参数如下。

object: 要转换为 dtype 对象的数据对象。

align: 如果为 True,则填充字段使其类似 C 的结构体。

copy: 指明是否复制 dtype 对象。如果为 False,则是对内置数据类型对象的引用。

如果使用 dtype 对象设置数据类型,那么可以对例 3.5 做如下修改。

【例 3.6】 使用 dtype 对象设置数据类型。

```
import numpy as np
x=np.array(5,dtype="float32")
print('x 为:',x)
print('x 对象的 data 属性: ',x.data)
print('x 对象的 size 属性:',x.size)
print('x 对象的维数:',x.ndim)
y=np.array(x,dtype="bool_")
print('转换为 bool 类型的 x 为:',y)
z=np.array(y,dtype="float16")
print('True 值转换为 float16 类型为:',z)
```

运行结果如下。

```
x 为: 5.0
x 对象的 data 属性: <memory at 0x000002D11F552588>
x 对象的 size 属性: 1
x 对象的维数: 0
转换为 bool 类型的 x 为: True
```

True 值转换为 float16 类型为: 1.0

有些数据类型有简写,例如 int8, int16, int32, int64 四种数据类型可以使用字符串 'i1', 'i2', 'i4', 'i8' 简写代替。

例如,使用“i4”字符串代替 int32 类型。

```
import numpy as np
dt = np.dtype('i4')
print(dt)
```

2. 使用 astype() 修改数据类型

在数组建立之后,也可以使用 NumPy 中数组附带的 astype() 方法修改其数据类型,格式如下。

```
array.astype(dtype, order='K', casting='unsafe', subok=True, copy=True)
```

例如,将 y 设置成 float32 类型,可以用:

```
y=y.astype("float32")
```

或者

```
y=y.astype(np.float32)
```

另外,使用 NumPy 数组的 astype() 方法还可以把 Python 的数据类型映射给 dtype 类型,如语句 `x=x.astype(float)` 与 `x=x.astype(np.float)` 运行结果相同。

表 3.2 是常用 Python 对象与 NumPy 的 dtype 对象的对应表,其他数据类型没有与 Python 等效的数据类型。

表 3.2 Python 对象与 dtype 对象对应关系表

Python 对象	dtype 对象
int	numpy.int_
bool	numpy.bool_
float	numpy.float_
complex	numpy.complex_

【扩展】由于 Pandas 是基于 NumPy 数组的,所以也能用 astype() 对 DataFrame 的字段进行类型转换。

【例 3.7】 使用 astype() 转换 DataFrame。

```
import pandas as pd
df = pd.DataFrame([{'qty': '3', 'num': '50'}, {'qty': '7', 'num': '20'}])
print(df.dtypes)
print('-----')
df['qty'] = df['qty'].astype('int')
```

```
df['num'] = df['num'].astype('float64')
print(df.dtypes)
```

可以看到,两个列的数据类型由初始的 object 变成了 float64 和 int32。

```
DataFrame 的 dtypes:
Num      object
Qty      object
dtype: object
-----
astype() 转换后的 dtypes:
Num      float64
Qty      int32
dtype: object
```

3.1.3 NumPy 数组属性

1. 常用术语

(1) 轴(Axis): 每个线性数组称为一个轴,轴即数组的维度(Dimensions)。例如,将二维数组看作一维数组,此一维数组中每个元素又是一个一维数组,则每个一维数组是 NumPy 中的一个轴。第一个轴相当于底层数组,第二个轴是底层数组中的数组。

(2) 秩(Rank): 秩描述 NumPy 数组的维数,即轴的数量。一维数组的秩为 1,二维数组的秩为 2,以此类推。

例如,[0,1,2]是一维数组,只有一个轴,其秩为 1,轴长度为 3;[[0,1,2],[3,4,5]]是一个二维数组,数组的秩为 2,具有两个轴,其中第一个轴(维度)的长度为 2,第二个轴(维度)的长度为 3。

在使用的时候可以声明 axis。如果 axis=0,表示按第 0 轴方向操作,即对每列进行操作;如果 axis=1,表示按第 1 轴方向操作,即对每行进行操作。

【例 3.8】 使用 axis 参数设置当前轴。

```
import numpy as np
arr=np.array([[0,1,2],[3,4,5]])
print(arr)
print(arr.sum(axis=0))
print(arr.sum(axis=1))
```

运行结果如下。

```
[[0 1 2]
 [3 4 5]]
[3 5 7]
[ 3 12]
```

在这个程序中,首先使用 arr.sum(axis=0)进行垂直(列)方向的求和计算,然后使用 arr.sum(axis=1)沿行方向计算。

2. 基本属性

NumPy 的 ndarray 数组具有属性,可以获得数组的信息,常见属性见表 3.3。

表 3.3 常见的 ndarray 数组属性

属 性	说 明
ndarray.ndim	秩,轴的数量
ndarray.shape	数组的维度
ndarray.size	数组元素的总个数
ndarray.dtype	数组元素类型
ndarray.itemsize	每个元素的大小(B)
ndarray.data	实际数组元素

1) ndarray.ndim

在 NumPy 中 ndarray.ndim 返回这个数组的维数,等于秩。reshape()函数可以将数组变形重构,调整数组各维度的大小。

reshape()的格式为:

```
numpy.reshape(a, newshape, order='C')
```

【例 3.9】 使用 reshape()函数调整数组形状。

```
import numpy as np
arr=np.array([0, 1, 2, 3, 4, 5, 6, 7])
#显示数组 arr 的 rank
print('秩为:',arr.ndim)
arr3D = arr.reshape(2,2,2)
print(arr3D)
print ('秩为:',arr3D.ndim)
```

显示结果如下。

```
秩为: 1
[[[0 1]
  [2 3]]

  [[4 5]
  [6 7]]]
秩为: 3
```

思考: reshape()函数是否修改原 arr 数组? 请使用 print()函数查看。

2) ndarray.shape

ndarray.shape 代表数组的维度,返回值为一个元组。这个元组的长度就是 ndim 属性(秩)。另外,ndarray.shape 也可以用于调整数组大小。

【例 3.10】 显示数组的维度。

```
import numpy as np
a = np.array([[1, 2, 3], [4, 5, 6]])
print (a.shape)
```

【例 3.11】 调整数组大小。

```
import numpy as np
a = np.array([[1, 2, 3], [4, 5, 6]])
a.shape = (3, 2)
print (a)
```

3) 数据类型 dtype

数据类型对象 dtype 是一个特殊的对象,包含 ndarray 将一块内存解析成特定数据类型所必需的信息。

【例 3.12】 创建 dtype 数据类型对象。

```
myArr=np.array([1, 2, 3], dtype=np.float64)
myArr.dtype
```

查看运行结果:

```
dtype('float64')
```

3.1.4 其他创建数组的方式

ndarray 数组可以使用 array() 函数来构造。此外,还有其他几种方式可以用来创建特殊的数组。

1. numpy.empty()

NumPy 的 empty() 函数能创建一个指定形状、数据类型的空数组。这个数组没有经过初始化,其内容为空。表 3.4 为创建空数组的参数。

格式:

```
numpy.empty(shape, dtype = float, order = 'C')
```

表 3.4 创建空数组的参数

参数	描 述
shape	数组形状
dtype	数据类型,可选
order	有"C"和"F"两个选项,分别代表行优先和列优先,表示在计算机内存中存储元素的顺序

【例 3.13】 创建一个空数组。

```
import numpy as np
```

```
x = np.empty([3,2], dtype = int)
print(x)
```

运行后得到的数组元素值是不确定的,因为所用空间未初始化。

2. numpy.zeros()

有时需要创建全 0 填充的数组,此时可以使用 NumPy 的 zeros()函数,其参数见表 3.5。
格式:

```
numpy.zeros(shape, dtype = float, order = 'C')
```

表 3.5 创建 zeros 数组的参数

参数	描 述
shape	数组形状
dtype	数据类型,可选
order	'C' 用于 C 风格——行为主的数组,或者 'F' 用于 FORTRAN 风格——列为主的数组

【例 3.14】 创建一个全 0 数组。

```
import numpy as np
#默认为浮点数
x = np.zeros(5)
print(x)
#设置类型为整数
y = np.zeros((5,), dtype = np.int)
print(y)
#自定义类型
z = np.zeros((2,2), dtype = [('x', 'i4'), ('y', 'i4')])
print(z)
```

3. numpy.ones()

有时需要一个以 1 填充的数组,这时可以使用 NumPy 专门提供的 ones()函数来创建。

格式:

```
numpy.ones(shape, dtype=None, order='C')
```

【例 3.15】 建立一个全 1 数组。

```
import numpy as np
#默认为浮点数
x = np.ones(5)
print(x)
#自定义类型
```

```
x = np.ones([2,2], dtype = int)
print(x)
```

4. 产生数列的函数

在进行科学运算时,经常用到基本的简单数列,如 1~50 等。Python 中提供了 range() 函数。NumPy 中也有类似的函数,如 arange()、linspace() 函数等。

1) range() 函数

Python 内置的 range() 函数通过指定开始值、终值和步长可以创建一个一维数组。注意,生成的数组不包括终值。

格式:

```
range(start, stop [, step])
```

所生成的数组从 start 开始,到 stop-1 结束,间隔(步长)为 step。默认情况下从 0 开始。step 默认为 1,需要是整数。

例如:

```
arr1=range(0,5,1)
```

2) arange() 函数

NumPy 的 arange() 函数功能与 range() 函数类似,在 start 开始到 stop 的范围内,生成一个 ndarray 数组。

格式:

```
arange([start,] stop [, step,], dtype=None)
```

【例 3.16】 生成 3~9 的步长为 0.2 的数组。

```
import numpy as np
arr2=np.arange(3,9,0.2)
arr2
```

运行结果如下。

```
array([3. , 3.2, 3.4, 3.6, 3.8, 4. , 4.2, 4.4, 4.6, 4.8, 5. , 5.2, 5.4,
       5.6, 5.8, 6. , 6.2, 6.4, 6.6, 6.8, 7. , 7.2, 7.4, 7.6, 7.8, 8. ,
       8.2, 8.4, 8.6, 8.8])
```

3) linspace() 函数

格式:

```
numpy.linspace(start, stop, num=50, endpoint=True, retstep=False, dtype=None)
```

其中,start 为序列的起始值,stop 为结束值,num 是生成的样本数。

【例 3.17】 生成 1~5 中的 10 个数。

```
import numpy as np
```

```
arr3=np.linspace(1, 5, 10)
arr3
```

运行结果如下。

```
array([1.          , 1.44444444, 1.88888889, 2.33333333, 2.77777778,
       3.22222222, 3.66666667, 4.11111111, 4.55555556, 5.          ])
```

5. 使用随机函数创建数组

除了简单的顺序数列,NumPy 还在 random 子模块中提供了随机函数,常见的随机函数见表 3.6。

表 3.6 常用的 NumPy 随机函数

函 数	描 述
rand(d0,d1,...,dn)	随机产生指定维度的浮点数组
randint(low[,high,size,dtype])	随机产生[low,high]的整数
random([size])	随机产生[0.0, 1.0)的浮点数
uniform(start,end,size)	从[start,end)均匀分布的数据中随机抽取一组浮点数
normal(loc, scale, size)	基于给定的均值和方差,随机产生一组正态分布的浮点数

* 正态分布(Normal Distribution): 又称高斯分布,是许多统计方法的理论基础。分布图形左右对称。正态分布的参数包括均值和标准差。同样的均值情况下,标准差越大,曲线越平阔;标准差越小,曲线越狭窄。使用 np.random.normal()函数可以生成服从正态分布的数据。

【例 3.18】 创建随机数组。

```
#生成 2 行 3 列的随机浮点数组
np.random.rand(2,3)
#生成 2 行 2 列的 10 以内的随机整数数组
np.random.randint(0,10,(2,2))
#生成 2 行 3 列的[1,2)的随机浮点数组
np.random.uniform(1,2,(2,3))
```

6. 其他数据结构转换成 ndarray

NumPy 中可以通过 array()函数,将 Python 中常见的数值序列,如 List(列表)和 Tuple(元组)等,转换为 ndarray 数组。

【例 3.19】 将 list 类型转换成 ndarray。

```
import numpy as np
#List
```

```
data = [[2000, 'Ohino', 1.5],
        [2002, 'Ohino', 3.6],
        [2002, 'Nevada', 2.9]]
print(type(data))
#List to array
ndarr = np.array(data)
print(type(ndarr))
```

运行结果如下。

```
<class 'list'>
<class 'numpy.ndarray'>
```

3.1.5 切片、迭代和索引

切片是指取数据序列对象的一部分的操作,前面介绍过字符串、列表、元组都支持切片语法。ndarray 数组与其他数据序列类似,也可以进行索引、切片和迭代。



视频讲解

1. 切片

对 ndarray 进行切片操作与一维数组相同,用索引标记切片的起始和终止位置即可。因为 ndarray 可以是多维数组,在进行切片时,通常需要设定每个维度上的切片位置。

NumPy 还提供了一个 copy() 方法,可以根据现有的 ndarray 数组创建新的 ndarray 数组。使用 copy() 方法与切片,可以用原数组的一部分生成新数组。

【例 3.20】 创建二维 ndarray 的切片。

```
import numpy as np
#创建一个 4 行 6 列的二维数组
arr = np.arange(24).reshape(4, 6)
print('arr = \n', arr)
#截取第 2 行到最后一行、第 1 列到第 3 列构成的 ndarray
arr1 = arr[1:, :3]
print('B = \n', arr1)
```

运行结果如下。

```
arr =
[[ 0  1  2  3  4  5]
 [ 6  7  8  9 10 11]
 [12 13 14 15 16 17]
 [18 19 20 21 22 23]]
B =
[[ 6  7  8]
 [12 13 14]
 [18 19 20]]
```

【例 3.21】 使用 `numpy.copy()` 函数对 `ndarray` 数组进行切片复制。

```
import numpy as np
# 创建一个 4 行 6 列的二维数组
arr = np.arange(24).reshape(4, 6)
print('arr = \n', arr)
# 切片复制 arr 的第 2 行到第 4 行、第 1 列到第 3 列
arr2 = np.copy(arr[1:4, 0:3])
print('A = \n', arr2)
# 复制 arr2 到 arr3
arr3 = arr2.copy()
print('B = \n', arr3)
```

2. 迭代

与其他数据序列类似, `ndarray` 也可以通过 `for` 循环实现迭代。当维数多于一维时, 迭代操作使用嵌套的 `for` 循环。

迭代时, 通常按照第一条轴(默认为行)对二维数组进行扫描。如果需要按其他维度迭代, 可以使用 `apply_along_axis(func,axis,arr)` 函数指定当前处理的轴。

此外, NumPy 还包含一个循环迭代器类 `numpy.nditer`, 所生成的迭代器(Iterator)对象是一个根据位置进行遍历的对象。这是一个有效的多维迭代器对象, 与 Python 内置的 `iter()` 函数类似, 每个数组元素可使用迭代器对象来访问, 从而很方便地对数组进行遍历。

【例 3.22】 使用嵌套 `for` 循环对 `ndarray` 数组进行迭代遍历。

```
import numpy as np
a = np.arange(0, 60, 5)
a = a.reshape(3, 4)
for xline in a:
    for yitem in xline:
        print(yitem, end= ' ')
```

运行结果如下。

```
0 5 10 15 20 25 30 35 40 45 50 55
```

【例 3.23】 使用 `nditer` 对象对 `ndarray` 数组进行迭代。

```
import numpy as np
a = np.arange(0, 60, 5)
a = a.reshape(3, 4)
print(a)
print(np.nditer(a))
for x in np.nditer(a):
    print(x, end= ' ')
```

运行结果如下。

```
[[ 0  5 10 15]
 [20 25 30 35]
 [40 45 50 55]]
<numpy.nditer object at 0x000002D121467CB0>
0 5 10 15 20 25 30 35 40 45 50 55
```

迭代的顺序与数组的内容布局相匹配,不受数据排序的影响。例如,对上述数组的转置进行迭代,可以发现,虽然数据的显示顺序发生了变化,但不影响迭代的顺序。

【例 3.24】 转置数组的迭代。

```
import numpy as np
a = np.arange(0, 60, 5)
a = a.reshape(3, 4)
print(a)
b = a.T
print(b)
print('Iterator in a:')
for x in np.nditer(a):
    print(x, end='|')
print('\nIterator in a.T:')
for y in np.nditer(b):
    print(y, end='|')
```

运行结果如下。

```
[[ 0  5 10 15]
 [20 25 30 35]
 [40 45 50 55]]
[[ 0 20 40]
 [ 5 25 45]
 [10 30 50]
 [15 35 55]]
Iterator in a:
0|5|10|15|20|25|30|35|40|45|50|55|
Iterator in a.T:
0|5|10|15|20|25|30|35|40|45|50|55|
```

如果需要特定的顺序,可以设置显式参数来强制 nditer 对象使用某种顺序,如例 3.25。

【例 3.25】 数组的访问顺序。

```
import numpy as np
a = np.arange(0, 60, 5)
a = a.reshape(3, 4)
print(a)
print('C 风格的顺序:')
for x in np.nditer(a, order = 'C'):
    print(x, end='|')
```

```
print( '\n' )
print( 'F 风格的顺序:')
for y in np.nditer(a, order = 'F'):
    print(y,end='|')
```

运行结果如下。

```
[[ 0  5 10 15]
 [20 25 30 35]
 [40 45 50 55]]
C风格的顺序:
0|5|10|15|20|25|30|35|40|45|50|55|

F风格的顺序:
0|20|40|5|25|45|10|30|50|15|35|55|
```

3.1.6 NumPy 计算

NumPy 中的 ndarray 可以直接进行基本运算,包括条件运算、统计运算,以及基本数组运算等。

1. 条件运算

NumPy 中的条件运算除了常见的比较大小运算,还可以使用 where()函数实现查找操作。where()函数格式如下。

```
where(condition, x if true, y if false)
```

该函数根据条件表达式 condition 的值返回特定的数组。当条件为真时返回 x 数组,条件为假时返回 y 数组。

【例 3.26】 简单条件运算。

```
import numpy as np
stus_score = np.array([[80, 88], [82, 81], [84, 75], [86, 83], [75, 81]])
result=[stus_score> 80]
print(result)
```

运行结果如下。

```
[array([[False,  True],
        [ True,  True],
        [ True, False],
        [ True,  True],
        [False,  True]])]
```

【例 3.27】 用 np.where()函数实现数据筛选。

```
import numpy as np
num = np.random.normal(0, 1, (3,4))
print(num)
```



```
num[num<0.5]=0
print(num)
print(np.where(num>0.5,1,0))
```

运行结果如下。

```
[[-1.76760946  1.37716782 -0.93033474  0.89155541]
 [-0.91615883 -1.00495783 -0.66251008  1.64800667]
 [-0.59892913  0.49531236 -0.85283977  0.35239407]]
[[0.          1.37716782  0.          0.89155541]
 [0.          0.          0.          1.64800667]
 [0.          0.          0.          0.          ]]
[[0 1 0 1]
 [0 0 0 1]
 [0 0 0 0]]
```

2. 统计计算

NumPy 提供了丰富的统计函数,常用统计函数如表 3.7 所示。

表 3.7 NumPy 的常用统计函数

函 数	描 述
argmax()	求最大值的索引
argmin()	求最小值的索引
cumsum()	从第一个元素开始累加各元素
max()	求最大值
mean()	求算术平均值
min()	求最小值
std()	求数组元素沿给定轴的标准偏差
sum()	求和

【例 3.28】 ndarray 的统计计算。

```
import numpy as np
stus_score = np.array([[80, 88], [82, 81], [84, 75], [86, 83], [75, 81]])
# 求每列的最大值(0 表示列)
result = np.max(stus_score, axis=0)
print(result)
# 求每行的最大值(1 表示行)
result = np.max(stus_score, axis=1)
print(result)
# 求每行的最小值(1 表示行)
result = np.min(stus_score, axis=1)
print(result)
# 求每列的平均值(0 表示列)
```

```
result = np.mean(stus_score, axis=0)
print(result)
```

运行结果如下。

```
[86 88]
[88 82 84 86 81]
[80 81 75 83 75]
[81.4 81.6]
```

3.2 Pandas

Pandas (Python Data Analysis Library) 是 Python 的一个数据分析包, 是基于 NumPy 的一种工具, 是为了解决数据分析任务而创建的。

Pandas 使用强大的数据结构提供高性能的数据操作和分析工具。模块提供了大量的能便捷处理数据的函数、方法和模型, 还包括操作大型数据集的工具, 从而能够高效分析数据。

Pandas 主要处理以下三种数据结构。

(1) Series: 一维数组, 与 NumPy 中一维的 ndarray 类似。数据结构接近 Python 中的 List 列表, 数据元素可以是不同的数据类型。

(2) DataFrame: 二维数据结构。DataFrame 可以理解成 Series 的容器, 其内部的每项元素都可以看作一个 Series。DataFrame 是重要的数据结构, 在机器学习中经常使用。

(3) Panel: 三维数组, 可以理解为 DataFrame 的容器, 其内部的每项元素都可以看作一个 DataFrame。

这些数据结构都构建在 NumPy 数组的基础之上, 运算速度很快。

3.2.1 Series 数据结构

Series 是一种类似于 一维数组的对象, 它由一组数据以及一组与之相关的数据标签 (即索引) 组成, 数据可以是任何 NumPy 数据类型 (整数、字符串、浮点数、Python 对象等)。

1. 创建 Series 对象

创建 Series 对象可以使用函数 `pd.Series(data, index)`, 其中, `data` 表示数据值, `index` 是索引, 默认情况下会自动创建一个 $0 \sim N-1$ (N 为数据的长度) 的整数型索引。访问 Series 对象的成员可以使用类似 ndarray 数组的切片访问方法, 也可以按索引名访问。

【例 3.29】 创建一个 Series 对象。

```
import pandas as pd
s = pd.Series([1, 3, 5, 9, 6, 8])
print(s)
```

【例 3.30】 为一个地理位置数据创建 Series 对象。

```
import pandas as pd
#使用列表创建,索引值为默认值
print('----- 列表创建 Series -----')
s1=pd.Series([1,1,1,1,1])
print(s1)
print('----- 字典创建 Series -----')
#使用字典创建,索引值为字典的 key 值
s2=pd.Series({'Longitude':39, 'Latitude':116, 'Temperature':23})
print('First value in s2:',s2['Longitude'])
print('----- 用序列作 Series 索引 -----')
#使用由 range() 函数生成的迭代序列设置索引值
s3=pd.Series([3.4,0.8,2.1,0.3,1.5],range(5,10))
print('First value in s3:',s3[5])
```

运行结果如下。

```
----- 列表创建 Series -----
0    1
1    1
2    1
3    1
4    1
dtype: int64
----- 字典创建 Series -----
First value in s2: 39
----- 用序列作 Series 索引 -----
First value in s3: 3.4
```

2. 访问 Series 数据对象

1) 修改数据

可以通过赋值操作直接修改 Series 对象成员的值,还可以为多个对象成员批量修改数据。

【例 3.31】 对例 3.30 创建的 s2,将温度增加 2℃,设置城市为 Beijing。

```
#温度增加 2℃,设置城市为 Beijing
s2["City"]="Beijing"
s2['Temperature']+=2
s2
```

运行结果如下。

```
Longitude      39
Latitude       116
```

```

Temperature      25
City              Beijing
dtype: object

```

2) 按条件表达式筛选数据

【例 3.32】 找出 s3 中大于 2 的数据。

```
s3[s3>2]
```

输出结果如下。

```

5      3.4
7      2.1
dtype: float64

```

3) 增加对象成员

两个 Series 对象可以通过 `append()` 函数进行拼接,从而产生一个新的 Series 对象。进行拼接操作时,原来的 Series 对象内容保持不变。

【例 3.33】 为 s2 添加一项湿度数据。

```

stiny=pd.Series({'humidity':84})
s4=s2.append(stiny)
print('-----原 Series:-----\n',s2)
print('-----新 Series:-----\n',s4)

```

输出结果如下。

```

-----原 Series:-----
Longitude      39
Latitude       116
Temperature     25
City           Beijing
dtype: object
-----新 Series:-----
Longitude      39
Latitude       116
Temperature     25
City           Beijing
humidity       84
dtype: object

```

可以看到,合并操作不影响原 Series。结果中原 s2 数据没有变化,新创建的 s4 对象接收了合并后的新数据。

4) 删除对象成员

可以通过 `drop()` 函数删除对象成员,可以删除一个或多个对象成员。与 `append()` 函数一样,`drop()` 函数也不改变原对象的内容,而会返回一个新的 Series 对象。