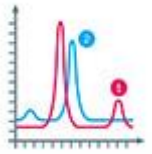

NHẬP MÔN LẬP TRÌNH KHOA HỌC DỮ LIỆU

Bài 7: Thư viện NumPy

Nội dung

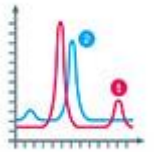

1. Một số gói python cho KHDL
2. Giới thiệu về NumPy
3. Khởi tạo mảng và chỉ số
4. Các phép toán trên mảng
5. Một số thao tác thông dụng
6. Bài tập

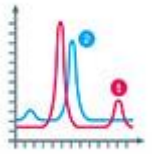

Phần 1

Một số gói python cho KHDL

Một số gói python cho KHDL

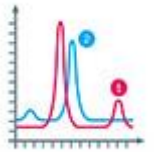

- Ngôn ngữ python có hệ thống các gói rất phong phú, hỗ trợ nhiều lĩnh vực khác nhau, từ xây dựng ứng dụng, xử lý web, xử lý text, xử lý ảnh,…
  - Sử dụng pip để tải các gói mới về từ internet
- Một số gói dành cho lập trình thông thường:
  - os: xử lý file và tương tác với hệ điều hành
  - networkx và igraph: làm việc với dữ liệu đồ thị, có thể làm việc với dữ liệu rất lớn (đồ thị hàng triệu đỉnh)
  - regular expressions: tìm kiếm mẫu trong dữ liệu text
  - BeautifulSoup: trích xuất dữ liệu từ file HTML hoặc từ website

Một số gói python cho KHDL

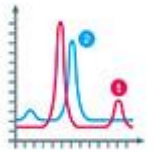

- NumPy (Numerical Python): là gói chuyên về xử lý dữ liệu số (nhiều chiều); gói cũng chứa các hàm đại số tuyến tính cơ bản, biến đổi fourier, sinh số ngẫu nhiên nâng cao,…
- SciPy (Scientific Python): dựa trên Numpy, cung cấp các công cụ mạnh cho khoa học và kỹ nghệ, chẳng hạn như biến đổi fourier rời rạc, đại số tuyến tính, tối ưu hóa và ma trận thưa
- Matplotlib: chuyên sử dụng để vẽ biểu đồ, hỗ trợ rất nhiều loại biểu đồ khác nhau

Một số gói python cho KHDL

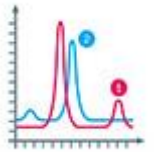

- Pandas: chuyên sử dụng cho quản lý và tương tác với dữ liệu có cấu trúc, được sử dụng rộng rãi trong việc thu thập và tiền xử lý dữ liệu
- Scikit Learn: chuyên về học máy, dựa trên NumPy, SciPy và matplotlib; thư viện này có sẵn nhiều công cụ hiệu quả cho học máy và thiết lập mô hình thống kê chẳng hạn như các thuật toán phân lớp, hồi quy, phân cụm và giảm chiều dữ liệu
- Statsmodels: cho phép người sử dụng khám phá dữ liệu, ước lượng mô hình thống kê và kiểm định

Một số gói python cho KHDL

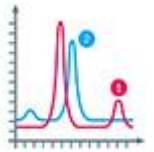

- Seaborn: dự trên matplotlib, cung cấp các công cụ diễn thị (visualization) dữ liệu thống kê đẹp và hiệu quả, mục tiêu của gói là sử dụng việc diễn thị như là trọng tâm của khám phá và hiểu dữ liệu
- Bokeh: để tạo các ô tương tác, biểu đồ tổng quan trên nền web, rất hiệu quả khi tương tác với dữ liệu lớn và trực tuyến
- Blaze: gói dựa trên Numpy và Pandas hướng đến dữ liệu phân tán hoặc truyền phát, là công cụ mạnh mẽ tạo diễn thị về dữ liệu cực lớn

Một số gói python cho KHDL

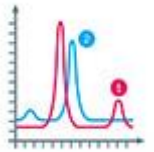

- Scrapy: chuyên về thu thập thông tin trên web, rất phù hợp với việc lấy các dữ liệu theo mẫu
- SymPy: tính toán chuyên ngành dùng cho số học, đại số, toán rời rạc và vật lý lượng tử
- Theano: gói chuyên dùng tính toán hiệu quả các mảng nhiều chiều, sử dụng rộng rãi trong học máy
- TensorFlow: gói chuyên dùng cho học máy của Google, đặc biệt là các mạng thần kinh nhân tạo
- Keras: thư viện cấp cao chuyên về học máy, sử dụng Theano, TensorFlow hoặc CNTK làm phụ trợ

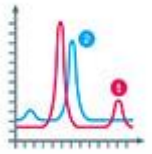

Phần 2

Giới thiệu về NumPy

Giới thiệu về NumPy

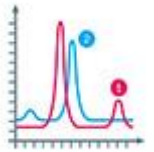

- NumPy là thư viện bổ sung của python, do không có sẵn, ta phải cài đặt: `pip install numpy`

```
Microsoft Windows [Version 10.0.16299.371]
(c) 2017 Microsoft Corporation. All rights reserved.

d:\Nam.DHTL\2.2 Nhập môn Khoa học Dữ liệu>pip install numpy
Collecting numpy
  Downloading https://files.pythonhosted.org/packages/af/e4/7d7107bdfb5c33f6cf33cdafea8c27d1
209cf0068a6e3e3d3342be6f3578/numpy-1.14.3-cp36-none-win_amd64.whl (13.4MB)
    100% |                                | 13.4MB 60kB/s
Installing collected packages: numpy
Successfully installed numpy-1.14.3
```

  - Một số hệ thống python đã có sẵn numpy thì có thể bỏ qua bước này
  - Cách đơn giản nhất để kiểm tra xem hệ thống đã cài numpy hay không là thử import gói xem có bị báo lỗi hay không: `import numpy as np`

Đặc điểm của NumPy

- Đối tượng chính của NumPy là các mảng đa chiều đồng nhất (homogeneous multidimention array)
  - Kiểu dữ liệu phần tử con trong mảng phải giống nhau
  - Mảng có thể một chiều hoặc nhiều chiều
  - Các chiều (axis) được đánh thứ tự từ 0 trở đi
  - Số chiều gọi là hạng (rank)
  - Có đến 24 kiểu số khác nhau
  - Kiểu ndarray là lớp chính xử lý dữ liệu mảng nhiều chiều
  - Rất nhiều hàm và phương thức xử lý ma trận

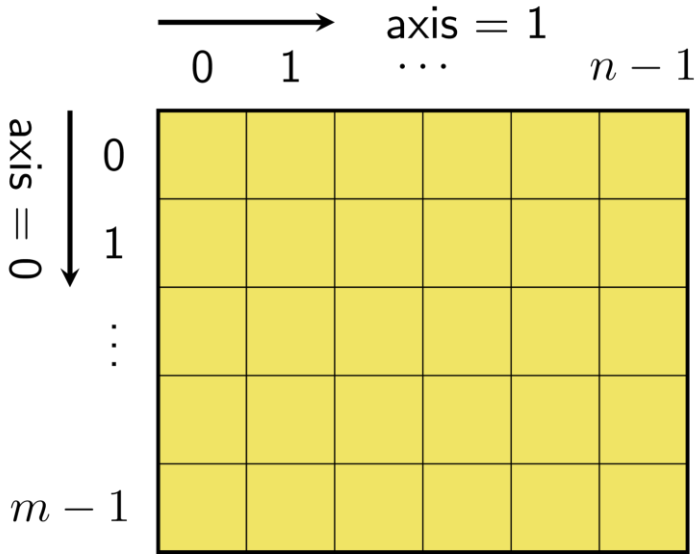

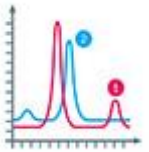

Phần 3

Khởi tạo mảng và chỉ số

Tạo mảng và truy cập

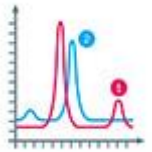

```
import numpy as np

a = np.array([1, 2, 3])   # tạo mảng 1 chiều
print(type(a))            # in "<class 'numpy.ndarray'>"
print(a.shape)            # in "(3,)"
print(a[0], a[1], a[2])   # in "1 2 3"
a[0] = 5
print(a)                  # in "[5, 2, 3]"
b = np.array([[1, 2, 3],[4, 5, 6]])    # tạo mảng 2 chiều
print(b.shape)                         # in "(2, 3)"
print(b[0, 0], b[0, 1], b[1, 0])       # in "1 2 4"
print(np.diag([1, 3, 4]))              # in ra cái gì?
```

Nhiều cách khởi tạo phong phú

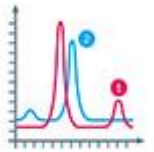

```
import numpy as np
x = np.range(3.0)                   # mảng [0. 1. 2.]
a = np.zeros((2, 2))                # mảng 2x2 toàn số 0
b = np.ones((1, 2))                 # mảng 1x2 toàn số 1
c = np.full((3, 2, 2), 9)           # mảng 3x2x2 toàn số 9
d = np.eye(2)                       # ma trận đơn vị 2x2
e = np.random.random(3, 2)          # mảng 3x2 ngẫu nhiên [0,1)
# mảng 2x3 điền các số từ 1 đến 6, kiểu số nguyên 32 bit
x = np.array([[1, 2, 3], [4, 5, 6]], np.int32)
print(x.ndim, x.size)
print(x.shape)                      # in "(2, 3)"
print(x.dtype)                      # in "dtype('int32')"
```

Truy cập theo chỉ số (slicing)

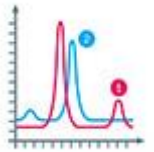

```
import numpy as np

# mảng 3x4
a = np.array([[1, 2, 3, 4], [5, 6, 7, 8], [9, 10, 11, 12]])

# mảng 2x2 trích xuất từ a, dòng 0+1, cột 1+2
b = a[:2, 1:3]

# chú ý: mảng của numpy tham chiếu chứ không copy dữ liệu
print(a[0, 1])        # in "2"
b[0, 0] = 77          # b[0, 0] cũng là a[0, 1]
print(a[0, 1])        # in "77"
```

Cẩn thận với slicing

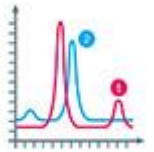

```
row_r1 = a[1, :]                # mảng 1 chiều độ dài 4
row_r2 = a[1:2, :]              # mảng 2 chiều 1x4
print(row_r1, row_r1.shape)     # in ra "[5 6 7 8] (4,)"
print(row_r2, row_r2.shape)     # in ra "[[5 6 7 8]] (1, 4)"

col_r1 = a[:, 1]                # mảng 1 chiều độ dài 3
col_r2 = a[:, 1:2]              # mảng 2 chiều 3x1
print(col_r1, col_r1.shape)     # in ra "[ 2  6 10] (3,)"
print(col_r2, col_r2.shape)     # in ra "[[ 2]
                                #        [ 6]
                                #        [10]] (3, 1)"
```

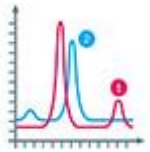

Phần 4

Các phép toán trên mảng

NumPy có nhiều phép toán về mảng

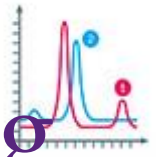

```
import numpy as np

x = np.array([[1, 2], [3, 4]], dtype=np.float64)
y = np.array([[5, 6], [7, 8]], dtype=np.float64)

print(x + y)         # print(np.add(x, y)), xử lý khác list
print(x - y)         # print(np.subtract(x, y))
print(x * y)         # print(np.multiply(x, y))
print(x / y)         # print(np.divide(x, y))
print(np.sqrt(x))    # khai căn tất cả các phần tử
print(2**x)          # tính 2 mũ các phần tử trong x
# chú ý: phép nhân/chia thực hiện theo cặp phần tử của x và y
```

Nhân ma trận (dot) và nghịch đảo

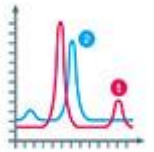

```
import numpy as np

x = np.array([[1, 2],[3, 4]])
y = np.array([[5, 6],[7, 8]])

v = np.array([9, 10])
w = np.array([11, 12])

print(v.dot(w))              # tương tự print(np.dot(v, w))
print(x.dot(v))              # tương tự print(np.dot(x, v))
print(x.dot(y))              # tương tự print(np.dot(x, y))
print(np.linalg.inv(x))      # tính và in nghịch đảo của x
```

Ma trận chuyển vị

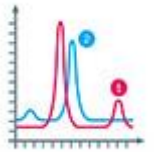

```
import numpy as np

x = np.array([[1, 2], [3, 4]])
print(x)          # in ra "[[1 2]
                  #         [3 4]]"
print(x.T)        # in ra "[[1 3]
                  #         [2 4]]"
# chú ý: mảng 1 chiều không có chuyển vị
y = np.array([1, 2, 3])
print(y)          # in ra "[1 2 3]"
print(y.T)        # in ra "[1 2 3]"
z = np.array([[1, 2, 3]])
print(z.T)        # đoán xem in ra cái gì?
```

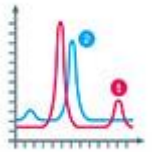

Phần 5

Một số thao tác thông dụng

Đọc dữ liệu từ file

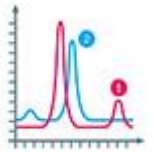

```
from io import StringIO
import numpy as np


c = StringIO("0 1\n2 3")
x = np.loadtxt(c)         # array([[ 0.,  1.],
                          #        [ 2.,  3.]])
d = StringIO("M 21 72\nF 35 58")
y = np.loadtxt(d, dtype={'names': ('gender', 'age', 'weight'),
'formats': ('S1', 'i4', 'f4')})
print(y)                  # [('M', 21, 72.0), ('F', 35, 58.0)]
```

Cơ chế broadcasting

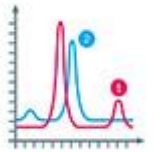

```
import numpy as np


x = np.array([[1, 2, 3], [4, 5, 6], [7, 8, 9], [10, 11, 12]])
v = np.array([1, 0, 1])
y = x + v
print(y)      # in ra "[[ 2  2  4]
              #         [ 5  5  7]
              #         [ 8  8 10]
              #         [11 11 13]]"
```

Tính tổng theo các trục

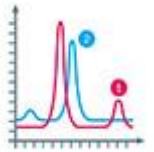

```
import numpy as np

x = np.array([[1, 2], [3, 4]])

print(np.sum(x))            # tính tổng toàn bộ x, in "10"
print(np.sum(x, axis=0))    # tính tổng mỗi cột, in "[4 6]"
print(np.sum(x, axis=1))    # tính tổng mỗi hàng, in "[3 7]"
```

Trích xuất dữ liệu theo dãy

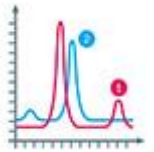

```
import numpy as np


a = np.array([[1,2], [3, 4], [5, 6]])
# Prints "[1 4 5]"
print(a[[0, 1, 2], [0, 1, 0]])
# Prints "[1 4 5]"
print(np.array([a[0, 0], a[1, 1], a[2, 0]]))
# Prints "[2 2]"
print(a[[0, 0], [1, 1]])
# Prints "[2 2]"
print(np.array([a[0, 1], a[0, 1]]))
```

Lọc phần tử theo chỉ số

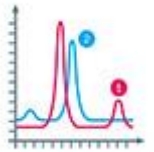

```
import numpy as np

a = np.array([[1, 2, 3], [4, 5, 6], [7, 8, 9], [10, 11, 12]])
b = np.array([0, 2, 0, 1])   # b là mảng các chỉ số
print(a[np.arange(4), b])    # in ra "[1  6  7 11]"

# cộng tất cả các phần tử được lọc thêm 10
a[np.arange(4), b] += 10

print(a)                     # in ra "array([[11,  2,  3],
                             #               [ 4,  5, 16],
                             #               [17,  8,  9],
                             #               [10, 21, 12]])
```

Lọc dữ liệu theo điều kiện

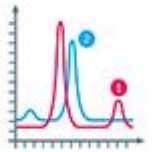

```
import numpy as np

a = np.array([[1, 2], [3, 4], [5, 6]])

bool_idx = (a > 2)
print(bool_idx)              # in ra "[[False False]
                             #         [ True  True]
                             #         [ True  True]]"
# lọc dữ liệu trong a, trả về một dãy
print(a[bool_idx])           # Prints "[3 4 5 6]"
# có thể viết trực tiếp điều kiện (ngắn gọn hơn)
print(a[a > 2])              # Prints "[3 4 5 6]"
```

Điều chỉnh cỡ ma trận

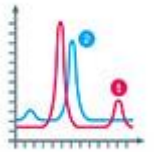

```
>>> x = np.array([[1, 3], [4, 4], [4, 2]])
>>> x.shape
(3, 2)
>>> x = np.array([[1, 3], [4, 4], [4, 2]])
>>> x = x.reshape(2, 3)        // chỉnh thành 2x3
>>> x
array([[1, 3, 4],  [4, 4, 2]])
>>> x = np.array([[1, 3], [4, 4], [4, 2]])
>>> x = x.reshape(2, -1)       // tự tính chiều còn lại
>>> x
array([[1, 3, 4],  [4, 4, 2]])
```

Elementwise operation

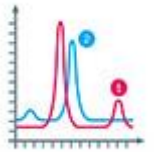

```
>>> x = np.array([1, 2, 3])
>>> np.log(x)          // lấy log cơ số e từng phần tử
array([ 0,  0.69314718,  1.09861229])
>>> np.abs(x)          // lấy trị tuyệt đối từng phần tử
array([1, 2, 3])
>>> np.maximum(x, 2) // so sánh từng phần tử với 2 và lấy max
array([2, 2, 3])
>>> np.minimum(x, 2) // so sánh từng phần tử với 2 và lấy min
array([1, 2, 2])
>>> x**2               // lũy thừa 2 từng phần tử
array([1, 4, 9])
```

Tính norm cấp 2 của vector

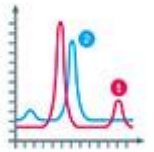

```
# norm cấp 2 của vector là chiều dài của vector đó
# |x|_2 = |x| = ∛(x_1^2 + x_2^2 + ⋯ + x_n^2)

x = np.array([[0, 3], [4, 3], [6, 8]])
# tính norm mỗi dòng, kết quả: array([[3], [5], [10]])
np.linalg.norm(x, axis = 1, keepdims = True)

x = np.array([[0, 6], [4, 0], [3, 8]])
# tính norm mỗi cột, kết quả: array([[5, 10]])
np.linalg.norm(x, axis = 0, keepdims = True)
```

Sinh mảng ngẫu nhiên

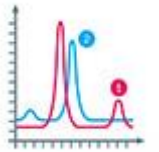

```
np.random.random(3, 2) # mảng 3x2 ngẫu nhiên trong [0,1)
np.random.randn()      # một số sinh theo phân phối chuẩn
np.random.randn(3)     # mảng 3 số theo phân phối chuẩn
np.random.randn(3, 4)  # mảng 3x4 theo phân phối chuẩn
# mảng 2x4 gồm các số nguyên trong [3,15)
np.random.randint(3, 15, (2, 4))
# sinh một dãy là hoán vị ngẫu nhiên của dãy (0, 1, 2, …, 19)
np.random.permutation(20)
```

Các hàm thống kê

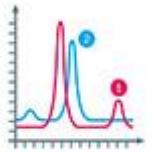

```
import numpy as np
a = np.random.randn(3, 4)
# tính trung bình của cả ma trận a
print(np.mean(a))
# tính trung vị của cột đầu tiên
print(np.median(a[:,0]))
# tính độ lệch chuẩn của từng dòng
print(a.std(axis=0))
# tính phương sai của từng cột
print(a.var(axis=1))
```

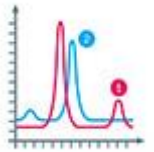

Phần 6

Bài tập

Bài tập

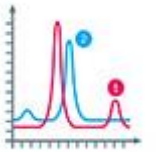

1. Tạo một ma trận 4x4 toàn các giá trị False
2. Cho một dãy số nguyên 100 phần tử, hãy tách lấy tất cả những phần tử lẻ cho vào một mảng
3. Cho một dãy số tự nhiên 20 phần tử, hãy thay thế tất cả những phần tử lẻ bằng số -1
4. Hai mảng a và b có cùng số dòng, hãy ghép chúng theo các dòng thành mảng c, các cột của a rồi đến các cột của b
5. Mảng a và b có cùng số cột, hãy ghép chúng theo các cột thành mảng c, các dòng của a rồi đến của b

Bài tập

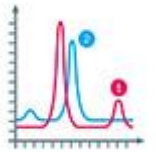

6. Cho một mảng a, hãy in ra tất cả những phần tử trong khoảng từ 5 đến 10
7. Sinh ra một mảng số thực có 1000 phần tử, các phần tử nằm trong khoảng từ -0.5 đến <0.5
8. Sinh một ma trận 3x5 gồm các số ngẫu nhiên từ 0 đến nhỏ hơn 10, tính và in ra số lớn nhất trên mỗi dòng của ma trận
9. Nhập mảng a và b có 10 phần tử, tính khoảng cách euclid giữa a và b

Bài giải

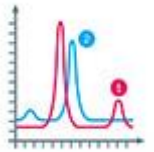

1. `numpy.full((4, 4), False, dtype=bool)`
2.
```
a = numpy.random.randint(1000, size=100)
b = a[a % 2 == 1]
print(b)
```
3.
```
a = numpy.random.randint(300, size=20)
a[a % 2 == 1] = -1
print(a)
```
4. `c = np.concatenate([a, b], axis=1)`
5. `c = np.concatenate([a, b], axis=0)`