

# ch01 머신러닝 시작하기

- Machine Learning with sklearn @ DJ,Lim
- update : 2022/05

## 학습 내용

- 머신러닝을 학습하기 위한 기본 라이브러리 이해 및 실습
- 머신러닝 모델 만들어보기

## 01 기본 개념 이해하기

- 샘플(sample) or 데이터 포인트(data point) : 하나의 개체 혹은 행을 말한다.
- 특성 or 속성(feature) : 샘플의 속성, 즉 열을 가르킨다.

## 02 기본 라이브러리 이해하기

### scikit-learn(사이킷 런)

- 오픈 소스입니다.
- 매우 인기 높고 독보적인 파이썬 머신러닝 라이브러리입니다.
- url : <http://scikit-learn.org/stable/documentation>
- 사용자 가이드 : [https://scikit-learn.org/stable/user\\_guide.html](https://scikit-learn.org/stable/user_guide.html)

### Numpy

- 파이썬으로 과학 계산을 하기 위한 꼭 필요한 패키지
- 다차원 배열을 위한 기능
- 선형 대수 연산 기능
- 푸리에 변환 같은 고수준 수학 함수와 유사 난수 생성기 기능
- python의 데이터 처리에 비해 매우 빠른 속도를 보여주어 pandas, 딥러닝 모델의 기본 자료형으로 사용
- url : <https://www.numpy.org/>

### SciPy

- SciPy(<https://www.scipy.org/scipylib>) 과학 계산용 함수를 모아놓은 파이썬 패키지.
- 고성능 선형대수 기능, 함수 최적화, 신호 처리, 특수한 수학 함수와 통계 분포 등
- 희소 행렬 기능

### Matplotlib

- 파이썬 대표적인 과학 계산용 그래프 라이브러리

### Pandas

- 데이터 처리와 분석을 위한 파이썬 라이브러리
- url : <https://pandas.pydata.org/>
- R의 data.frame을 본떠 설계한 **Dataframe**이라는 데이터 구조를 기반으로 만들어짐.
- SQL처럼 테이블 쿼리나 조인을 수행 가능함.

- xlsx, csv등의 다양한 파일과 데이터베이스에서 데이터를 읽어들일 수 있음.
- [https://pandas.pydata.org/pandas-docs/stable/getting\\_started/10min.html](https://pandas.pydata.org/pandas-docs/stable/getting_started/10min.html)

## mglearn

- 파이썬 라이브러리를 활용한 머신러닝 저자가 작성한 라이브러리
- 기본 머신러닝 내용 설명을 위한 그래프(knn 알고리즘 설명 등)

```
In [ ]: from IPython.display import display, Image
```

## 03 라이브러리 소프트웨어 버전 확인

라이브러리이름.\_\_version\_\_  
라이브러리이름.version

```
In [ ]: import sys  
print("파이썬 버전 :", sys.version)
```

파이썬 버전 : 3.8.5 (default, Sep 4 2020, 02:22:02)  
[Clang 10.0.0 ]

```
In [ ]: import pandas as pd  
print("판다스 버전 :", pd.__version__)
```

판다스 버전 : 1.1.3

```
In [ ]: import matplotlib  
import numpy as np  
import scipy as sp
```

## 직접 해보기1

- matplotlib, numpy, seaborn, scipy의 각각의 버전을 확인해 보자.
- 추가 라이브러리를 설치할 때 명령
  - pip install [라이브러리명]

## 04 머신러닝 모델을 위한 iris 데이터를 준비

### 데이터 : 붓꽃

- 종류 : setosa, versicolor, virginica
- 데이터 내용 : 붓꽃의 꽃잎과 꽃받침
- 우리가 해결하려고 하는 문제 : 데이터를 주고 붓꽃의 종류 예측하기

```
In [ ]: display(Image(filename='img/iris_setosa01.png'))
```



## 용어 이해하기

- **클래스(class)** : 출력될 수 있는 값들. 봇꽃의 종류들, 봇꽃의 종류는 세 클래스 중 하나에 속한다.
  - (구글 용어집) One of a set of enumerated target values for a label.
  - 레이블에 대한 열거된 목표값의 집합 중의 하나.
- **레이블(label)** : 데이터 포인트 하나(봇꽃 하나)에 대한 기대 출력. 특정 데이터 포인트에 대한 출력
  - (구글 용어집) 지도학습에서 예에 대한 답변 또는 결과 부분

## 데이터 준비

- scikit-learn에서 제공하는 기본 데이터 자료형을 이용한다.
- load\_iris가 반환한 iris 객체는 파이썬의 딕셔너리(Dictionary)와 유사한 Bunch 클래스의 객체

```
In [ ]: from sklearn.datasets import load_iris
iris = load_iris()
iris
```

```
Out[ ]: {'data': array([[5.1, 3.5, 1.4, 0.2],
       [4.9, 3. , 1.4, 0.2],
       [4.7, 3.2, 1.3, 0.2],
       [4.6, 3.1, 1.5, 0.2],
       [5. , 3.6, 1.4, 0.2],
       [5.4, 3.9, 1.7, 0.4],
       [4.6, 3.4, 1.4, 0.3],
       [5. , 3.4, 1.5, 0.2],
       [4.4, 2.9, 1.4, 0.2],
       [4.9, 3.1, 1.5, 0.1],
       [5.4, 3.7, 1.5, 0.2],
       [4.8, 3.4, 1.6, 0.2],
       [4.8, 3. , 1.4, 0.1],
       [4.3, 3. , 1.1, 0.1],
       [5.8, 4. , 1.2, 0.2],
       [5.7, 4.4, 1.5, 0.4],
       [5.4, 3.9, 1.3, 0.4],
       [5.1, 3.5, 1.4, 0.3],
       [5.7, 3.8, 1.7, 0.3],
       [5.1, 3.8, 1.5, 0.3],
       [5.4, 3.4, 1.7, 0.2],
       [5.1, 3.7, 1.5, 0.4],
       [4.6, 3.6, 1. , 0.2],
       [5.1, 3.3, 1.7, 0.5],
       [4.8, 3.4, 1.9, 0.2],
       [5. , 3. , 1.6, 0.2],
       [5. , 3.4, 1.6, 0.4],
```

[5.2, 3.5, 1.5, 0.2],  
[5.2, 3.4, 1.4, 0.2],  
[4.7, 3.2, 1.6, 0.2],  
[4.8, 3.1, 1.6, 0.2],  
[5.4, 3.4, 1.5, 0.4],  
[5.2, 4.1, 1.5, 0.1],  
[5.5, 4.2, 1.4, 0.2],  
[4.9, 3.1, 1.5, 0.2],  
[5., 3.2, 1.2, 0.2],  
[5.5, 3.5, 1.3, 0.2],  
[4.9, 3.6, 1.4, 0.1],  
[4.4, 3., 1.3, 0.2],  
[5.1, 3.4, 1.5, 0.2],  
[5., 3.5, 1.3, 0.3],  
[4.5, 2.3, 1.3, 0.3],  
[4.4, 3.2, 1.3, 0.2],  
[5., 3.5, 1.6, 0.6],  
[5.1, 3.8, 1.9, 0.4],  
[4.8, 3., 1.4, 0.3],  
[5.1, 3.8, 1.6, 0.2],  
[4.6, 3.2, 1.4, 0.2],  
[5.3, 3.7, 1.5, 0.2],  
[5., 3.3, 1.4, 0.2],  
[7., 3.2, 4.7, 1.4],  
[6.4, 3.2, 4.5, 1.5],  
[6.9, 3.1, 4.9, 1.5],  
[5.5, 2.3, 4., 1.3],  
[6.5, 2.8, 4.6, 1.5],  
[5.7, 2.8, 4.5, 1.3],  
[6.3, 3.3, 4.7, 1.6],  
[4.9, 2.4, 3.3, 1.],  
[6.6, 2.9, 4.6, 1.3],  
[5.2, 2.7, 3.9, 1.4],  
[5., 2., 3.5, 1.],  
[5.9, 3., 4.2, 1.5],  
[6., 2.2, 4., 1.],  
[6.1, 2.9, 4.7, 1.4],  
[5.6, 2.9, 3.6, 1.3],  
[6.7, 3.1, 4.4, 1.4],  
[5.6, 3., 4.5, 1.5],  
[5.8, 2.7, 4.1, 1.],  
[6.2, 2.2, 4.5, 1.5],  
[5.6, 2.5, 3.9, 1.1],  
[5.9, 3.2, 4.8, 1.8],  
[6.1, 2.8, 4., 1.3],  
[6.3, 2.5, 4.9, 1.5],  
[6.1, 2.8, 4.7, 1.2],  
[6.4, 2.9, 4.3, 1.3],  
[6.6, 3., 4.4, 1.4],  
[6.8, 2.8, 4.8, 1.4],  
[6.7, 3., 5., 1.7],  
[6., 2.9, 4.5, 1.5],  
[5.7, 2.6, 3.5, 1.],  
[5.5, 2.4, 3.8, 1.1],  
[5.5, 2.4, 3.7, 1.],  
[5.8, 2.7, 3.9, 1.2],  
[6., 2.7, 5.1, 1.6],  
[5.4, 3., 4.5, 1.5],  
[6., 3.4, 4.5, 1.6],  
[6.7, 3.1, 4.7, 1.5],  
[6.3, 2.3, 4.4, 1.3],  
[5.6, 3., 4.1, 1.3],  
[5.5, 2.5, 4., 1.3],  
[5.5, 2.6, 4.4, 1.2],  
[6.1, 3., 4.6, 1.4],  
[5.8, 2.6, 4., 1.2],  
[5., 2.3, 3.3, 1.],  
[5.6, 2.7, 4.2, 1.3],  
[5.7, 3., 4.2, 1.2],



```

\> - class:\n          - Iris-Setosa\n          - Iris-Vers
icolour\n          - Iris-Virginica\n          \n      :Summary Stat
istics:\n\n      ======\n      Min   Max   Mean   SD   Class Correlation\n      ======\n      ======\n      \n      sepal length:   4.3   7.9   5.84   0.83   0.\n5726\n      sepal width:   2.0   4.4   3.05   0.43   -0.4194\n      petal length:\n      1.0   6.9   3.76   1.76   0.9490 (high!)\n      petal width:   0.1   2.5   1.20\n      0.76   0.9565 (high!)\n      ======\n      ======\n      :Missing Attribute Values: None\n      :Class Distribution: 3\n      3.3% for each of 3 classes.\n      :Creator: R.A. Fisher\n      :Donor: Michael Ma\n      rshall (MARSHALL%PLU@io.arc.nasa.gov)\n      :Date: July, 1988\n\nThe famous Iri\n      s database, first used by Sir R.A. Fisher. The dataset is taken\nfrom Fisher\n      's paper. Note that it\n      's the same as in R, but not as in the UCI\nMachine Le\n      arning Repository, which has two wrong data points.\n\nThis is perhaps the bes\n      t known database to be found in the\npattern recognition literature. Fisher\n      's paper is a classic in the field and\nis referenced frequently to this day.\n(See Duda & Hart, for example.) The\n      ndata set contains 3 classes of 50 instan\n      ces each, where each class refers to a\n      type of iris plant. One class is line\n      arly separable from the other 2; the\n      nlatter are NOT linearly separable from e\n      ach other.\n\n.. topic:: References\n      - Fisher, R.A. "The use of multiple\n      measurements in taxonomic problems"\n      Annual Eugenics, 7, Part II, 179-188\n      (1936); also in "Contributions to\n      Mathematical Statistics" (John Wiley,\n      NY, 1950).\n      - Duda, R.O., & Hart, P.E. (1973) Pattern Classification and Sc\n      ene Analysis.\n      (Q327.D83) John Wiley & Sons. ISBN 0-471-22361-1. See pa\n      ge 218.\n      - Dasarathy, B.V. (1980) "Nosing Around the Neighborhood: A New Sy\n      stem\n      Structure and Classification Rule for Recognition in Partially Exp\n      osed\n      Environments". IEEE Transactions on Pattern Analysis and Machine\n      Intelligence, Vol. PAMI-2, No. 1, 67-71.\n      - Gates, G.W. (1972) "The Reduced\n      Nearest Neighbor Rule". IEEE Transactions\n      on Information Theory, May 19\n      72, 431-433.\n      - See also: 1988 MLC Proceedings, 54-64. Cheeseman et al's A\n      UTOCLASS II\n      conceptual clustering system finds 3 classes in the data.\n\n- Many, many more ...',
'feature_names': ['sepal length (cm)',\n    'sepal width (cm)',\n    'petal length (cm)',\n    'petal width (cm)'],
'filename': '/Users/toto/Documents/anaconda3/lib/python3.8/site-packages/skle\narn/datasets/data/iris.csv'}

```

[5.8 4. 1.2 0.2]  
[5.7 4.4 1.5 0.4]  
[5.4 3.9 1.3 0.4]  
[5.1 3.5 1.4 0.3]  
[5.7 3.8 1.7 0.3]  
[5.1 3.8 1.5 0.3]  
[5.4 3.4 1.7 0.2]  
[5.1 3.7 1.5 0.4]  
[4.6 3.6 1. 0.2]  
[5.1 3.3 1.7 0.5]  
[4.8 3.4 1.9 0.2]  
[5. 3. 1.6 0.2]  
[5. 3.4 1.6 0.4]  
[5.2 3.5 1.5 0.2]  
[5.2 3.4 1.4 0.2]  
[4.7 3.2 1.6 0.2]  
[4.8 3.1 1.6 0.2]  
[5.4 3.4 1.5 0.4]  
[5.2 4.1 1.5 0.1]  
[5.5 4.2 1.4 0.2]  
[4.9 3.1 1.5 0.2]  
[5. 3.2 1.2 0.2]  
[5.5 3.5 1.3 0.2]  
[4.9 3.6 1.4 0.1]  
[4.4 3. 1.3 0.2]  
[5.1 3.4 1.5 0.2]  
[5. 3.5 1.3 0.3]  
[4.5 2.3 1.3 0.3]  
[4.4 3.2 1.3 0.2]  
[5. 3.5 1.6 0.6]  
[5.1 3.8 1.9 0.4]  
[4.8 3. 1.4 0.3]  
[5.1 3.8 1.6 0.2]  
[4.6 3.2 1.4 0.2]  
[5.3 3.7 1.5 0.2]  
[5. 3.3 1.4 0.2]  
[7. 3.2 4.7 1.4]  
[6.4 3.2 4.5 1.5]  
[6.9 3.1 4.9 1.5]  
[5.5 2.3 4. 1.3]  
[6.5 2.8 4.6 1.5]  
[5.7 2.8 4.5 1.3]  
[6.3 3.3 4.7 1.6]  
[4.9 2.4 3.3 1. ]  
[6.6 2.9 4.6 1.3]  
[5.2 2.7 3.9 1.4]  
[5. 2. 3.5 1. ]  
[5.9 3. 4.2 1.5]  
[6. 2.2 4. 1. ]  
[6.1 2.9 4.7 1.4]  
[5.6 2.9 3.6 1.3]  
[6.7 3.1 4.4 1.4]  
[5.6 3. 4.5 1.5]  
[5.8 2.7 4.1 1. ]  
[6.2 2.2 4.5 1.5]  
[5.6 2.5 3.9 1.1]  
[5.9 3.2 4.8 1.8]  
[6.1 2.8 4. 1.3]  
[6.3 2.5 4.9 1.5]  
[6.1 2.8 4.7 1.2]  
[6.4 2.9 4.3 1.3]  
[6.6 3. 4.4 1.4]  
[6.8 2.8 4.8 1.4]  
[6.7 3. 5. 1.7]  
[6. 2.9 4.5 1.5]  
[5.7 2.6 3.5 1. ]  
[5.5 2.4 3.8 1.1]  
[5.5 2.4 3.7 1. ]  
[5.8 2.7 3.9 1.2]

```
[6.  2.7 5.1 1.6]
[5.4 3.  4.5 1.5]
[6.  3.4 4.5 1.6]
[6.7 3.1 4.7 1.5]
[6.3 2.3 4.4 1.3]
[5.6 3.  4.1 1.3]
[5.5 2.5 4.  1.3]
[5.5 2.6 4.4 1.2]
[6.1 3.  4.6 1.4]
[5.8 2.6 4.  1.2]
[5.  2.3 3.3 1. ]
[5.6 2.7 4.2 1.3]
[5.7 3.  4.2 1.2]
[5.7 2.9 4.2 1.3]
[6.2 2.9 4.3 1.3]
[5.1 2.5 3.  1.1]
[5.7 2.8 4.1 1.3]
[6.3 3.3 6.  2.5]
[5.8 2.7 5.1 1.9]
[7.1 3.  5.9 2.1]
[6.3 2.9 5.6 1.8]
[6.5 3.  5.8 2.2]
[7.6 3.  6.6 2.1]
[4.9 2.5 4.5 1.7]
[7.3 2.9 6.3 1.8]
[6.7 2.5 5.8 1.8]
[7.2 3.6 6.1 2.5]
[6.5 3.2 5.1 2. ]
[6.4 2.7 5.3 1.9]
[6.8 3.  5.5 2.1]
[5.7 2.5 5.  2. ]
[5.8 2.8 5.1 2.4]
[6.4 3.2 5.3 2.3]
[6.5 3.  5.5 1.8]
[7.7 3.8 6.7 2.2]
[7.7 2.6 6.9 2.3]
[6.  2.2 5.  1.5]
[6.9 3.2 5.7 2.3]
[5.6 2.8 4.9 2. ]
[7.7 2.8 6.7 2. ]
[6.3 2.7 4.9 1.8]
[6.7 3.3 5.7 2.1]
[7.2 3.2 6.  1.8]
[6.2 2.8 4.8 1.8]
[6.1 3.  4.9 1.8]
[6.4 2.8 5.6 2.1]
[7.2 3.  5.8 1.6]
[7.4 2.8 6.1 1.9]
[7.9 3.8 6.4 2. ]
[6.4 2.8 5.6 2.2]
[6.3 2.8 5.1 1.5]
[6.1 2.6 5.6 1.4]
[7.7 3.  6.1 2.3]
[6.3 3.4 5.6 2.4]
[6.4 3.1 5.5 1.8]
[6.  3.  4.8 1.8]
[6.9 3.1 5.4 2.1]
[6.7 3.1 5.6 2.4]
[6.9 3.1 5.1 2.3]
[5.8 2.7 5.1 1.9]
[6.8 3.2 5.9 2.3]
[6.7 3.3 5.7 2.5]
[6.7 3.  5.2 2.3]
[6.3 2.5 5.  1.9]
[6.5 3.  5.2 2. ]
[6.2 3.4 5.4 2.3]
[5.9 3.  5.1 1.8]]
```

In [ ]: # iris 디아터 셋의 설명 확인

```

iris[ 'DESCR' ]

Out[ ]: ''' _iris_dataset:\n\nIris plants dataset\n-----\n**Data Set
Characteristics:**\n\n :Number of Instances: 150 (50 in each of three classes)\n :Number of Attributes: 4 numeric, predictive attributes and the class
\n :Attribute Information:\n      - sepal length in cm\n      - sepal w
idth in cm\n      - petal length in cm\n      - petal width in cm\n
- class:\n          - Iris-Setosa\n          - Iris-Versicolour\n
- Iris-Virginica\n :Summary Statistics:\n\n =====
===== ===== ===== ===== ===== ===== ===== ===== ===== ===== =====
Min Ma
x  Mean   SD  Class Correlation\n  ===== ===== ===== ===== ===== ===== ===== ===== ===== =====
sepal length:  4.3  7.9  5.84  0.83  0.7826\n
sepal width:  2.0  4.4  3.05  0.43  -0.4194\n
petal length: 1.0  6.9
3.76  1.76  0.9490 (high!)\n
petal width:  0.1  2.5  1.20  0.76
0.9565 (high!)\n
==== ===== ===== ===== ===== ===== ===== ===== ===== ===== =====
==\n\n :Missing Attribute Values: None\n :Class Distribution: 33.3% for
each of 3 classes.\n :Creator: R.A. Fisher\n :Donor: Michael Marshall (M
ARSHALL%PLU@io.arc.nasa.gov)\n :Date: July, 1988\n\nThe famous Iris database,
first used by Sir R.A. Fisher. The dataset is taken\nfrom Fisher's paper.
Note that it's the same as in R, but not as in the UCI\nMachine Learning Repository,
which has two wrong data points.\n\nThis is perhaps the best known database
to be found in the\npattern recognition literature. Fisher's paper is
a classic in the field and\nis referenced frequently to this day. (See Duda &
Hart, for example.) The\ndataset contains 3 classes of 50 instances each, wh
ere each class refers to a\ntype of iris plant. One class is linearly separable
from the other 2; the\nlatter are NOT linearly separable from each other.\n
\n.. topic:: References\n\n - Fisher, R.A. "The use of multiple measurements
in taxonomic problems"\n     Annual Eugenics, 7, Part II, 179-188 (1936); also
in "Contributions to\n     Mathematical Statistics" (John Wiley, NY, 1950).\n
- Duda, R.O., & Hart, P.E. (1973) Pattern Classification and Scene Analysis.\n
(Q327.D83) John Wiley & Sons. ISBN 0-471-22361-1. See page 218.\n
- Dasarathy, B.V. (1980) "Nosing Around the Neighborhood: A New System\n     Structure
and Classification Rule for Recognition in Partially Exposed\n     Environment
s". IEEE Transactions on Pattern Analysis and Machine\n     Intelligence, Vo
l. PAMI-2, No. 1, 67-71.\n - Gates, G.W. (1972) "The Reduced Nearest Neighbor
Rule". IEEE Transactions\n     on Information Theory, May 1972, 431-433.\n
- See also: 1988 MLC Proceedings, 54-64. Cheeseman et al's AUTOCLASS II\n
conceptual clustering system finds 3 classes in the data.\n - Many, many mor
e ...

```

```

In [ ]: print( iris['data'].shape )    # iris 데이터의 'data'의 값이 가지는 행열 확인
print( iris['feature_names'] ) # iris 데이터 셋의 피처이름 확인
print( iris['data'][:5] )       # 5개의 데이터 확인
print( iris['target_names'][:5] )
print( iris['target'][:5] )

(150, 4)
['sepal length (cm)', 'sepal width (cm)', 'petal length (cm)', 'petal width (c
m)']
[[5.1 3.5 1.4 0.2]
 [4.9 3. 1.4 0.2]
 [4.7 3.2 1.3 0.2]
 [4.6 3.1 1.5 0.2]
 [5. 3.6 1.4 0.2]]
['setosa' 'versicolor' 'virginica']
[0 0 0 0 0]

```

## 데이터의 크기 확인

- 데이터의 사이즈 확인 : 데이터.shape
- 데이터의 자료형 확인 : type(데이터자료형)

```

In [ ]: print(iris['target'].shape)  # 타겟
print(iris['data'].shape)
print(type(iris['target']), type(iris['data']))

```

(150,)

```
(150, 4)
<class 'numpy.ndarray'> <class 'numpy.ndarray'>
```

## 05 데이터를 훈련 데이터와 테스트 데이터로 나누기

- 우리는 모델을 만들고 모델의 성능 측정을 위해 학습용 데이터 셋과 테스트용 데이터 셋으로 나누어준다.
- 학습용 데이터 : 모델 선택 후, 실제 학습에 사용하는 데이터 셋(실제 문제지의 문제)
- 테스트 데이터 : 학습 후, 실제 잘 동작하는지 확인하기 위한 데이터 (모의고사시험)
- 내용 : 모델을 새 데이터에 적용하기 전에 우리가 만든 모델이 잘 동작하는지 확인하기 위해 테스트 데이터를 활용하여 평가한다.

훈련 데이터 셋(training set) : 머신러닝 모델을 만들 때 쓰는 데이터 셋

테스트 데이터 셋(test set) : 모델이 얼마나 잘 작동하는지 쓰는 데이터 셋

- 테스트 데이터 셋을 다른 말로 홀드아웃(hold-out data)이라 한다.
  - 홀드 아웃 데이터 : 훈련중에 의도적으로 사용되지 않은 검증 데이터 세트 및 테스트 데이터 셋. 모델이 일반화 능력을 평가하는데 도움이 된다.
- scikit-learn은 데이터 셋을 나누주기 위해 train\_test\_split 함수를 이용.
- train\_test\_split 함수는 기본적으로 75% 훈련 세트, 25%의 테스트 세트

```
In [ ]: from sklearn.model_selection import train_test_split

X = iris['data']
y = iris['target']

X_train, X_test, y_train, y_test = train_test_split(X, y, random_state=0)

In [ ]: # 데이터 사이즈
print(X_train.shape)      # 훈련 데이터 셋 사이즈
print(X_test.shape)        # 테스트 데이터 셋 사이즈
print(y_train.shape)       # 훈련 데이터 레이블 사이즈
print(y_test.shape)        # 테스트 데이터 레이블 사이즈

(112, 4)
(38, 4)
(112,)
(38,)
```

## 06. 데이터 살펴보기 - 시각화

- 머신러닝 모델을 만들기 전 머신러닝 없이도 풀 수 있는 문제는 아닌지, 혹은 필요한 정보가 누락이 없는지 확인
- 산점도(SCATTER PLOT)를 이용하여 확인.
  - 한특성을 x축에 놓고 다른 하나는 y축에 놓아 데이터를 점으로 나타내는 그래프
- 2개의 변수만 사용 가능하여 산점도 행렬(scatter matrix)를 사용

```
In [ ]: import seaborn as sns

In [ ]: print(iris['feature_names']) # 붓꽃의 꽃잎과 꽃받침의 feature 이름

['sepal length (cm)', 'sepal width (cm)', 'petal length (cm)', 'petal width (cm)']

In [ ]: iris_df = pd.DataFrame(X_train, columns=iris.feature_names)
iris_df['species'] = y_train
```

```
iris_df['species'] = iris_df['species'].astype('category') # 자료형 변환  
iris_df.head()
```

```
Out[ ]:   sepal length (cm)  sepal width (cm)  petal length (cm)  petal width (cm)  species  
0           5.9             3.0            4.2             1.5            1  
1           5.8             2.6            4.0             1.2            1  
2           6.8             3.0            5.5             2.1            2  
3           4.7             3.2            1.3             0.2            0  
4           6.9             3.1            5.1             2.3            2
```

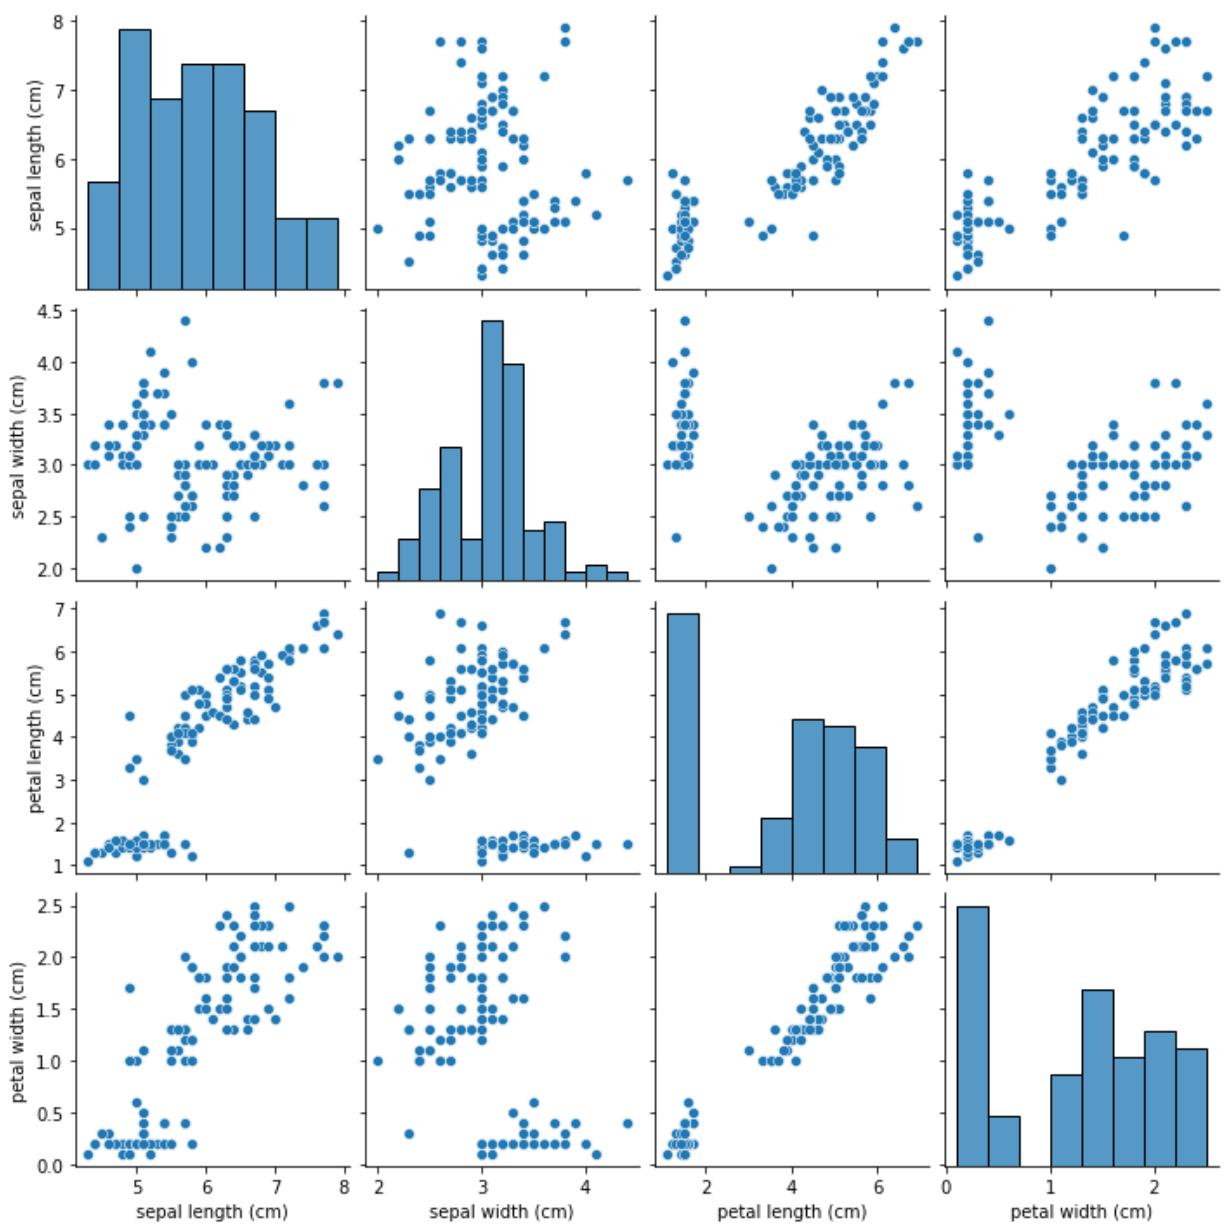
```
In [ ]: print(iris_df.shape)  
print(iris_df.info())
```

```
(112, 5)  
<class 'pandas.core.frame.DataFrame'>  
RangeIndex: 112 entries, 0 to 111  
Data columns (total 5 columns):  
 #   Column           Non-Null Count  Dtype     
---  --  
 0   sepal length (cm)    112 non-null   float64  
 1   sepal width (cm)     112 non-null   float64  
 2   petal length (cm)    112 non-null   float64  
 3   petal width (cm)     112 non-null   float64  
 4   species              112 non-null   category  
dtypes: category(1), float64(4)  
memory usage: 3.8 KB  
None
```

## seaborn를 활용한 산점도 행렬 확인

```
In [ ]: sns.pairplot(iris_df.iloc[ :, 0:4])  # 1~4열 선택
```

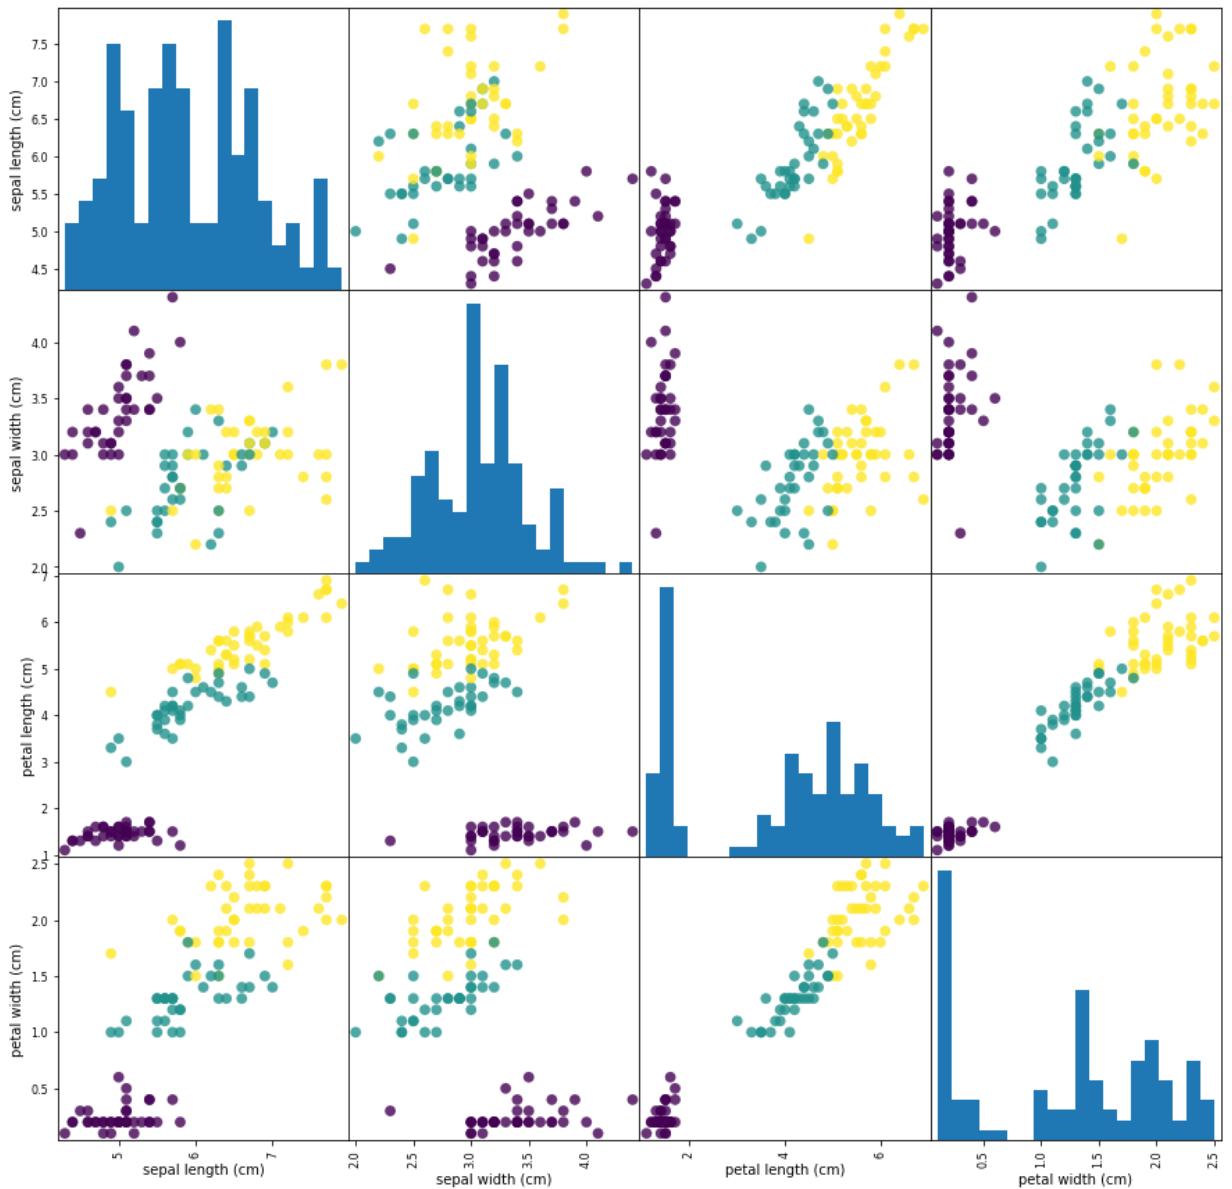
```
Out[ ]: <seaborn.axisgrid.PairGrid at 0x7f850ad86ac0>
```



## Pandas를 이용한 산점도 행렬 확인

```
In [ ]: pd.plotting.scatter_matrix(iris_df, c=y_train,          # 색
                                figsize=(15,15),           # 크기
                                marker='o',                # 표시
                                hist_kwds={'bins':20},      # 막대의 개수
                                s=60,                      # size
                                alpha=0.8 )    # 투명도
```

```
Out[ ]: array([[<AxesSubplot:xlabel='sepal length (cm)', ylabel='sepal length (cm)'>,
   <AxesSubplot:xlabel='sepal width (cm)', ylabel='sepal length (cm)'>,
   <AxesSubplot:xlabel='petal length (cm)', ylabel='sepal length (cm)'>,
   <AxesSubplot:xlabel='petal width (cm)', ylabel='sepal length (cm)'>],
  [<AxesSubplot:xlabel='sepal length (cm)', ylabel='sepal width (cm)'>,
   <AxesSubplot:xlabel='sepal width (cm)', ylabel='sepal width (cm)'>,
   <AxesSubplot:xlabel='petal length (cm)', ylabel='sepal width (cm)'>,
   <AxesSubplot:xlabel='petal width (cm)', ylabel='sepal width (cm)'>],
  [<AxesSubplot:xlabel='sepal length (cm)', ylabel='petal length (cm)'>,
   <AxesSubplot:xlabel='sepal width (cm)', ylabel='petal length (cm)'>,
   <AxesSubplot:xlabel='petal length (cm)', ylabel='petal length (cm)'>,
   <AxesSubplot:xlabel='petal width (cm)', ylabel='petal length (cm)'>],
  [<AxesSubplot:xlabel='sepal length (cm)', ylabel='petal width (cm)'>,
   <AxesSubplot:xlabel='sepal width (cm)', ylabel='petal width (cm)'>,
   <AxesSubplot:xlabel='petal length (cm)', ylabel='petal width (cm)'>,
   <AxesSubplot:xlabel='petal width (cm)', ylabel='petal width (cm)'>]], dtype=object)
```



## 07 첫번째 머신러닝 모델 만들기

- k-최근접 이웃(k-nearest neighbors, k-NN) 알고리즘 :
  - 훈련 데이터에서 새로운 데이터 포인트에 가장 가까운 'k개'의 이웃을 찾는다.
  - 이웃들의 클래스 중 빈도가 가장 높은 클래스를 예측값으로 사용

### 모델 만들기

```
In [ ]: from sklearn.neighbors import KNeighborsClassifier
model = KNeighborsClassifier(n_neighbors=2) # 2개의 이웃을 기준
```

### 모델 학습시키기

```
In [ ]: model.fit(X_train, y_train)
```

```
Out[ ]: KNeighborsClassifier(n_neighbors=2)
```

### 하나의 데이터로 예측해 보기

```
In [ ]: X_new = np.array([[5, 2.9, 1, 0.2]])
```

```
In [ ]: ### 예측시키기
```

```
pred = model.predict(X_new)
pred_targetname = iris['target_names'][pred]
print("예측 : ", pred)
print("예측한 타깃의 이름: ", pred_targetname)
```

```
예측 : [0]
예측한 타깃의 이름: ['setosa']
```

## 08 내가 만든 모델 평가하기

```
In [ ]: y_pred = model.predict(X_test)
print("예측값 :\n", y_pred)
```

```
예측값 :
[2 1 0 2 0 2 0 1 1 1 2 1 1 1 0 1 1 0 0 2 1 0 0 2 0 0 1 1 0 2 1 0 2 2 1 0
2]
```

```
In [ ]: print("테스트 세트의 정확도 : {:.2f}".format(np.mean(y_pred == y_test)))
```

```
테스트 세트의 정확도 : 0.97
```

## 실습해 보기

- titanic 데이터 셋을 활용하여 knn 모델을 구현해 보자

## REF

- sklearn score 매개변수 : [https://scikit-learn.org/stable/modules/model\\_evaluation.html](https://scikit-learn.org/stable/modules/model_evaluation.html)
- 구글 용어집 : <https://developers.google.com/machine-learning/glossary/>

## History

- 내용 확인 및 업데이트 2021/10 v11