SCIKIT-LEARN

(самая известная библиотека Python для машинного обучения)

scikit-learn требует наличия пакетов NumPy и SciPy.
Для построения графиков и интерактивной работы необходимо также установить matplotlib, IPython и Jupyter Notebook

Установка свободного дистрибутива Python для научных вычислений, специально предназначенного для Windows, включающего:

NumPy, SciPy, matplotlib, pandas, IPython и scikit-learn

Установка из командной строки Windows cmd: **pip install numpy scipy matplotlib ipython scikit-learn pandas**
Запуск cmd: **ipython3 notebook**
Запустится в веб-браузере Jupyter notebook

[Удобнее работать в JupyterLab: инсталл. **pip install jupyter lab**,
запуск: **jupyter lab**
Запустится JupyterLab]

Jupyter Notebook, JupyterLab

Интерактивная среда для запуска программного кода в браузере.
Инструмент для анализа данных,
Позволяет легко интегрировать программный код, текст и изображения.

NumPy

Один из основных пакетов для научных вычислений в Python.
Содержит функциональные возможности для работы с многомерными массивами, высокоуровневыми математическими функциями (операции линейной алгебры, преобразование Фурье, генератор псевдослучайных чисел).
Задает структуру данных - массив «NumPy»

Класс ndarray, многомерный (n-мерный) массив

```
import numpy as np
x = np.array([[1, 2, 3], [4, 5, 6]])
print("x:\n{}".format(x))
x:
[[1 2 3]
 [4 5 6]]
```

SciPy

Библиотека для научных вычислений: матричные вычисления, процедуры линейной алгебры, оптимизация, обработка сигналов, статистика.

SCIKIT-LEARN использует набор функций SciPy для реализации своих алгоритмов.

Пакет scipy.sparse создает разреженные матрицы (sparse matrices), которые представляют собой еще один формат данных для SCIKIT-LEARN.

Разреженная матрица - это матрица с преимущественно нулевыми элементами.

Подробную информацию о разреженных матрицах SciPy можно найти в **SciPy Lecture Notes**

```
 # (Создаем 2D массив NumPy с единицами по главной диагонали и нулями в остальных ячейках)
from scipy import sparse
eye = np.eye(4)
#numpy.eye(R, C = None, k = 0, dtype = type <‘float’>) : Return a matrix having 1’s on the diagonal and 0’s elsewhere w.r.t. k
print("массив NumPy:\n{}".format(eye))
массив NumPy:
[[1. 0. 0. 0.]
 [0. 1. 0. 0.]
 [0. 0. 1. 0.]
 [0. 0. 0. 1.]]
```

SciPy

```
# Массив NumPy преобразуем в разреженную матрицу SciPy в формате CSR
# Compressed Sparse Row Format (CSR), Compressed Sparse Column Format (CSC)
sparse_matrix = sparse.csr_matrix(eye)                    # единичная - по диагонали 1, ост.0
print("\nразреженная матрица SciPy в формате CSR:\n{}".format(sparse_matrix))
разреженная матрица SciPy в формате CSR:
(0, 0) 1.0
(1, 1) 1.0
(2, 2) 1.0
(3, 3) 1.0
```

```
# Создание разреженной матрицы с использованием формата
# COO (coordinate format) – координатный формат, задаем только координаты ненулевые элементов матрицы
# (номера строк и столбцов)
data = np.ones(4)
row_indices = np.arange(4)
col_indices = np.arange(4)
eye_coo = sparse.coo_matrix((data, (row_indices, col_indices)))
print("формат COO:\n{}".format(eye_coo))
формат COO:
(0, 0) 1.0
(1, 1) 1.0
(2, 2) 1.0
(3, 3) 1.0
```

Задание: создать разреженную матрицу M, dim(M)=10×6, где $M_{2,4}=M_{6,4}=M_{2,5}=M_{6,6}=1$ с использованием обоих форматов. Вывести на печать, сравнить.

Matplotlib

Основная библиотека для построения графиков.
Включает функции для создания высококачественных визуализаций типа линейных диаграмм, гистограмм, диаграмм разброса и т.д.
При работе в Jupyter Notebook можно вывести рисунок прямо в браузере с помощью встроенных команд %matplotlib notebook и %matplotlib inline.

```
# Построение графика с использованием библ. Matplotlib
%matplotlib inline
import matplotlib.pyplot as plt
x = np.linspace(-10, 10, 100)          # переменная X из 100 чисел от -10 до 10 (ось абсцисс)
y = np.sin(x)                          # функция от X
plt.plot(x, y, marker="x")             # построение графика
```

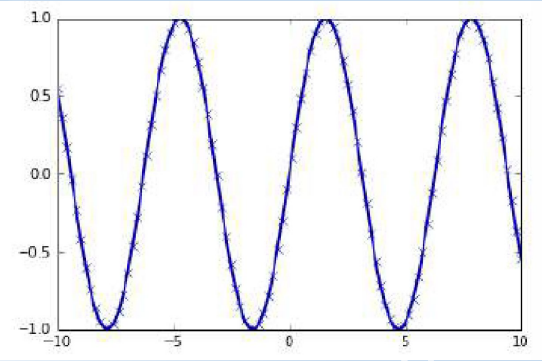

Pandas

Библиотека для обработки и анализа данных.
Построена на основе структуры данных DataFrame (таблицы, похожие на таблицы Excel).
Имеет широкие возможности по работе с таблицами, в частности, позволяет выполнять SQL-подобные запросы.
В отличие от NumPy, который требует, чтобы все записи в массиве были одного и того же типа, в pandas каждый столбец может иметь отдельный тип (например, целые числа, даты, числа с плавающей точкой и строки).
Способна работать с различными форматами файлов и баз данных, например, с файлами SQL, Excel и CSV.

Подробная информация – в книге
McKinney W. Python for Data Analysis. Data Wrangling with Pandas, NumPy, and Ipython. O'Reilly, 2012

```
# Пример создания DataFrame таблицы
inlineimport pandas as pd
# набор данных с характеристиками пользователей
data = {'Name': ["John", "Anna", "Peter", "Linda"], 'Location' : ["New York", "Paris", "Berlin", "London"], 'Age' : [24, 13, 53, 33]}
data_pandas = pd.DataFrame(data)
display(data_pandas)                    # IPython.display позволяет "красиво напечатать"  таблицу
```

	Age	Location	Name
0	24	New York	John
1	13	Paris	Anna
2	53	Berlin	Peter
3	33	London	Linda

в Jupyter notebook

	Name	Location	Age
0	John	New York	24
1	Anna	Paris	13
2	Peter	Berlin	53
3	Linda	London	33

в JupyterLab

2. Задача классификации. OneR (one rule) алгоритм

Вспомнить:

***class* (target, цель)**

Есть ли на фото тигр?
Болен ли пациент таким-то заболеванием?
Продается ли этот товар нужными объемами?

классификация

Обучить классификатор на известных классах так, чтобы при предъявлении ему неизвестного класса, он отнес бы его к одному из известных.

Задача: классифицировать сорта цветков ириса

Исходные данные: *features*
-длина и ширина лепестков (см),
-длина и ширина чашелистиков (см).

Возможные сорта *classes*
-Setosa,
-Versicolor,
-Virginica
различаются на основе перечисленных характеристик (признаков, features)

Цель: построить классификатор (модель машинного обучения), который сможет обучиться на основе перечисленных характеристик цветков ириса, классифицированных по сортам, и затем предскажет сорт для любого далее предъявляемого ему цветка ириса. *labels*

? Это обучение с учителем или без?

Поскольку есть примеры классов, то решаемая задача является задачей *обучения с учителем*

2. Задача классификации. OneR (one rule) алгоритм

Загрузить файл данных из модуля datasets библиотеки scikit-learn, вызвав функцию load_iris:

```
# загрузка файла данных
import numpy as np
from sklearn.datasets import load_iris
iris_dataset = load_iris()
X = iris_dataset.data
y = iris_dataset.target
```

Объект iris содержит ключи и значения. Просмотр структуры

```
# Структура - ключи и значения
print("Ключи iris_dataset: \n{}".format(iris_dataset.keys()))
```

Ключи iris_dataset:
dict_keys(['target_names', 'feature_names', 'DESCR', 'data', 'target'])

```
# ключ DESCR – краткое описание набора данных/ Просмотр DESCR одним из способов:
print(iris_dataset.DESCR)
# print("Ключи iris_dataset: \n{}".format(iris_dataset.keys()))
# print("Ключи iris_dataset: {}".format(iris_dataset.DESCR))

# Сами данные записаны в массивах target и data. data – массив NumPy, который содержит количественные измерения длины
# чашелистиков, ширины чашелистиков, длины лепестков и ширины лепестков:
print("Тип массива data: {}".format(type(iris_dataset['data'])))
```

Тип массива data: <class 'numpy.ndarray'>

```
# Строки в data соответствуют цветам ириса = примерам (samples), а столбцы - 4 характеристики (признака, feautures)
print("Форма (shape) массива data: {}".format(iris_dataset['data'].shape))
```

Форма (*shape*) массива data: (150, 4)

Задание1: вывести на печать первые 5 примеров (samples) массива data

2. Задача классификации. OneR (one rule) алгоритм

```
# Массив target содержит сорта уже измеренных цветов, записанные в виде массива NumPy
# и представляет собой одномерный массив - по 1му элементу для каждого цветка
# Сорта (классы) кодируются  целыми числами от 0 до 2:
# 0 – setosa,1 – versicolor, 2 – virginica

print("Тип массива target: {}".format(type(iris_dataset['target'])))
print("Форма массива target: {}".format(iris_dataset['target'].shape))
print("Классы:\n{}".format(iris_dataset['target']))

Тип массива target: <class 'numpy.ndarray'>
Форма массива target: (150,)
Ответы:
[0 0 0 0 0 0 0 0 0 0 0 0 0 0 0 0 0 0 0 0 0 0 0 0 0 0 0 0 0 0 0 0 0 0 0 0 0 0
0 0 0 0 0 0 0 0 0 0 0 0 0 1 1 1 1 1 1 1 1 1 1 1 1 1 1 1 1 1 1 1 1 1 1 1 1
1 1 1 1 1 1 1 1 1 1 1 1 1 1 1 1 1 1 1 1 1 1 1 1 1 2 2 2 2 2 2 2 2 2 2 2 2
2 2 2 2 2 2 2 2 2 2 2 2 2 2 2 2 2 2 2 2 2 2 2 2 2 2 2 2 2 2 2 2 2 2 2 2 2
2 2]
```

Задание2: просмотреть остальные ключи

2. Задача классификации. OneR (one rule) алгоритм

Для решения задачи классификации с учителем надо иметь 2 набора данных:

-обучающие данные (training data, training set).

-тестовые данные (test data, test set, hold-out set).

Функция train_test_split (библиотека scikit-learn) перемешивает исходный набор данных случайным образом и разбивает его на две части: обучающий набор = 75% samples, тестовый набор = 25% samples

```
# Чтобы в точности для отладки повторно воспроизвести случайное перемешивание, в генераторе псевдослучайных чисел зададим
# фиксированное стартовое значение random_state=0
from sklearn.model_selection import train_test_split
X_train, X_test, y_train, y_test = train_test_split(iris_dataset['data'], iris_dataset['target'], random_state=0)
форма массива X_train: (112, 4)
форма массива y_train: (112,)
форма массива X_test: (38, 4)
форма массива y_test: (38,)
```

Качественный анализ данных: матрица диаграмм рассеяния

Для пары признаков – на плоскости (scatter plot). Если признаков больше, то строятся матрицы диаграммы (scatterplot matrix, pair plots) для всех возможных пар (в pandas функция scatter_matrix)

```
# матрица диаграмм рассеяния
# создаем dataframe из данных в массиве X_train
# маркируем столбцы, используя строки в iris_dataset.feature_names
# создаем матрицу рассеяния из dataframe, цвет точек атоматом, По диагонали - гистограммы каждого признака
import pandas as pd
from pandas import plotting
%matplotlib inline
iris_dataframe = pd.DataFrame(X_train, columns=iris_dataset.feature_names)
grr = plotting.scatter_matrix(iris_dataframe, c=y_train, figsize=(15, 15), marker='o',
hist_kwds={'bins': 20}, s=60, alpha=.8)
```

2. Задача классификации. OneR (one rule) алгоритм

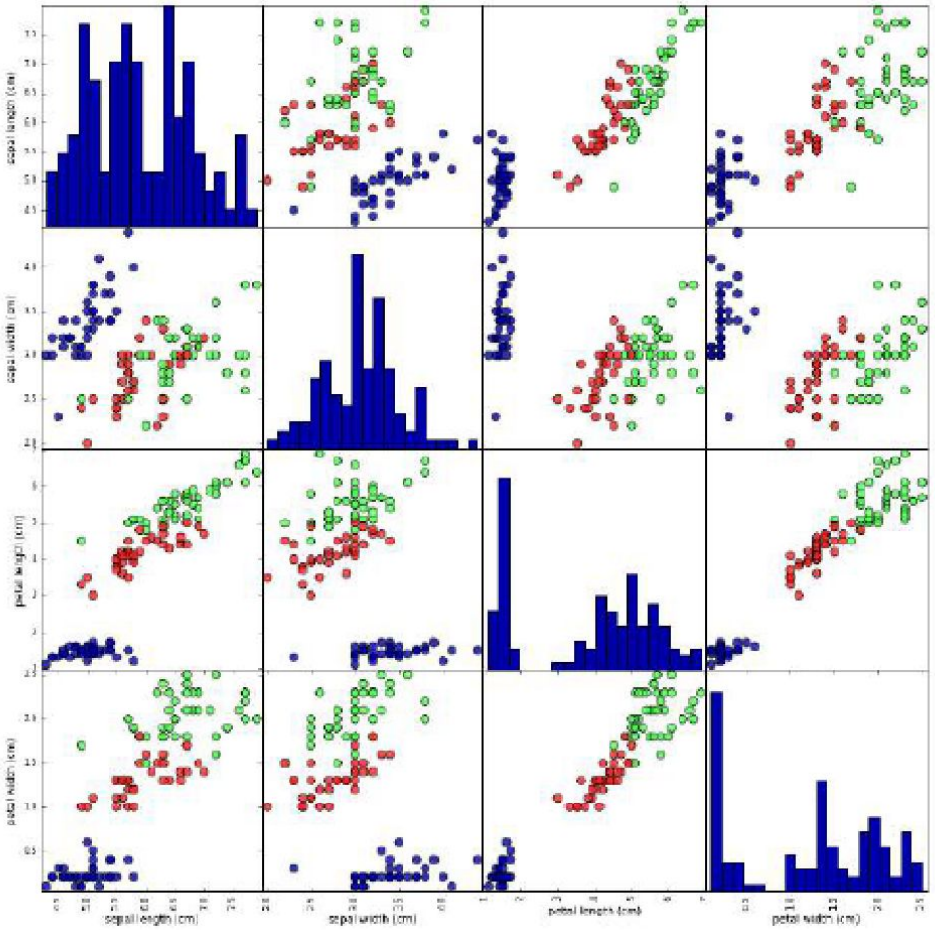

Задание3: сделать вывод по матрицам рассеяния

Признаки позволяют относительно хорошо разделить три класса
Модель машинного обучения, вероятно,
сможет научиться разделять их.

2. Задача классификации. OneR (one rule) алгоритм

Для решения задачи классификации с учителем (построения классификатора) используем метод k-means (ближайших соседей)

Библиотека scikit-learn, где модели машинного обучения реализованы в собственных классах, называемых Estimator.

Алгоритм классификации на основе метода k ближайших соседей реализован в классификаторе KNeighborsClassifier модуля neighbors.

Задание4: формализовать использование метода k-means для решения рассматриваемой задачи классификации, пояснить особенности его использования

- Тренировка выполняется на обучающем наборе данных;
- В ходе классификации вводимой точки данных алгоритм находит точку в обучающем наборе, которая ближе всего находится к вводу;
- присвоение метки (классификация, отнесение к классу) введенной новой точки.

k означает: вместо того, чтобы использовать лишь «ближайшего соседа» к вводу, рассматривается любое фиксированное число k>1 соседей (например, три, или пять, или более соседей).

Т.о. классификация (прогноз, predict) для вводимой точки данных выполняется для того класса, которому принадлежит большинство из k соседей.

2. Задача классификации. OneR (one rule) алгоритм

Создать объект-экземпляр класса, задав параметры модели: количество соседей k (установим k = 1)

```
# Создать объект-экземпляр класса, задав параметры модели: количество соседей k= 1
from sklearn.neighbors import KNeighborsClassifier
knn = KNeighborsClassifier(n_neighbors=1)        # Объект knn включает алгоритм, который будет использоваться для
                                                 # построения модели на обучающих данных, а также алгоритм,
                                                 # который сгенерирует прогнозы для новых точек данных
```

Для обучения вызывать метод fit объекта knn, который принимает в качестве аргументов массивы NumPy: X_train и y_train, содержащие обучающие и тестовые данные

```
knn.fit(X_train, y_train)
KNeighborsClassifier(algorithm='auto', leaf_size=30, metric='minkowski', metric_params=None, n_jobs=1, n_neighbors=1, p=2,
weights='uniform')
```

Почти все параметры классификатора KNeighborsClassifier имеют значения по умолчанию (параметр n_neighbor=1 задавали).

Большинство классификаторов в scikit-learn имеют массу параметров, но большая часть из них связана с оптимизацией скорости вычислений или предназначена для особых случаев использования.

Не стоит подробно останавливаться на всех параметрах, выводимых классификатором