Machine Learning

ML Python

ML tutorial python

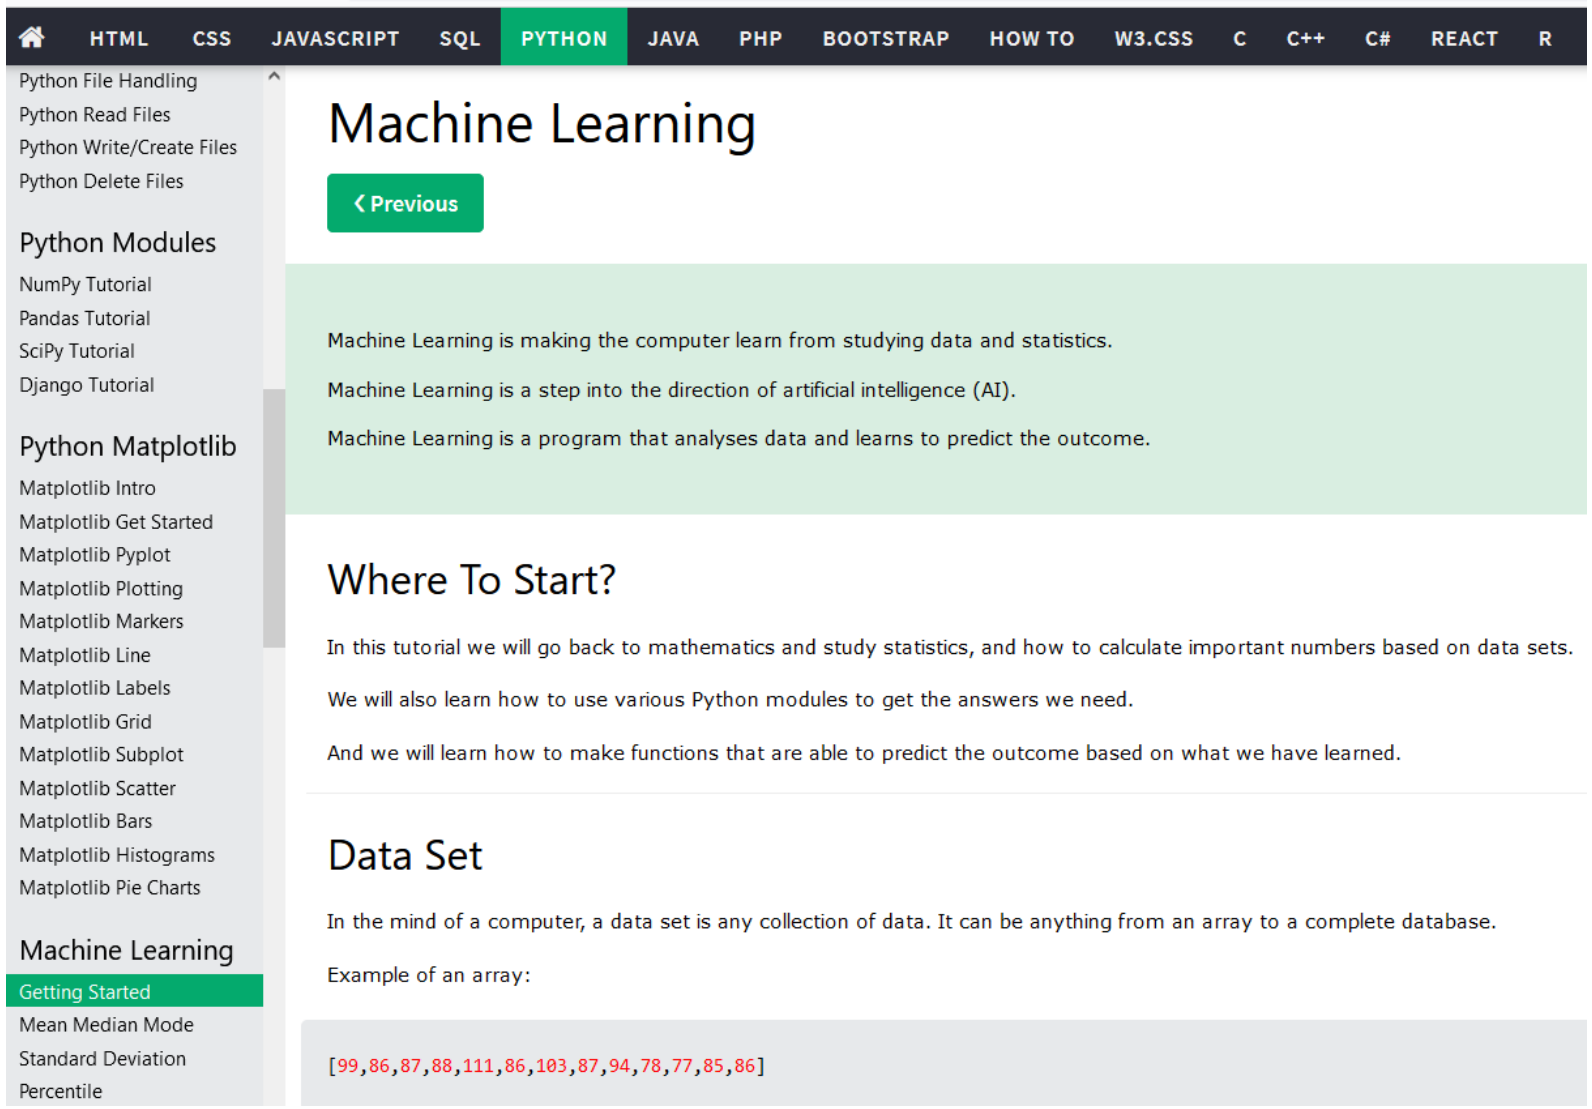

https://www.w3schools.com/python/python_ml_getting_started.asp

Visual Studio Code

wygodny edytor kodu

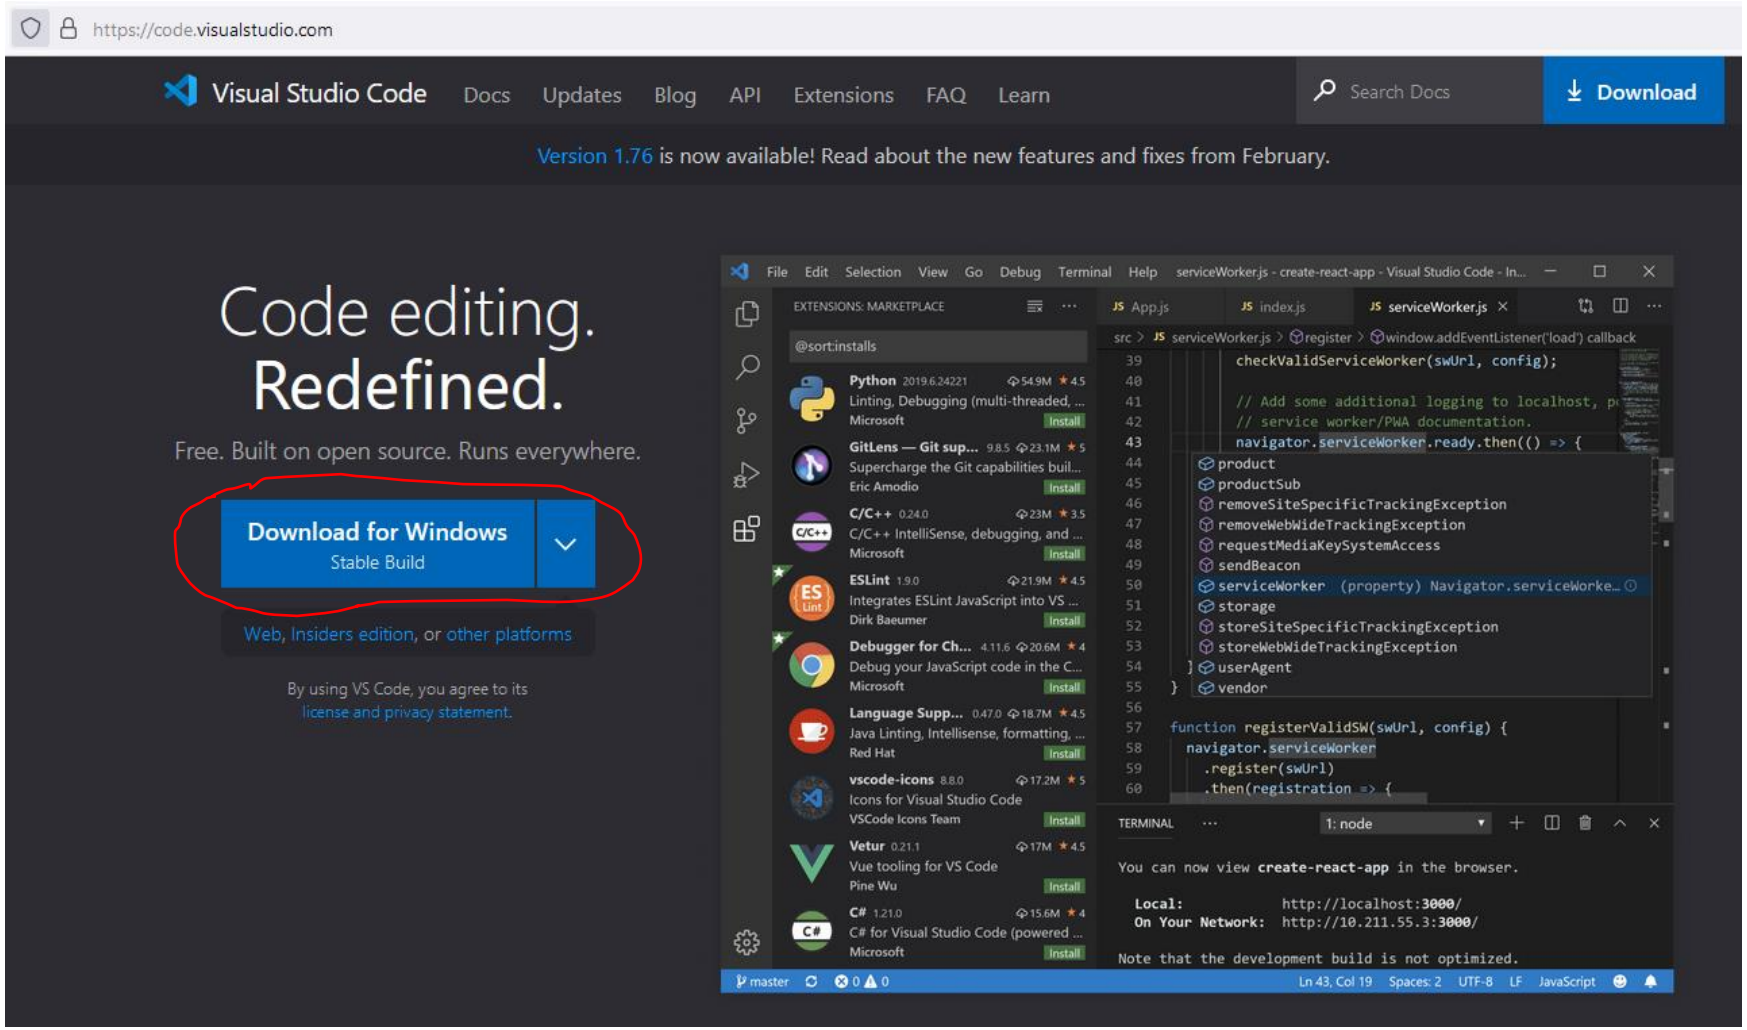

https://code.visualstudio.com/

Visual Studio Code

instalacja Pythona

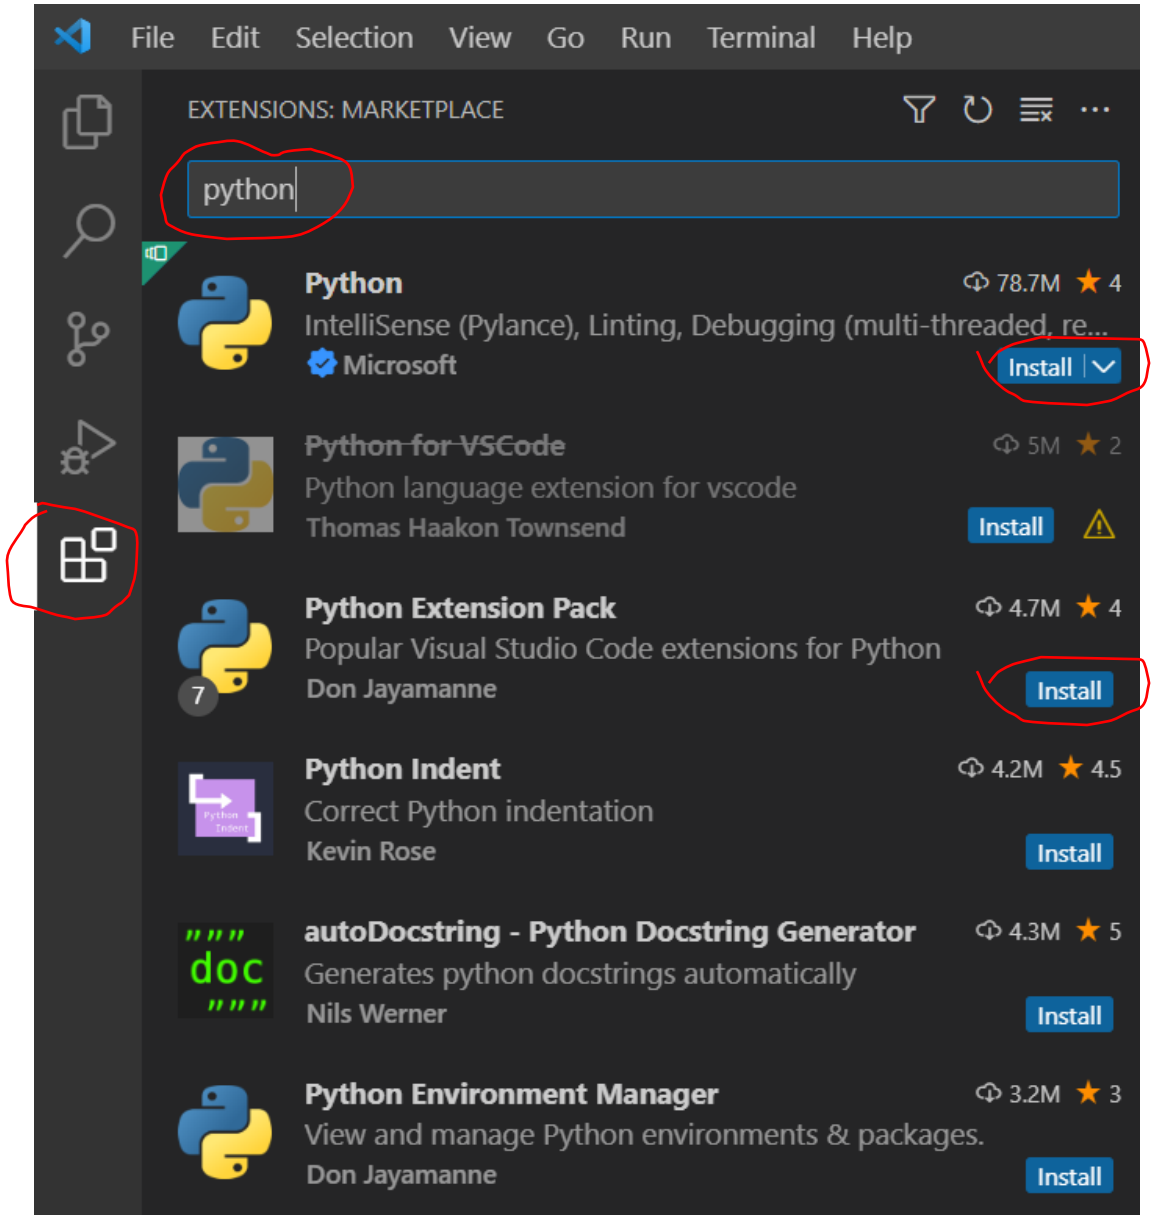

VSC Auto Save

włączenie auto zapisu
w Visual Studio Code

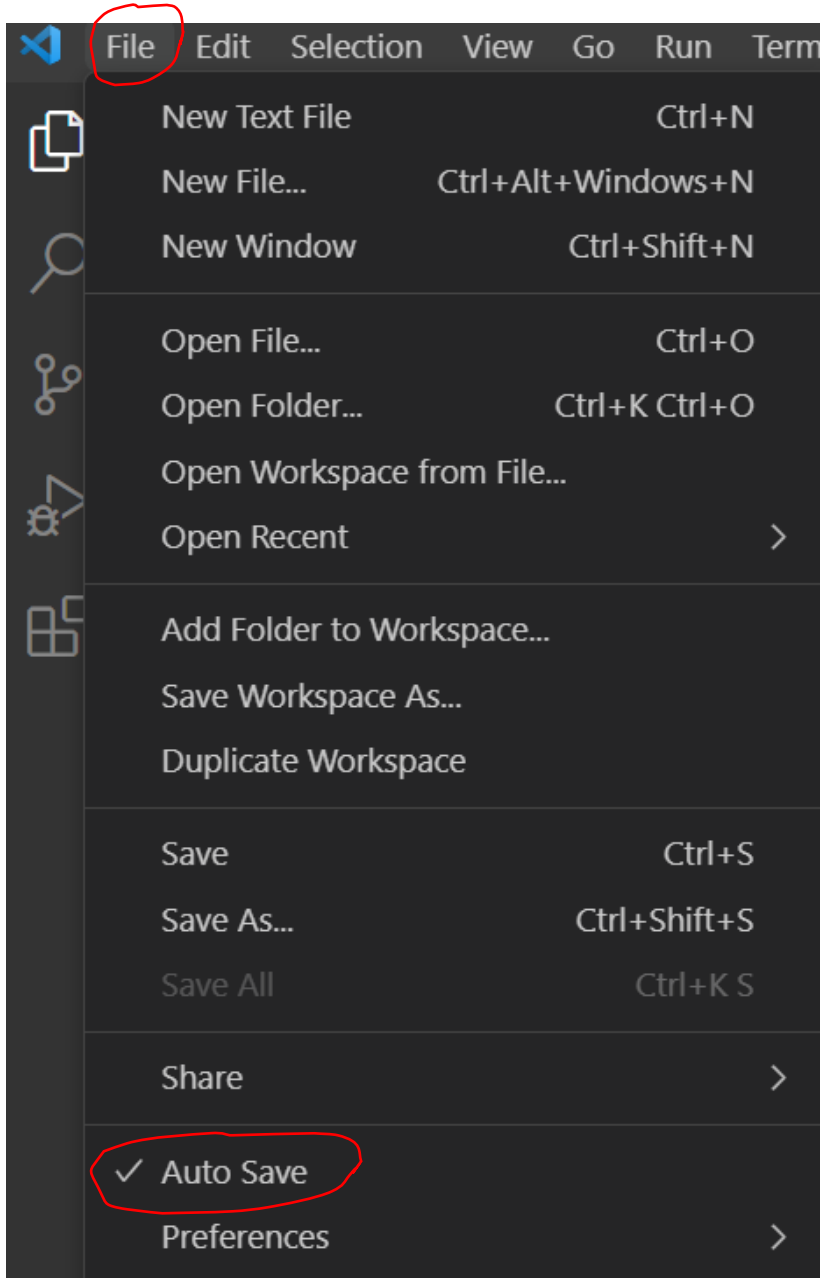

Typy danych

dane liczbowe

Numerical

liczby całkowite

Discrete Data

10 , 20 ,345, 56789
liczba uczniów w klasie
liczba ławek w szkole
liczba szkół w Łodzi

liczby rzeczywiste

Continuous Data

3.14, 2.3456
średnia ocen
temperatura ciała

dane skategoryzowane
(dane dzielą się na kategorie, których nie można porównywać ze sobą)

Categorical

biały, czerwony, niebieski
tak, nie
kobieta, mężczyzna

dane skategoryzowane
(dane dzielą się na kategorie, ale kategorie te są uporządkowane lub uszeregowane w określony sposób, dzięki temu można je porównywać ze sobą)

Ordinal

znajomość języka:
podstawowa, średnia, biegła
stopnie w szkole:
1,2,3,4,5,6

znając typ danych można zastosować odpowiednią technikę do ich analizy

biblioteka NumPy

The fundamental package for scientific computing with Python

biblioteka Pythona do wykonywania szybkich operacji na tablicach (Python nie ma zaimplementowanych tablic)

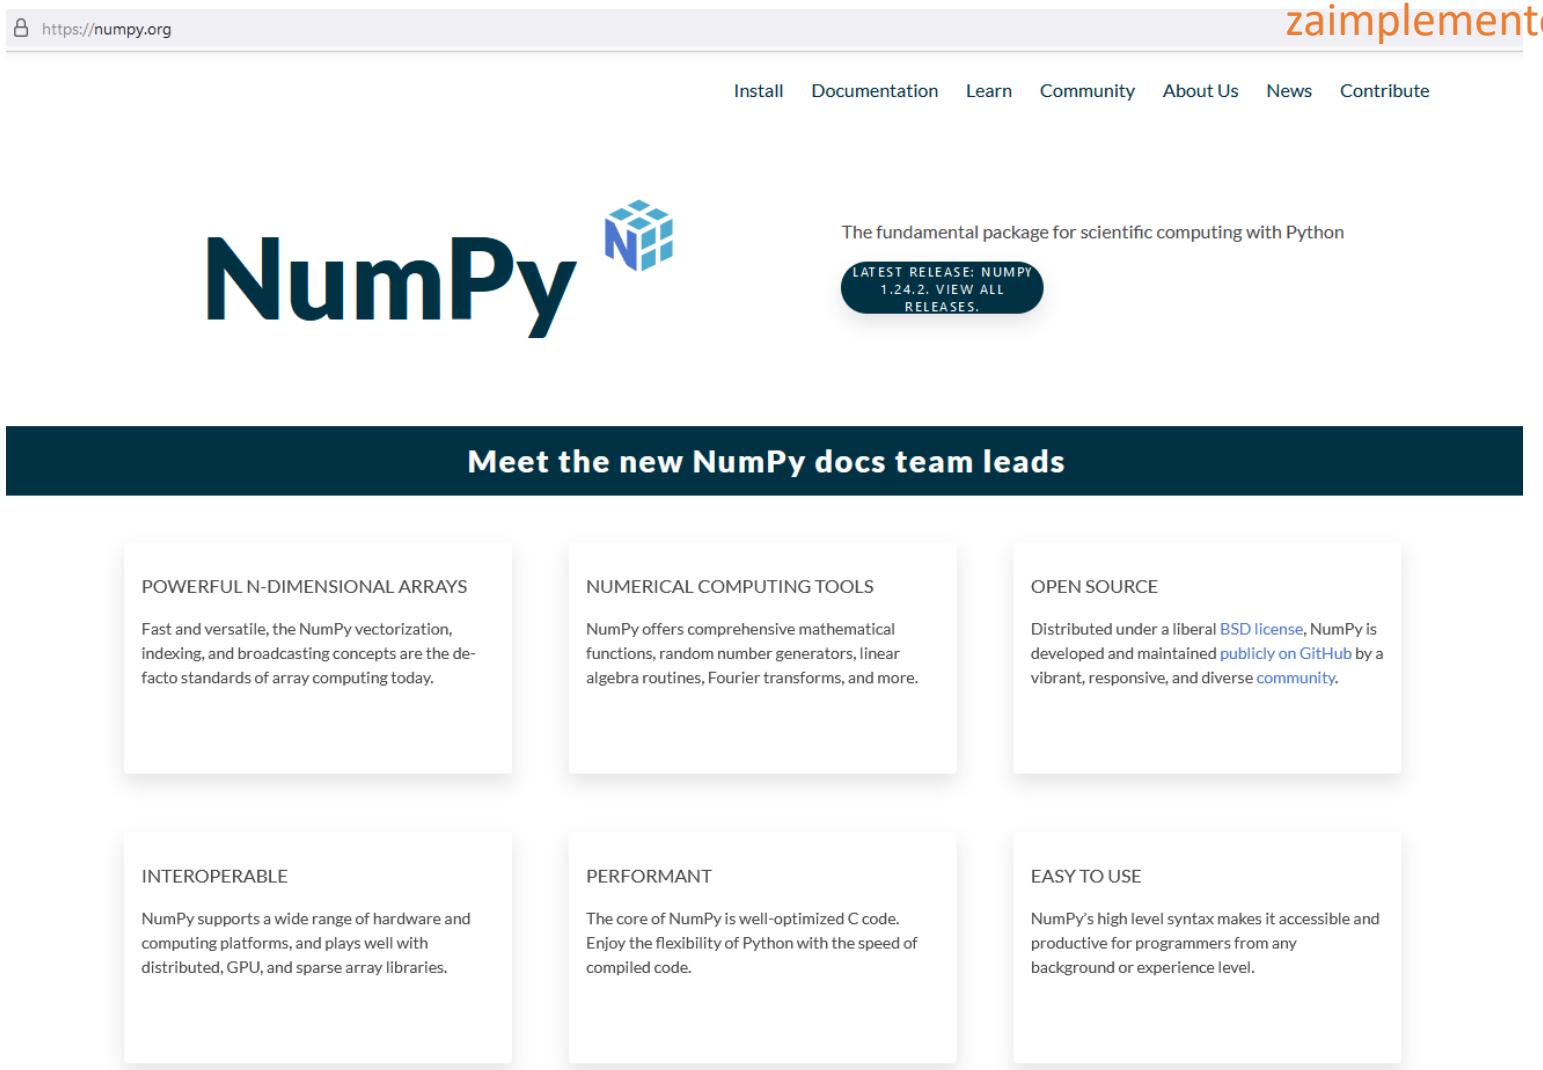

https://numpy.org/

https://analityk.edu.pl/python-numpy/

biblioteka NumPy

instalacja biblioteki NumPy w VSC

```
pip install numpy
```

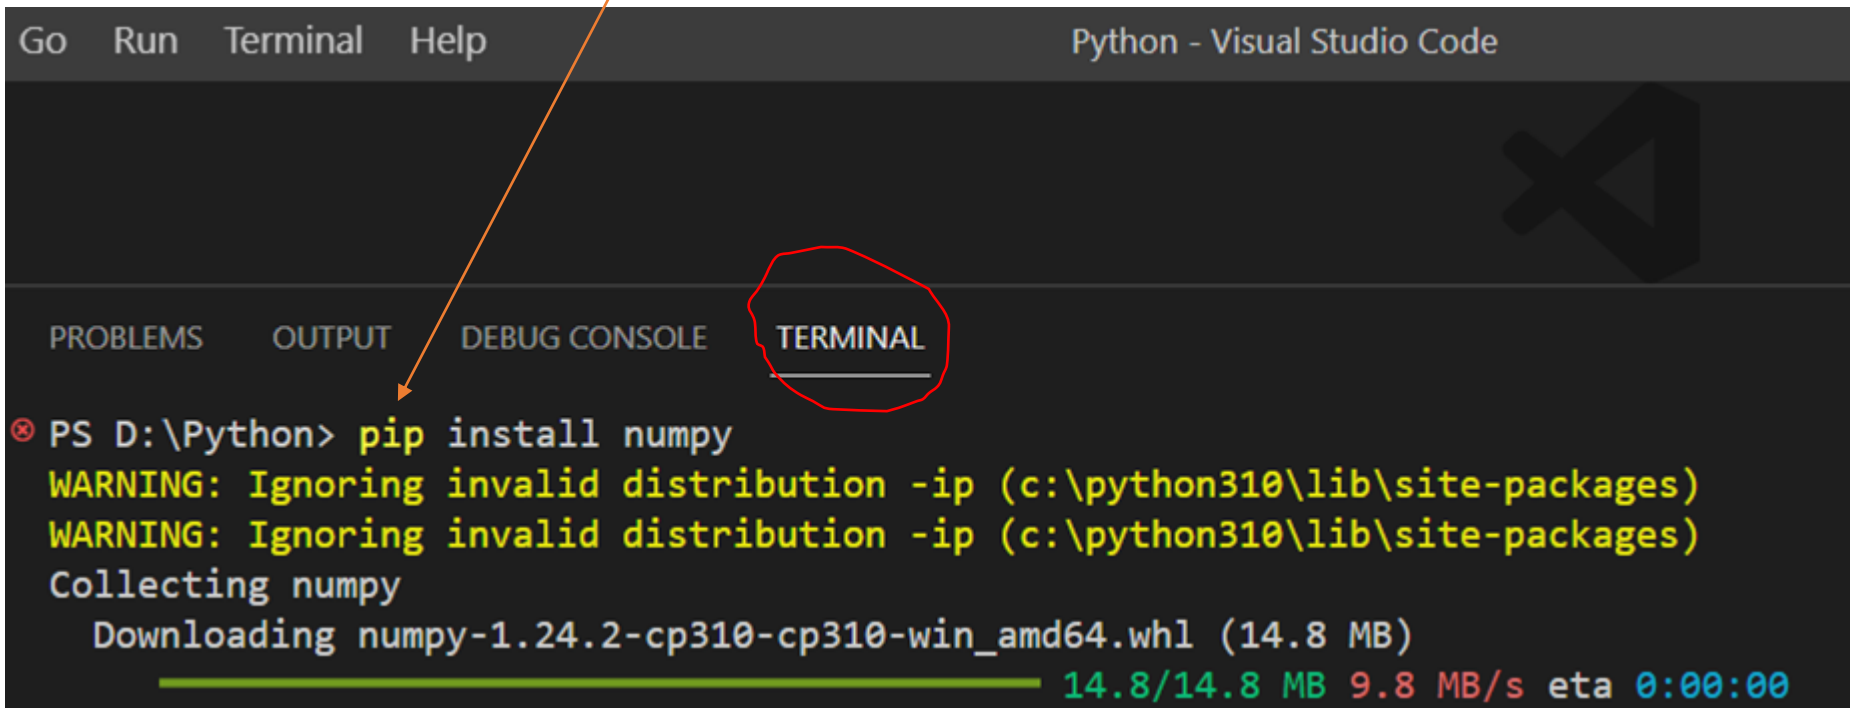

Mean (średnia arytmetyczna)

suma liczb podzielona przez ich liczbę

tablica z ocenami

średnia ocen

mean.py

```python
import numpy

oceny = [1,5,3,3,4,6,2,5]

# wyliczenie średniej arytmetycznej 1 sposób
sumaOcen = 1 + 5 + 3 + 3 + 4 + 6 + 2 + 5
iloscOcen = 8
srednia = sumaOcen/iloscOcen

# wyliczenie średniej arytmetycznej 2 sposób
mean = numpy.mean(oceny)

print("srednia: ")
print(srednia)
print("mean ")
print(mean)
```

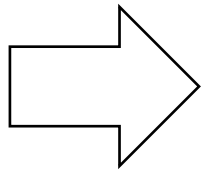

```
srednia:
3.625
mean
3.625
```

wyliczenie średniej z tablicy ocen za pomocą biblioteki NumPy

w3schools

Mean (średnia arytmetyczna)

Zadanie

Napisz program mean.py wyliczający średnią arytmetyczną wymyślonego przez Ciebie zbioru liczb

Median (mediana)

wartość środkowa posortowanego zbioru liczb

wyliczenie mediany z tablicy ocen za pomocą biblioteki NumPy

liczba ocen jest nieparzysta – można znaleźć wartość środkową posortowanego zbioru

median.py

```
1   import numpy
2
3   oceny = [1,5,4,3,6,2,5]
4
5   # oceny posortowane:
6   # 1 2 3 4 5 5 6
7
8   median = numpy.median(oceny)
9
10  print("median: ")
11  print(median)
```

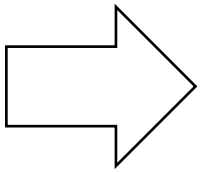

```
median:
4.0
```

w3schools

Median (mediana)

median1.py

```python
import numpy

oceny = [1,5,4,3,1,6,2,5]

# oceny posortowane:
# 1 1 2 3 4 5 5 6

median = numpy.median(oceny)

print("median: ")
print(median)
```

liczba ocen jest parzysta – nie ma jednej wartości środkowej posortowanego zbioru

w tym przypadku medianą jest średnia arytmetyczna dwóch środkowych liczb:
(2+4)/2=3.5

```
median:
3.5
```

Median (mediana)

Zadanie

Napisz program median.py wyliczający medianę (2 przypadki) wymyślonego przez Ciebie zbioru liczb

biblioteka SciPy

Fundamental algorithms for scientific computing in Python

SciPy to biblioteka służąca do obliczeń, która opiera się na bibliotece NumPy

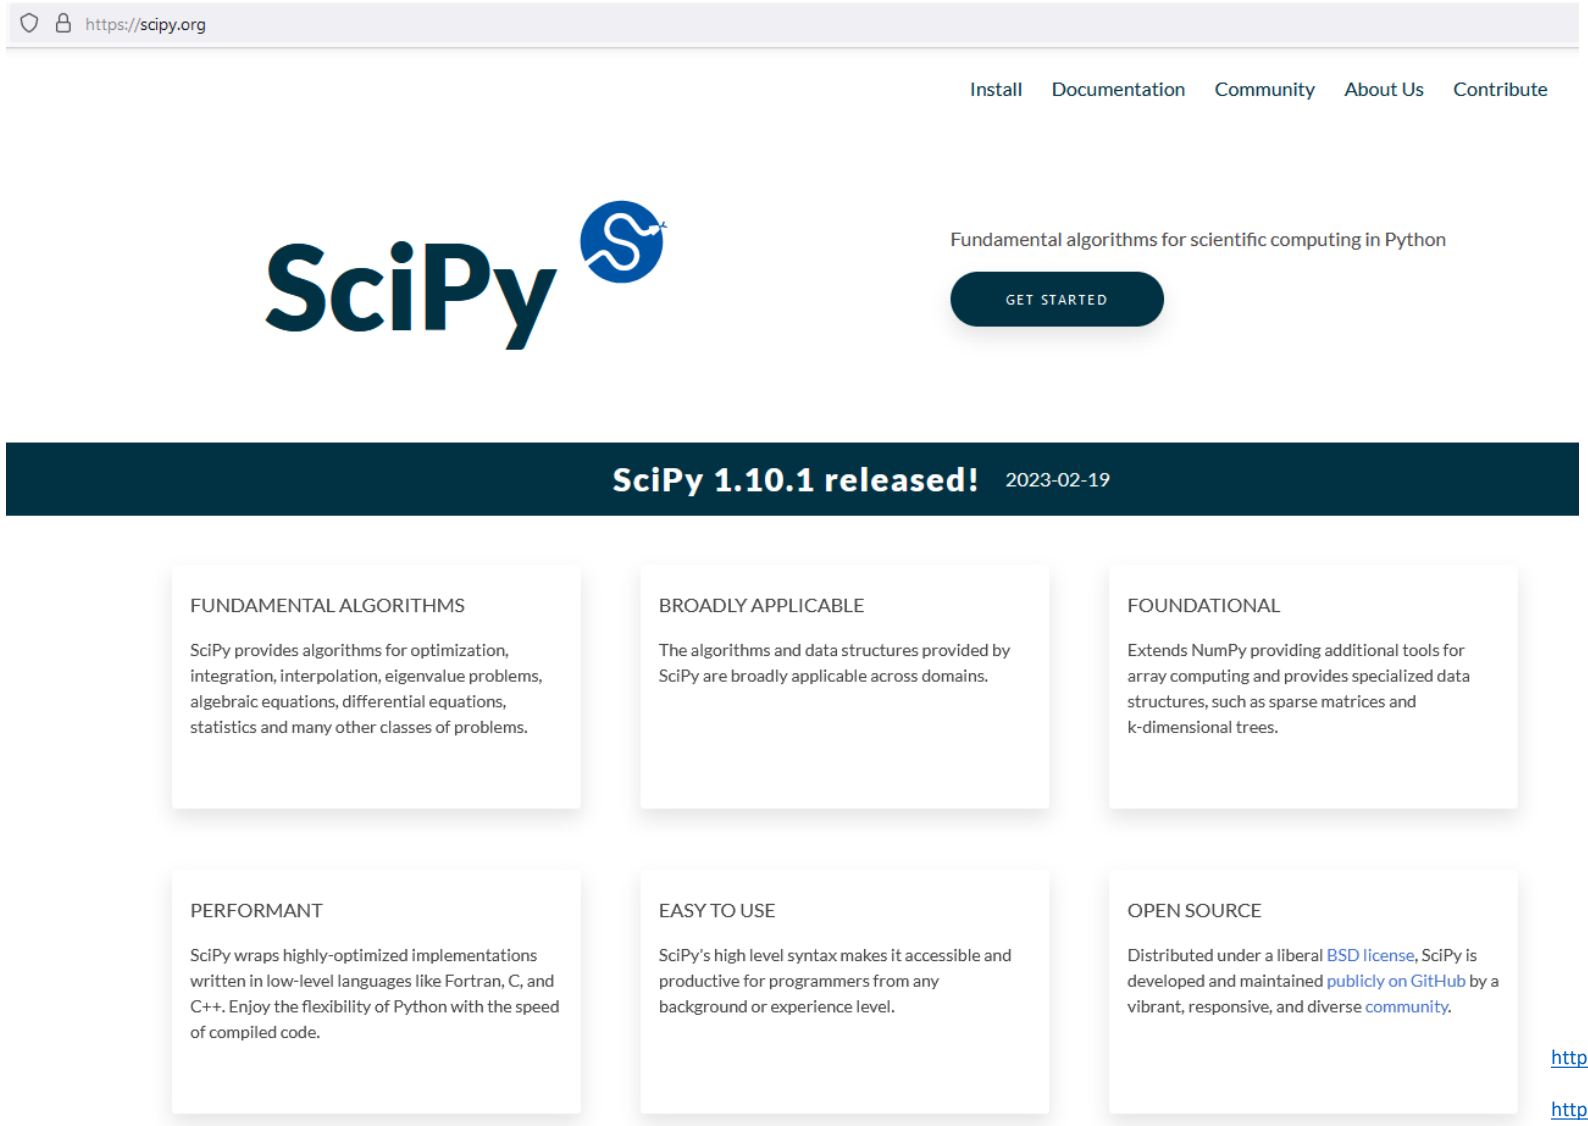

https://scipy.org/

https://www.w3schools.com/python/scipy/scipy_intro.php

biblioteka SciPy

instalacja biblioteki SciPy w VSC

```
pip install scipy
```

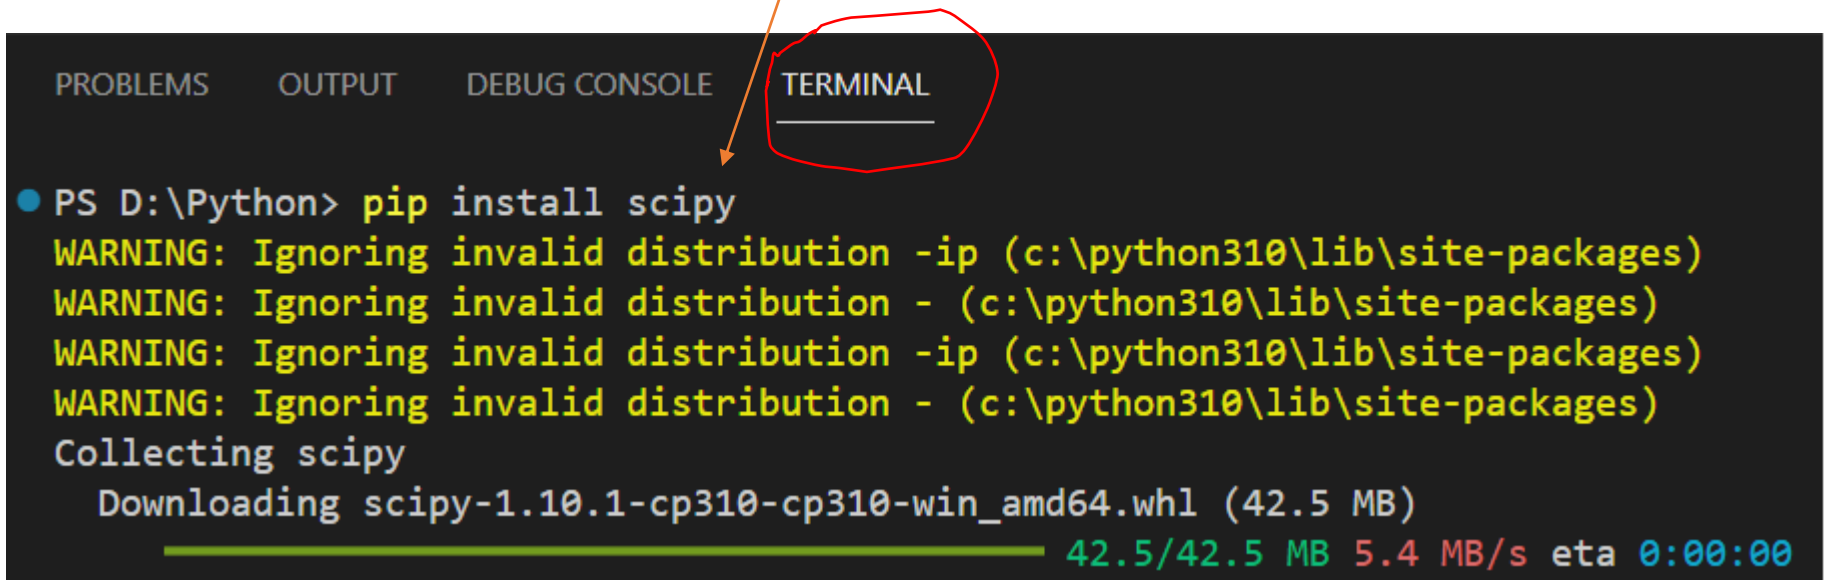

Mode (moda)

najczęściej występująca wartość liczbowa

mode.py

```python
from scipy import stats

oceny = [1,5,4,3,1,6,2,5,5,5,6,1,3,2,2]

mode = stats.mode(oceny)

print("mode: ")
print(mode)
```

```
mode:
ModeResult(mode=array([5]), count=array([4]))
```

wyliczenie najczęściej występującej wartości liczbowej w zbiorze za pomocą biblioteki SciPy

najczęściej występująca ocena to 5

5 występuje 4 razy

w3schools

Mode (moda)

Zadanie

Napisz program mode.py wyliczający modę wymyślonego przez Ciebie zbioru liczb

Standard Deviation (Odchylenie standardowe)

Odchylenie standardowe opisuje rozłożenie danej wielkości (np. wzrostu uczniów) wokół średniej

duże odchylenie standardowe

	Jan	Mirek	Ola	Nadia	Klaudia	Średnia
wzrost	180	120	150	210	140	160

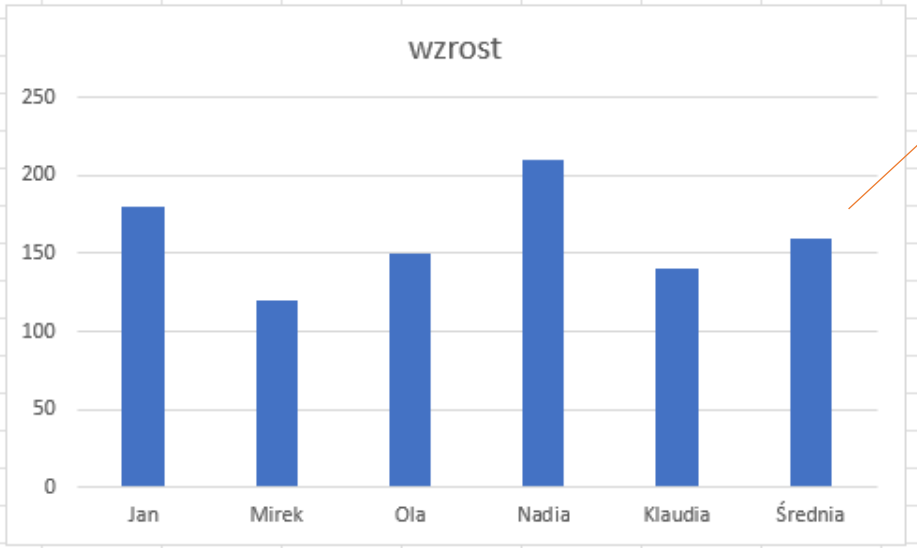

średnia

małe odchylenie standardowe

	Jan	Mirek	Ola	Nadia	Klaudia	Średnia
wzrost	180	182	185	181	177	181

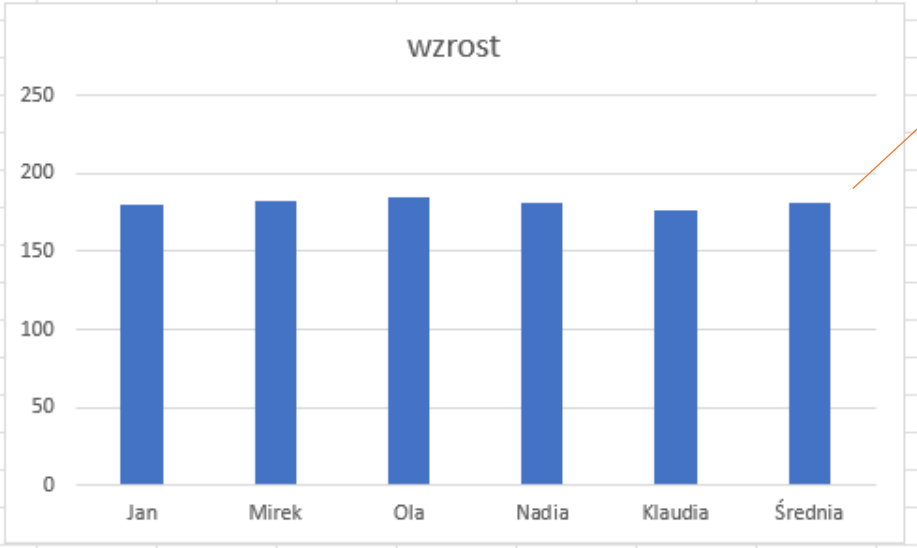

średnia

Standard Deviation (Odchylenie standardowe)

Załóżmy że mamy dane liczby $x_1, x_2, \ldots, x_n$ oraz że ich średnia arytmetyczna wynosi $\overline{X}$

Wówczas **odchylenie standardowe** tych liczb od ich średniej arytmetycznej, to pierwiastek kwadratowy z wariancji, czyli:

$$\sigma = \sqrt{\frac{\left(x_1 - \overline{X}\right)^2 + \left(x_2 - \overline{X}\right)^2 + \ldots + \left(x_n - \overline{X}\right)^2}{n}}$$

sigma

wariancja

odchylenie standardowe jest pierwiastkiem z wariancji

https://www.matemaks.pl/odchylenie-standardowe.html

Standard Deviation (Odchylenie standardowe)

liczymy odchylenie standardowe „ręcznie” ze wzoru (pierwiastek z wariancji)

	Jan	Mirek	Ola	Nadia	Klaudia	Średnia
wzrost	180	120	150	210	140	160

większość wartości mieści się w przedziale (średnia – σ, średnia + σ), czyli około (128.4 , 191.6)

wariancja:

$(180-160)^2 + (120-160)^2 + (150-160)^2 + (210-160)^2 + (140-160)^2 = 5000$

5000/5 = 1000

odchylenie standardowe wzrostu uczniów od średniej arytmetycznej ich wzrostu:

$\sigma = \sqrt{1000} = 31{,}62277660168379$

Standard Deviation (Odchylenie standardowe)

liczymy odchylenie standardowe „ręcznie” ze wzoru (pierwiastek z wariancji)

	Jan	Mirek	Ola	Nadia	Klaudia	Średnia
wzrost	180	182	185	181	177	181

większość wartości mieści się w przedziale (średnia – σ, średnia + σ), czyli około (178.4 , 183.6)

wariancja:

$(180-181)^2 + (182-181)^2 + (185-181)^2 + (181-181)^2 + (177-181)^2 = 34$

$34/5 = 6{,}8$

odchylenie standardowe wzrostu uczniów od średniej arytmetycznej ich wzrostu:

$\sigma = \sqrt{6{,}8} = 2{,}607680962081059$

Standard Deviation (Odchylenie standardowe)

wyniki działania programu zgadzają się z obliczeniami

standardDeviation.py > ...

```python
# Odchylenie standardowe

import numpy

wzrost1 = [180, 120, 150, 210, 140]

sigma1 = numpy.std(wzrost1)

print(sigma1)  # 31.622776601683793



wzrost2 = [180, 182, 185, 181, 177]

sigma2 = numpy.std(wzrost2)

print(sigma2)  # 2.6076809620810595
```

duże odchylenie standardowe

małe odchylenie standardowe

w3schools

Standard Deviation (Odchylenie standardowe)

Zadanie

Napisz program standardDeviation.py
wyliczający odchylenie standardowe
wymyślonego przez Ciebie zbioru liczb
za pomocą biblioteki numpy oraz „ręcznie”
ze wzoru (pierwiastek z wariancji)
i porównaj oba wyniki.

Percentile (percentyl, centyl)

jednostka statystyczną opisującą położenie danego wyniku
względem całej grupy wyników

waga uczniów w klasie

percentyl 70 wynosi 80.5

55,64,67,68,69,71,73,75,75,76,80,81,81,82,83,84

70% ma wagę mniejszą lub równą 80.5

30% ma wagę większą lub równą 80.5

percentyl 30 wynosi 70

55,64,67,68,69,71,73,75,75,76,80,81,81,82,83,84

30% ma wagę mniejszą lub równą 70

70% ma wagę większą lub równą 70

w3schools

Percentile (percentyl, centyl)

percentile.py > ...

```python
# percentyl

import numpy

# waga uczniów w klasie
wagaUcznow = [55,64,67,68,69,71,73,75,75,76,80,81,81,82,83,84]


x = numpy.percentile(wagaUcznow, 70)

print(x) # 80,5

# percentyl 70 wynosi 80.5, czyli 70% uczniów w klasie waży 80.5 kg lub mniej,
# a 30% waży 80.5 lub więcej

x1 = numpy.percentile(wagaUcznow, 30)

print(x1) # 70

# percentyl 30 wynosi 70, czyli 30% uczniów w klasie waży 70 kg lub mniej,
# a 70% waży 70 kg lub więcej
```

Percentile (percentyl, centyl)

SiatkiCentylowe.pl
Sprawdź czy Twoje dziecko rośnie prawidłowo!

GAZETA.PL eDZIECKO

Stwórz wykres rozwoju swojego dziecka

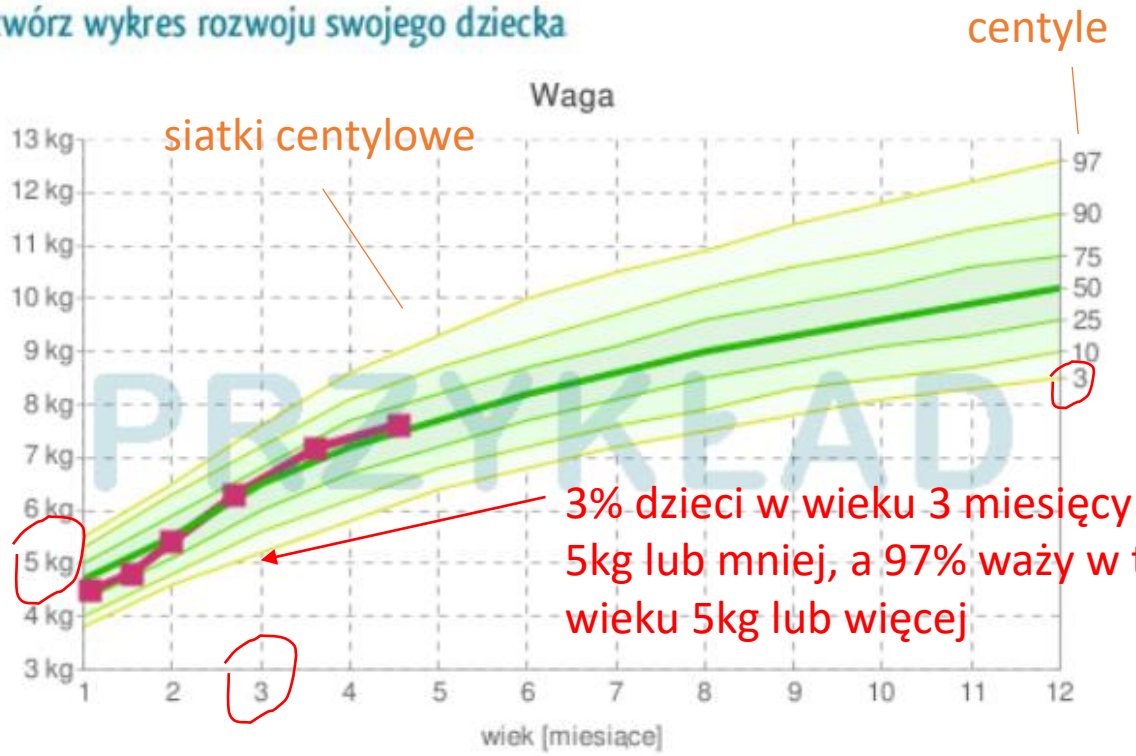

Imię dziecka

Chłopiec ✓ Dziewczynka

Data urodzenia 1 sty 2023

Poród po 37 tygodniu ciąży

Aktualna waga np. 5,6 lub 5600 kg lub g

Aktualny wzrost np. 1,3 lub 130 m lub cm

Sprawdź

Percentile (percentyl, centyl)

Zadanie

Napisz program percentile.py wyliczający percentyle (np. 30, 70, 90) wymyślonego przez Ciebie zbioru liczb.

Data Distribution

generowanie większych zestawów danych o losowych wartościach z zadanego przedziału

dataDistribution.py > ...

```
1   import numpy
2
3   # generujemy tablicę z 100 liczbami zmiennoprzecinkowymi
4   # od 0.0 do 10.0
5   x = numpy.random.uniform(0.0, 10.0, 100)
6
7   print(x)
```

PROBLEMS OUTPUT DEBUG CONSOLE TERMINAL

```
[7.674779   7.69883332 0.92209627 9.83660979 3.08315446 0.60584779
 6.09662585 8.36481537 5.56000548 2.62851999 3.37267935 4.76898585
 1.49754479 1.90010583 4.73398192 4.82357879 6.42636956 2.57747062
 5.5997542  9.75040714 0.63285461 5.69627121 7.82804193 4.2911846
 8.64308559 1.91042692 3.74896261 1.58336151 6.73568663 6.73575566
 2.73016232 0.57961486 6.27834905 1.11411084 3.17106164 2.57413344
 5.97488182 1.49737393 3.50607135 3.89399608 7.408972   5.14622145
 9.43683799 3.87058616 9.86684954 7.81324592 8.30541873 6.63463676
 8.46751301 3.07323543 0.06238049 8.76128193 2.21374294 1.71140466
 5.39412918 3.2636824  7.66549917 3.27410594 8.94793225 8.09374154
 9.39442246 9.24498564 2.94694031 2.764871   0.82347865 9.85358219
 9.67886126 3.69106715 8.28428369 6.72515776 3.57139894 2.13184733
 9.57992567 2.07685891 5.44043542 4.32569312 6.49344519 2.29765696
 7.82494696 7.68550252 2.81913035 8.93955411 0.63003125 7.06999215
 3.3745049  8.83460066 5.74506609 5.06203303 1.29873823 0.96009959
 4.42899987 4.2416471  3.15878843 6.84989385 0.30176548 4.00414833
 9.78681706 3.60114878 0.83930493 6.51612493]
```

Matplotlib

biblioteka do wizualizacji danych

instalacja biblioteki do wizualizacji danych (polecenie konsoli VSC)

```
pip install matplotlib
```

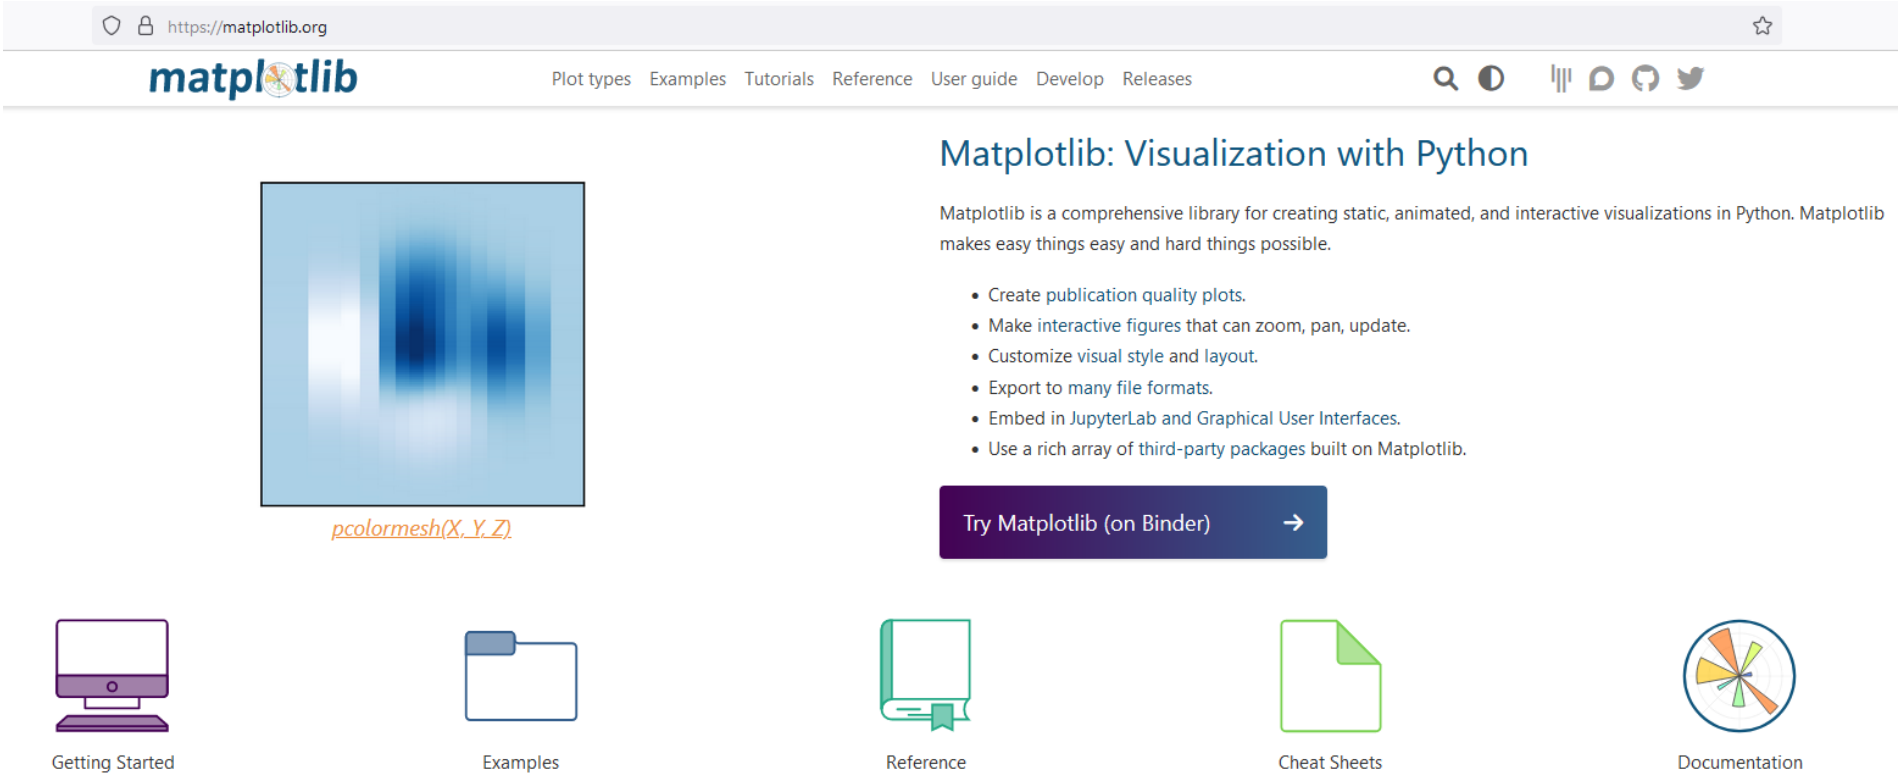

https://matplotlib.org/

Matplotlib Tutorial

Histogram

wizualizacja danych

```python
import numpy
import matplotlib.pyplot as plt
# generujemy tablicę 100 liczb od 0.0 do 10.0
x = numpy.random.uniform(0.0, 10.0, 100)
# printujemy wygenerowaną tablicę w konsoli
print(x)
# rysujemy wykres, dzielimy wartości liczb w tablicy na 10 części
# (0-1, 1-2, 2-3, 3-4, 4-5, 5-6, 6-7, 7-8, 8-9, 9-10)
plt.hist(x, 10)
plt.show()
```

PROBLEMS OUTPUT DEBUG CONSOLE TERMINAL

```
[1.92179086 5.98150425 5.94373096 6.14511435 9.23256774 2.8359206
 4.12616451 6.69787685 3.19985642 8.48468981 4.61581537 2.95289493
 2.07073596 4.96036226 5.21528547 3.52346587 0.10252719 8.00412672
 9.09351464 6.84431797 8.78220438 3.39492939 0.72205618 1.73004308
 5.97051677 6.17851747 4.665998   0.58243455 6.65103211 1.92881416
 3.52439853 9.47233201 4.65297173 1.13391145 7.96241203 4.86049233
 2.76540945 3.86651517 5.41103277 1.4162206  9.08593993 0.66104275
 6.71714142 4.69211213 2.49520636 8.9098651  2.82854516 3.61967312
 2.4218803  7.69995261 9.76259368 5.46836413 9.46304091 7.60461799
 4.83357485 9.02502164 6.22683394 4.43410032 0.91141602 4.7919888
 4.91433794 8.02934503 5.51602024 4.86131828 8.76303273 9.85742086
 0.79407558 2.08266313 1.41496389 0.75169256 5.70705268 7.51512718
 9.93874135 8.6803627  1.0375709  1.33474207 3.00148903 9.81997885
 3.9907255  4.63053324 1.94705201 5.93010293 9.91223935 4.46037871
 9.17946869 5.79040179 6.8266409  3.63845849 7.38982254 9.85350806
 6.44424543 4.34043448 0.42971314 6.30665949 5.23082335 9.70468113
 1.43708385 4.72039859 2.27684719 7.0696808 ]
```

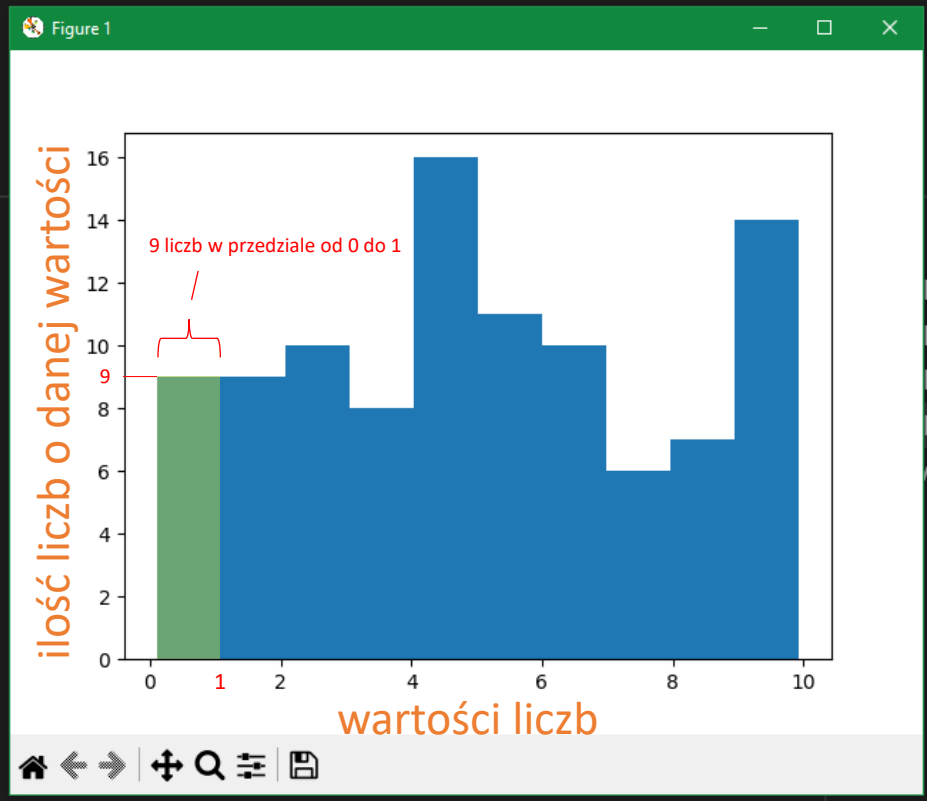

interpretacja wykresu:

Wartość liczb	Ilość liczb o danej wartości
0-1	9
1-2	9
2-3	10
3-4	8
4-5	16
5-6	11
6-7	10
7-8	6
8-9	7
9-10	14

w sumie 100 liczb

w3schools

Histogram

Zadanie

Wygeneruj większy zestaw danych
i przedstaw go na wykresie.
Zinterpretuj dane na wykresie (opisz wykres).

Normal Data Distribution
(rozkład normalny, krzywa Gaussa)

normalDataDistribution.py > ...

```python
import numpy
import matplotlib.pyplot as plt

# generujemy 100000 losowych liczb
# o średniej 10.0 oraz odchyleniu standardowym 1.0,
# króre tworzą rozkład normalny
x = numpy.random.normal(10.0, 1.0, 100000)

# generujemy wykres podzielony na 100 słupków
plt.hist(x, 100)
plt.show()
```

reguła 3 sigm

68.2% liczb znajduje się w zakresie pomiędzy (μ-σ, μ +σ)
95.4% liczb znajduje się w zakresie pomiędzy (μ-2σ, μ +2σ)
99.7% liczb znajduje się w zakresie pomiędzy (μ-3σ, μ +3σ)

σ – odchylenie standardowe (sigma)
μ – średnia (mi)

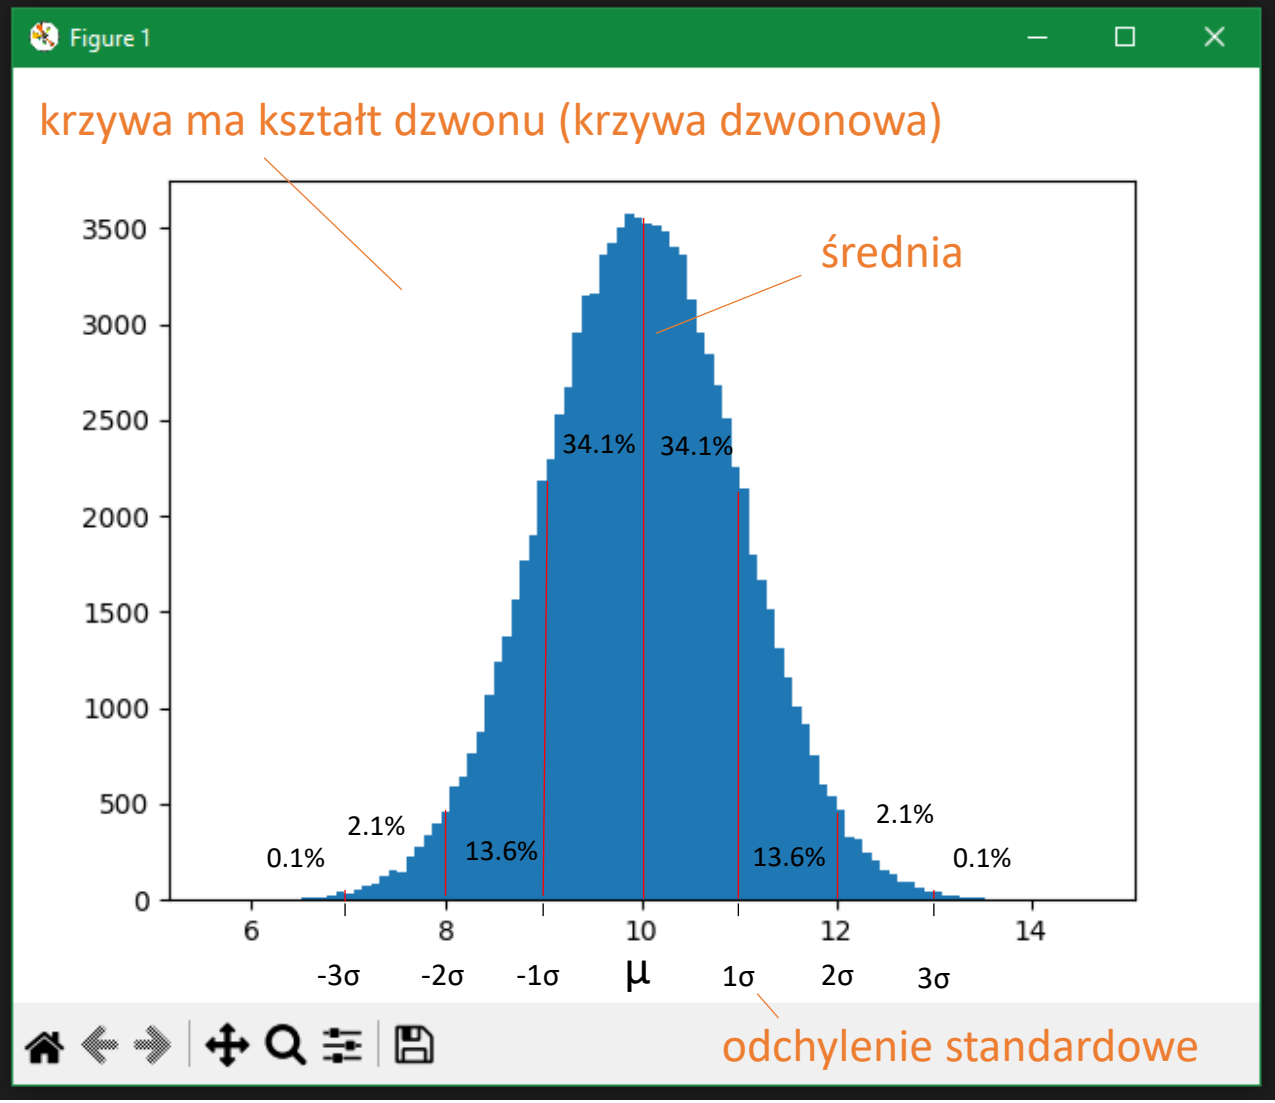

Normal Data Distribution
(rozkład normalny, krzywa Gaussa)

Rozkład normalny spotykamy w życiu codziennym np.:

- poziom inteligencji człowieka - najwięcej osób posiada średni poziom inteligencji, IQ = 100.
  Dużo mniej osób posiada poziom inteligencji równy IQ = 80, czy IQ = 120, a jeszcze mniej, IQ = 65, czy IQ = 135.
  Inteligencja mierzona testami inteligencji uważana jest za zmienną o rozkładzie normalnym.
- wzrost człowieka może być uznany w przybliżeniu za zmienną o rozkładzie normalnym

https://pl.wikipedia.org/wiki/Rozk%C5%82ad_normalny

Normal Data Distribution
(rozkład normalny, krzywa Gaussa)

Zadanie

Wygeneruj losowy zestaw danych,
którego wartości tworzą rozkład normalny.
Wygeneruj krzywą dzwonową rozkładu.

Scatter Plot (wykres punktowy)

scatterPlot.py > ...

```python
# dane pobrane ze strony ZUS:
# https://www.zus.pl/baza-wiedzy/skladki-wskazniki-odsetki/wskazniki/przecietne-wynagrodzenie-w-latach

import numpy
import matplotlib.pyplot as plt

# lata
x = [1995,1996,1997,1998,1999,2000,2001,2002,2003,2004,2005,2006,2007,2008,2009,2010,
     2011,2012,2013,2014,2015,2016,2017,2018,2019,2020,2021,2022]

# przeciętna pensja w Polsce
y = [702.62,873.00,1061.93,1239.49,1706.74,1923.81,2061.85,2133.21,2201.47,2289.57,
    2380.29,2477.23,2691.03,2943.88,3102.96,3224.98,3399.52,3521.67,3650.06,3783.46,
    3899.78,4047.21,4271.51,4585.03,4918.17,5167.47,5662.53,6346.15]


# przecietne roczne zarobki w Polsce
y1 = [8431.44,10476.00,12743.16,14873.88,20480.88,23085.72,24742.20,25598.52,26417.64,27474.84,
     28563.48,29726.76,32292.36,35326.56,37235.52,38699.76,40794.24,42260.04,43800.72,45401.52,
     46797.36,48566.52,51258.12,55020.36,59018.04,62009.64,67950.36,76153.80]


plt.scatter(x, y)
plt.show()
```

dane pobrane ze strony ZUS

Scatter Plot (wykres punktowy)

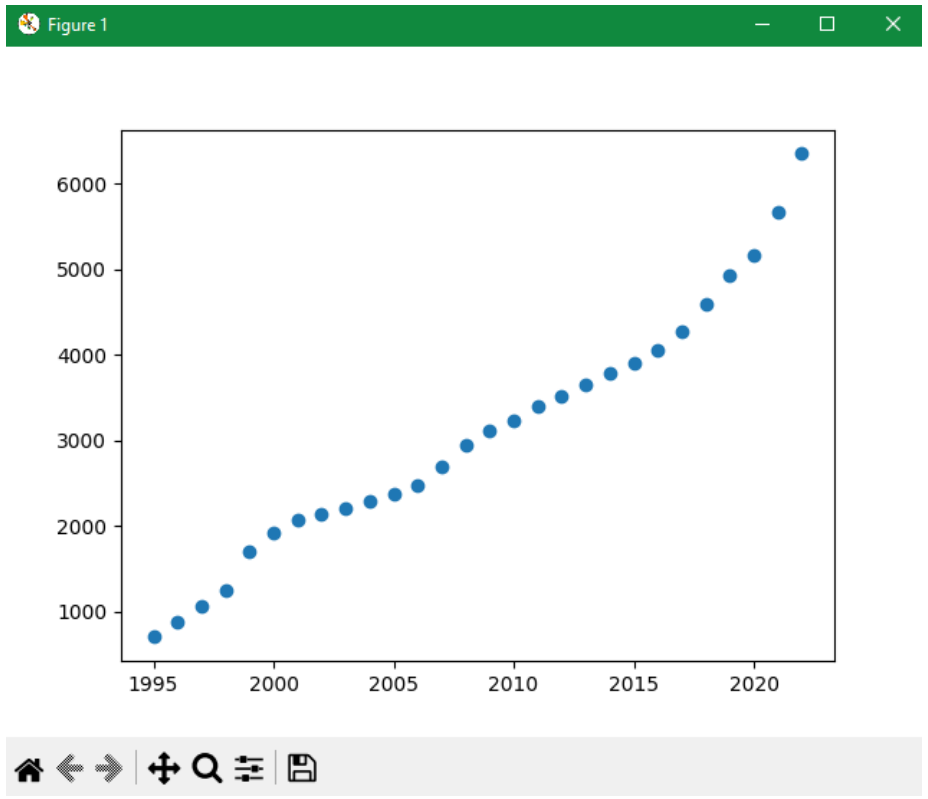

przeciętne zarobki miesięczne w Polsce od 1995 roku wg. ZUS

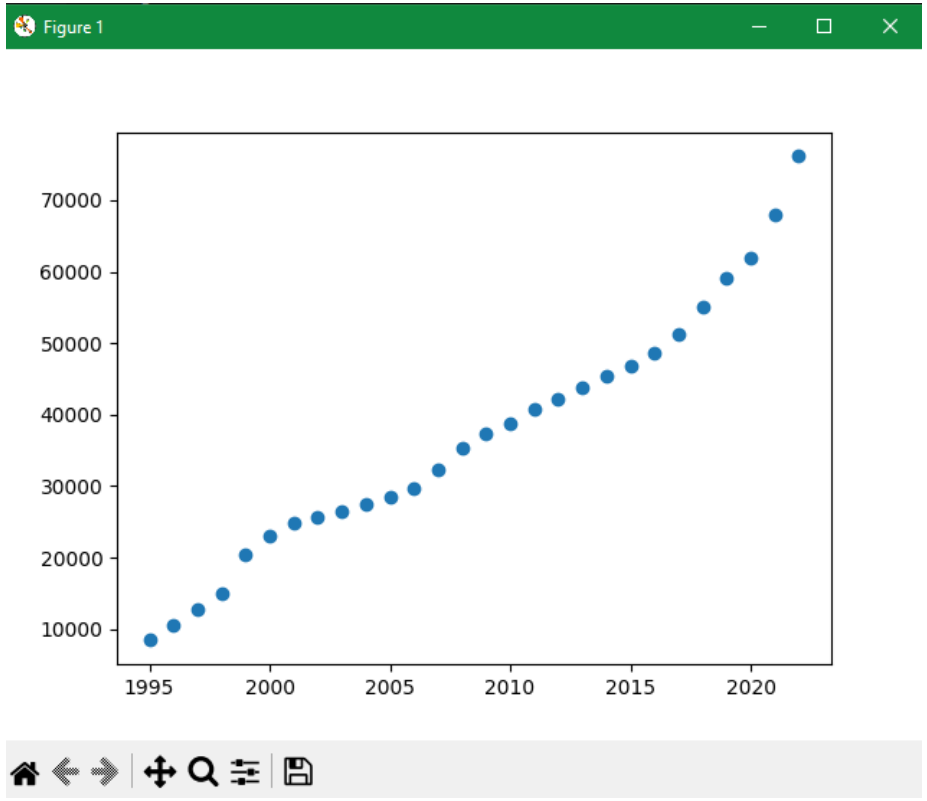

przeciętne zarobki roczne w Polsce od 1995 roku wg. ZUS

Scatter Plot (wykres punktowy)

scatterPlotRandom.py > ...

```python
import numpy
import matplotlib.pyplot as plt

x = numpy.random.normal(20.0, 1.0, 1000)
y = numpy.random.normal(10.0, 2.0, 1000)

plt.scatter(x, y)
plt.show()
```

x oraz y są rozkładami normalnymi

μ (średnia – mi)

σ (odchylenie standardowe - sigma)

ilość liczb wygenerowanych losowo

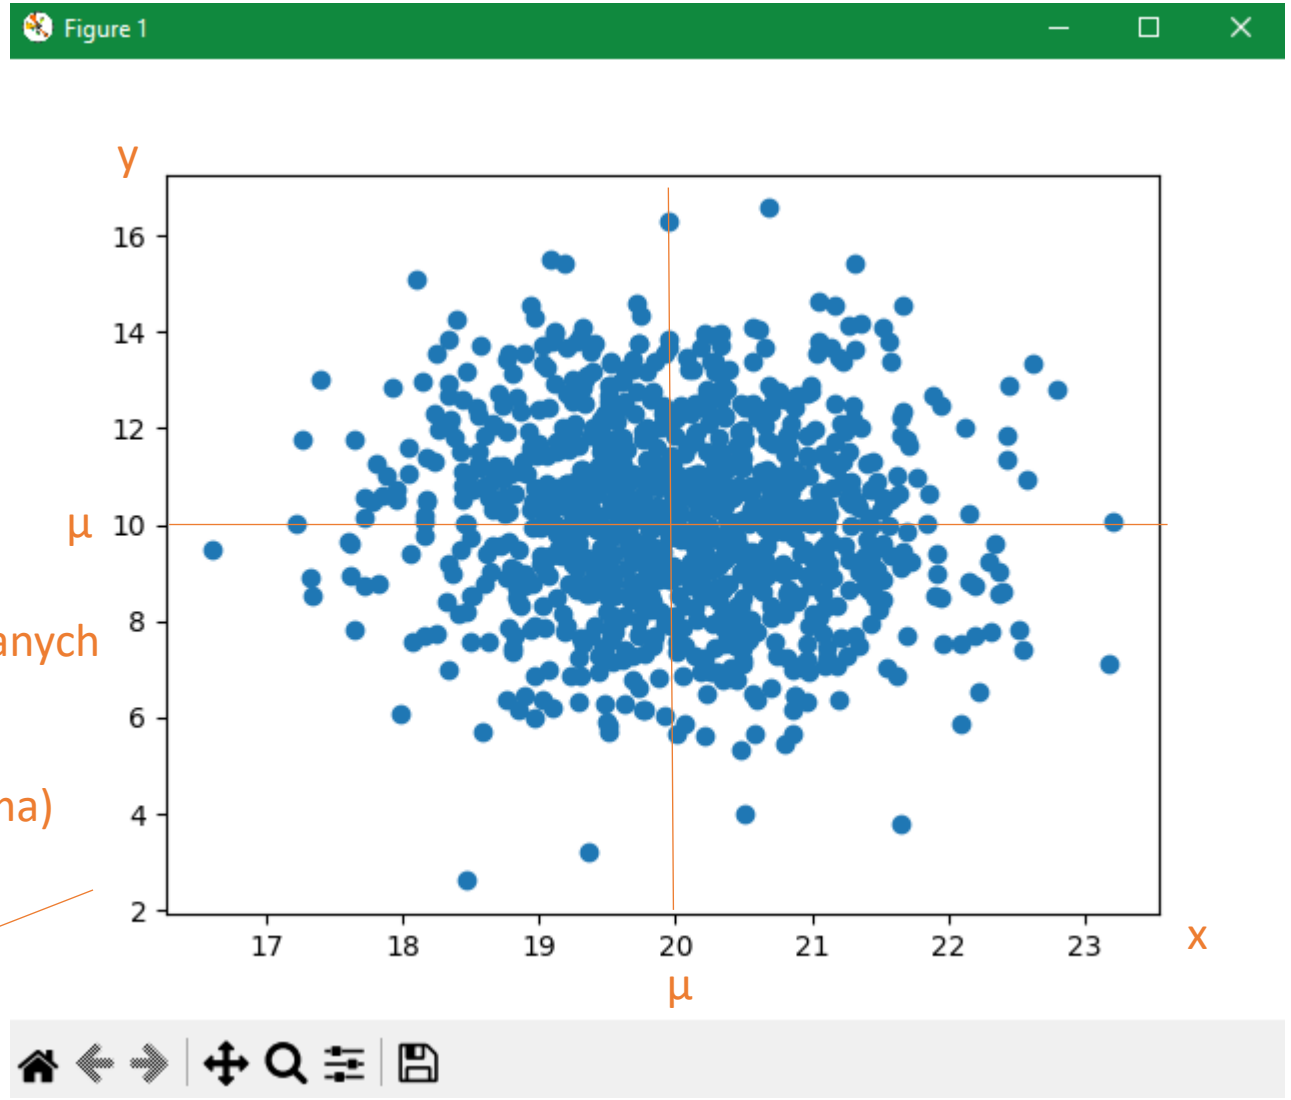

kropki koncentrują się po osi x wokół wartości 20 (średnia) oraz po osi y wokół wartości 10 (średnia). Wartości liczb są bardziej rozstrzelone po osi y (większe odchylenie standardowe - bardziej odbiegają od średniej)

Model

aproksymacja danych za pomocą funkcji

zbiór danych

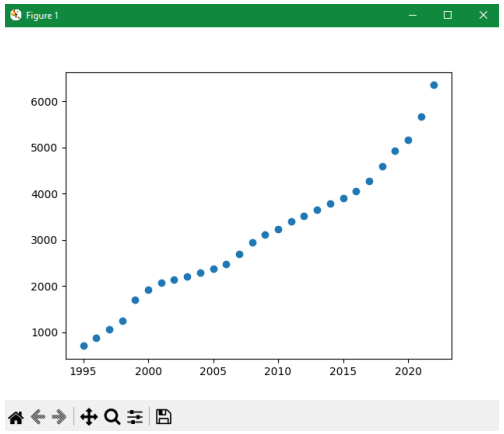

zbiór danych

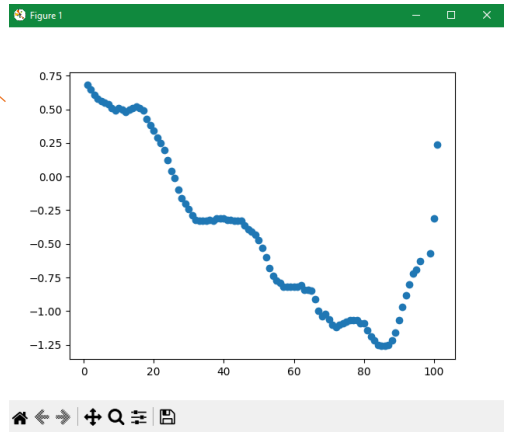

tworzenie modelu

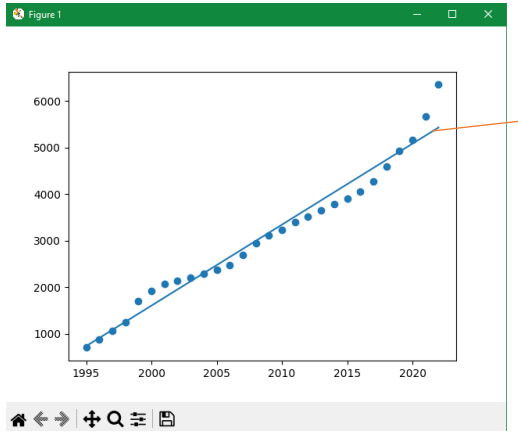

model liniowy (*Linear Regression*)

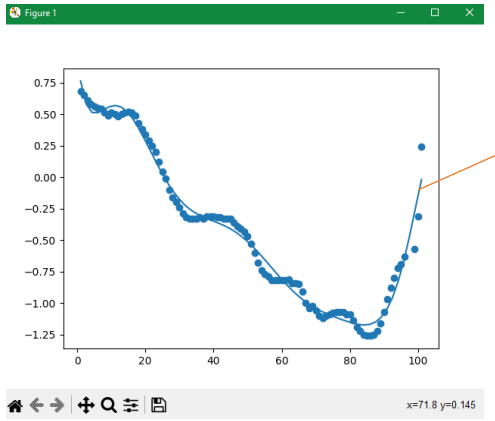

model wielomianowy (*Polynomial Regression*)

Linear Regression (Regresja liniowa)

liniowa zależność pomiędzy zmiennymi

zależność pomiędzy zmiennymi wykorzystywana do przewidywania wyniku przyszłych zdarzeń.

linearRegression.py > ...

```python
import matplotlib.pyplot as plt
from scipy import stats

# lata
x = [1995,1996,1997,1998,1999,2000,2001,2002,2003,2004,2005,2006,2007,2008,2009,2010,
     2011,2012,2013,2014,2015,2016,2017,2018,2019,2020,2021,2022]

# przeciętna pensja w Polsce
y = [702.62,873.00,1061.93,1239.49,1706.74,1923.81,2061.85,2133.21,2201.47,2289.57,
     2380.29,2477.23,2691.03,2943.88,3102.96,3224.98,3399.52,3521.67,3650.06,3783.46,
     3899.78,4047.21,4271.51,4585.03,4918.17,5167.47,5662.53,6346.15]


slope, intercept, r, p, std_err = stats.linregress(x, y)

def myfunc(x):
  return slope * x + intercept

mymodel = list(map(myfunc, x))

plt.scatter(x, y)
plt.plot(x, mymodel)
plt.show()
```

wartości na osi x

wartości na osi y

wyliczenie kluczowych wartości regresji liniowej

definicja funkcji dopasowującej wartości y w zależności od x

tworzenie modelu – tablicy z dopasowanymi wartościami y

rysowanie wykresów

https://pl.wikipedia.org/wiki/Regresja_liniowa

Linear Regression (Regresja liniowa)

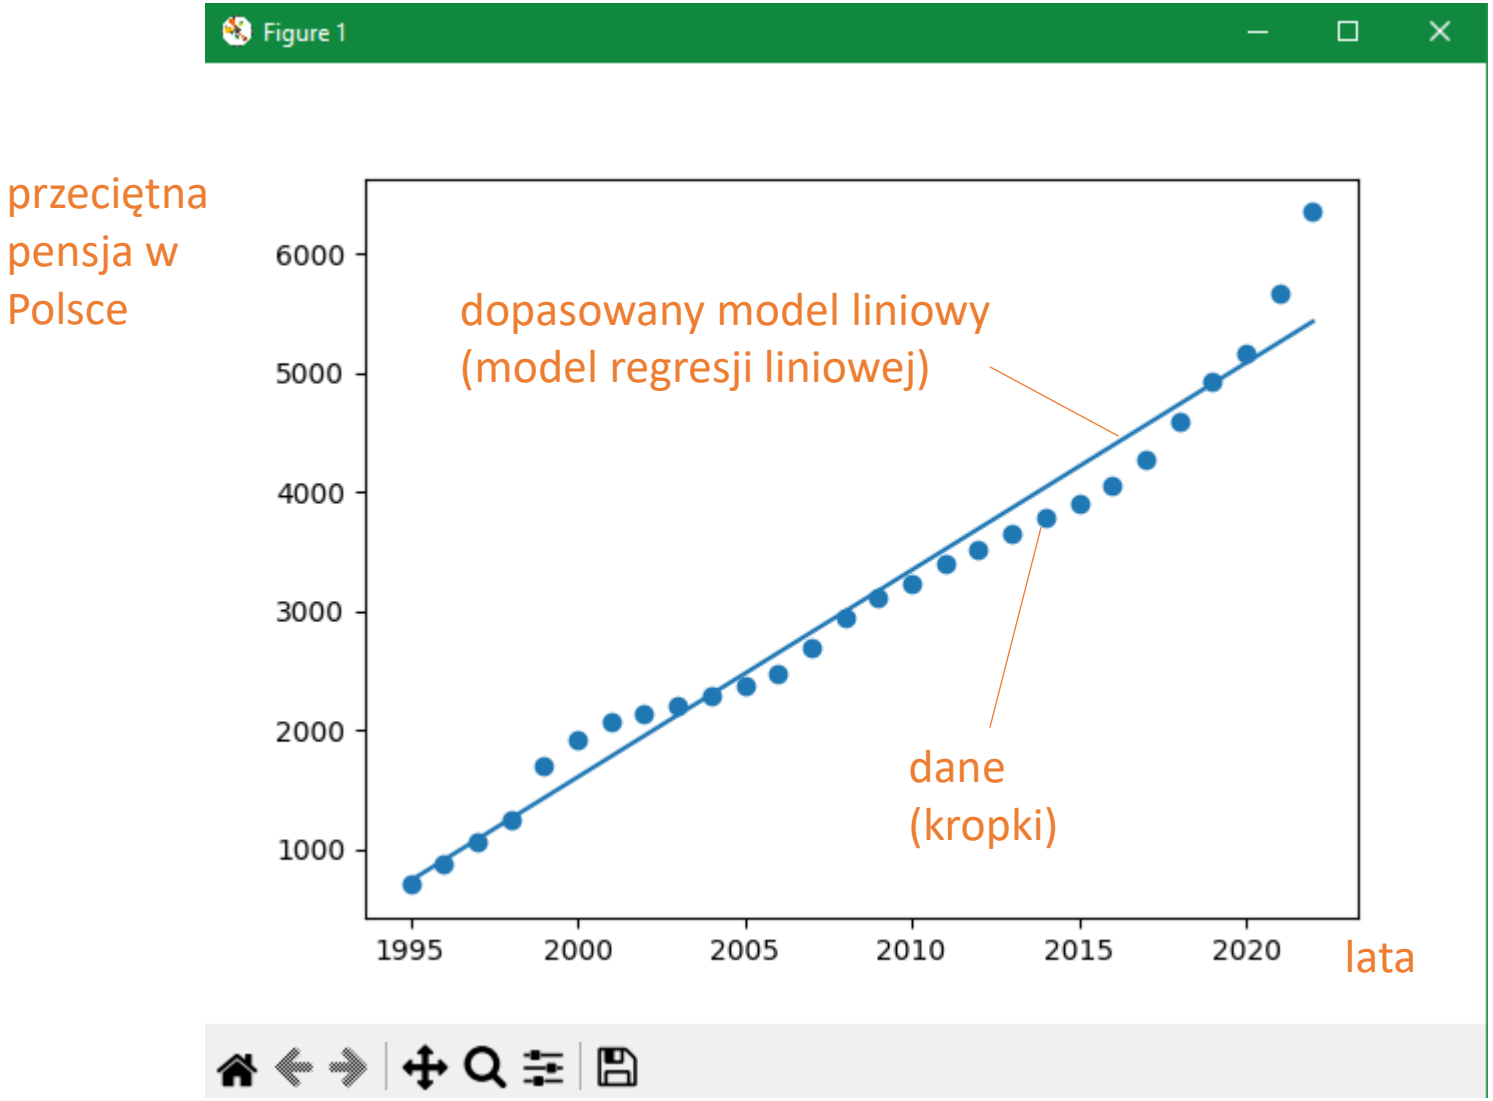

coefficient of correlation r
(współczynnik korelacji r Pearsona)

liczba określająca stopień zależności liniowej pomiędzy zmiennymi (czy taka zależność jest i w jakim stopniu)

r jak relationship (relacja)

r został opracowany przez angielskiego matematyka Karla Pearsona.

silna zależność

brak zależności

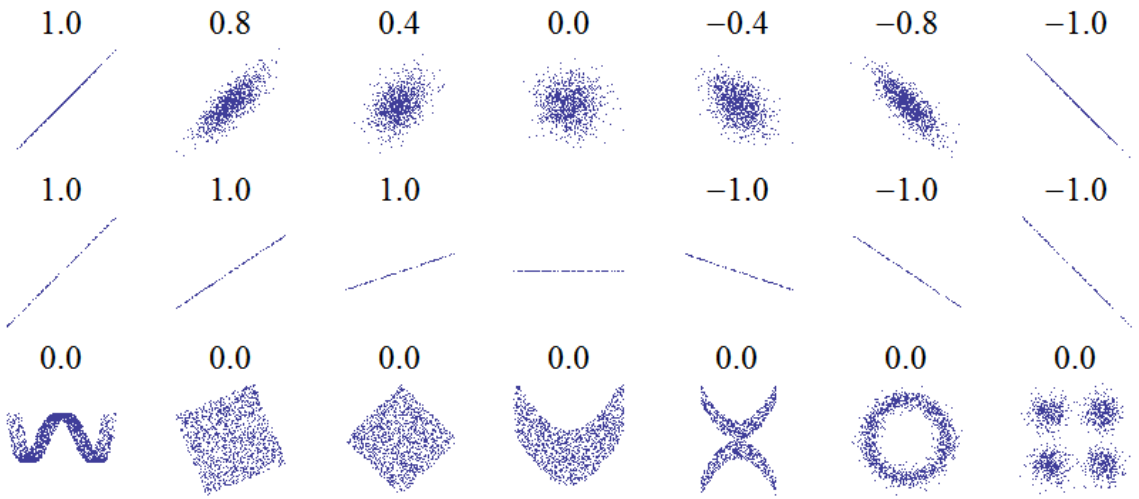

Wartość r waha się od -1 do 1:

- 0 oznacza brak zależności liniowej
- 1 oraz -1 oznacza 100% zależność linową

za pomocą r można badać zależność danych, (czy można utworzyć regresję liniową)

https://pl.wikipedia.org/wiki/Wsp%C3%B3%C5%82czynnik_korelacji_Pearsona

coefficient of correlation r
(współczynnik korelacji r Pearsona)

linearRegressionR.py > ...

```python
# coefficient of correlation r
# współczynnik korelacji r Pearsona
# Czy regresja liniowa dobrze pasuje do danych?


import matplotlib.pyplot as plt
from scipy import stats

# lata
x = [1995,1996,1997,1998,1999,2000,2001,2002,2003,2004,2005,2006,2007,2008,2009,2010,
     2011,2012,2013,2014,2015,2016,2017,2018,2019,2020,2021,2022]

# przeciętna pensja w Polsce
y = [702.62,873.00,1061.93,1239.49,1706.74,1923.81,2061.85,2133.21,2201.47,2289.57,
    2380.29,2477.23,2691.03,2943.88,3102.96,3224.98,3399.52,3521.67,3650.06,3783.46,
    3899.78,4047.21,4271.51,4585.03,4918.17,5167.47,5662.53,6346.15]

slope, intercept, r, p, std_err = stats.linregress(x, y)

print(r)
```

```
0.983556773600779
```

duża zależność liniowa y od x (model liniowy przeciętnej pensji w Polsce wydaje się być dobrze dopasowanym)

Linear Regression (Regresja liniowa)

jeśli r jest bliskie jedynki, możemy przewidzieć przyszłość

linearRegressionPredictFuture.py > ...

```python
from scipy import stats

# lata
x = [1995,1996,1997,1998,1999,2000,2001,2002,2003,2004,2005,2006,2007,2008,2009,2010,
     2011,2012,2013,2014,2015,2016,2017,2018,2019,2020,2021,2022]

# przeciętna pensja w Polsce
y = [702.62,873.00,1061.93,1239.49,1706.74,1923.81,2061.85,2133.21,2201.47,2289.57,
    2380.29,2477.23,2691.03,2943.88,3102.96,3224.98,3399.52,3521.67,3650.06,3783.46,
    3899.78,4047.21,4271.51,4585.03,4918.17,5167.47,5662.53,6346.15]

slope, intercept, r, p, std_err = stats.linregress(x, y)

def myfunc(x):
  return slope * x + intercept

pensja2024 = myfunc(2024)

print(pensja2024)
```

```
5775.192698412691
```

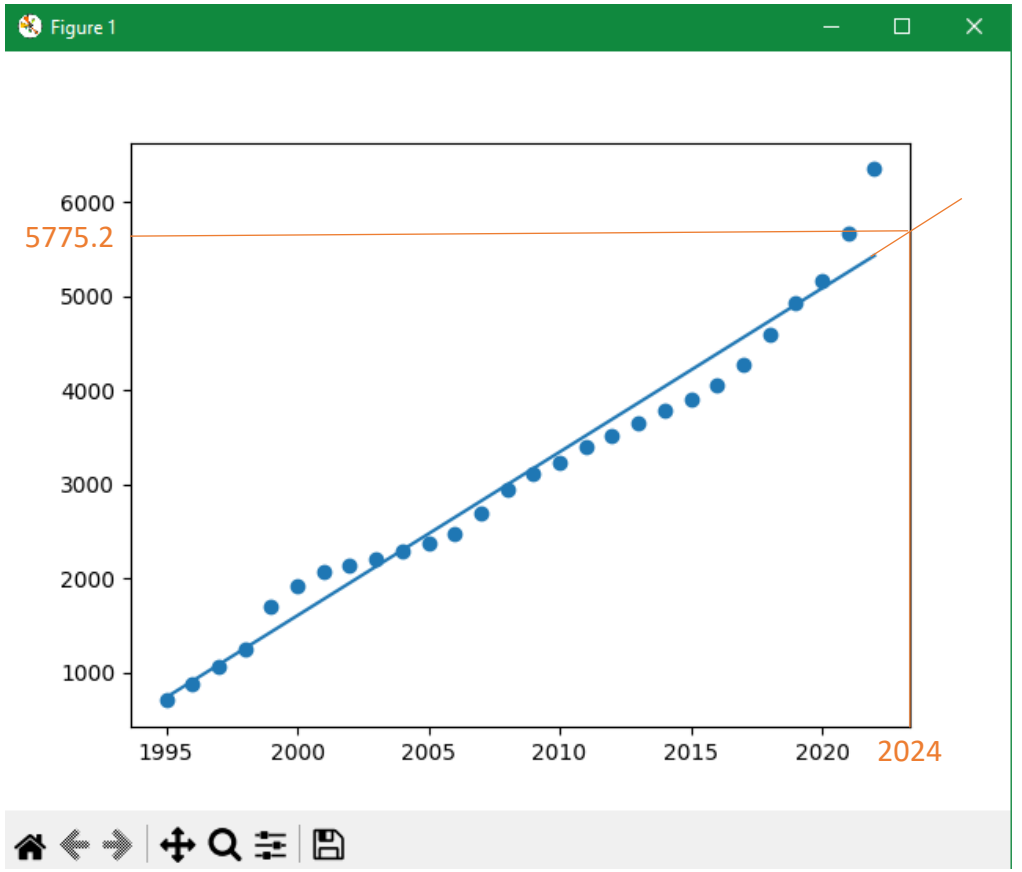

liczymy jaka będzie przeciętna pensja w Polsce w 2024 roku

słabe dopasowanie danych

Linear Regression (Regresja liniowa)

linearRegressionBadFit.py > ...

```python
# złe dopasowanie regresji liniowej

import numpy
import matplotlib.pyplot as plt
from scipy import stats

# generujemy tablice z 100 losowymi liczbami zmiennoprzecinkowymi
# od 0.0 do 100.0
x = numpy.random.uniform(0.0, 100.0, 100)
y = numpy.random.uniform(0.0, 100.0, 100)

slope, intercept, r, p, std_err = stats.linregress(x, y)

def myfunc(x):
  return slope * x + intercept

mymodel = list(map(myfunc, x))

plt.scatter(x, y)
plt.plot(x, mymodel)
plt.show()

print(r)
```

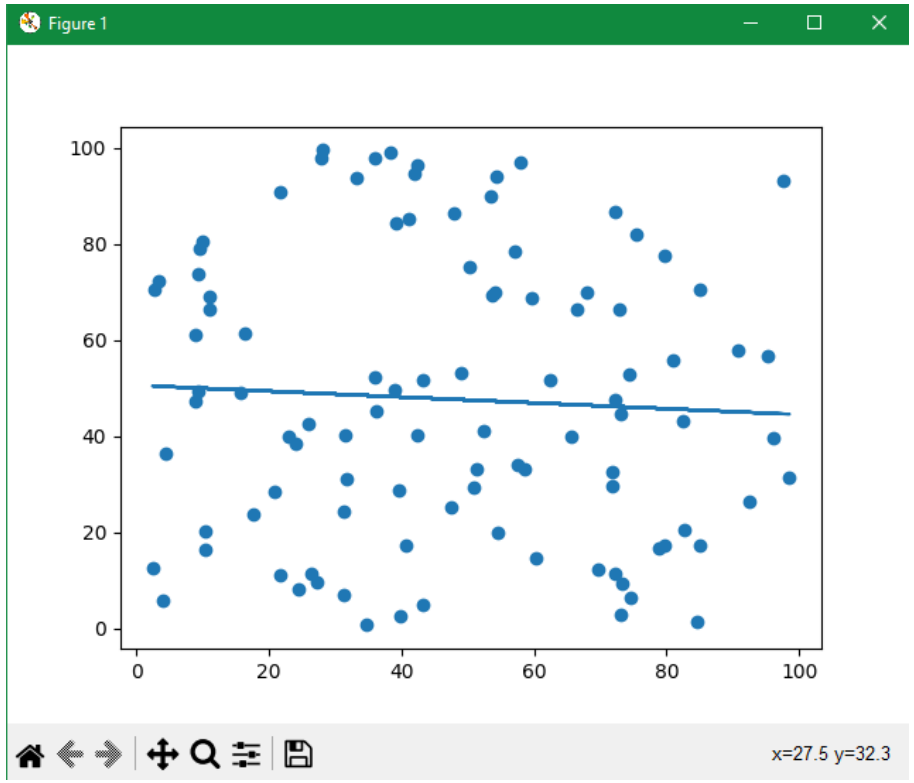

ten zestaw danych nie nadaje się do regresji liniowej.

```
-0.023567404078000325
```

współczynnik korelacji r Pearsona jest bliski zeru – słaba zależność liniowa między zmiennymi x oraz y

Scatter Plot, Linear Regression, r

Zadanie

Znajdź dane, które nadają się do przedstawienia w formie wykresu punktowego i zastosuj do nich regresję liniową (możesz skorzystać z danych ZUS) Wylicz współczynnik korelacji r Pearsona, oceń stopień zależności liniowej pomiędzy zmiennymi, znajdź nowe dane na podstawie regresji liniowej.

Dane pogodowe

mapa czujników wilgotności, temperatury, ciśnienia, zanieczyszczeń powietrza itp..

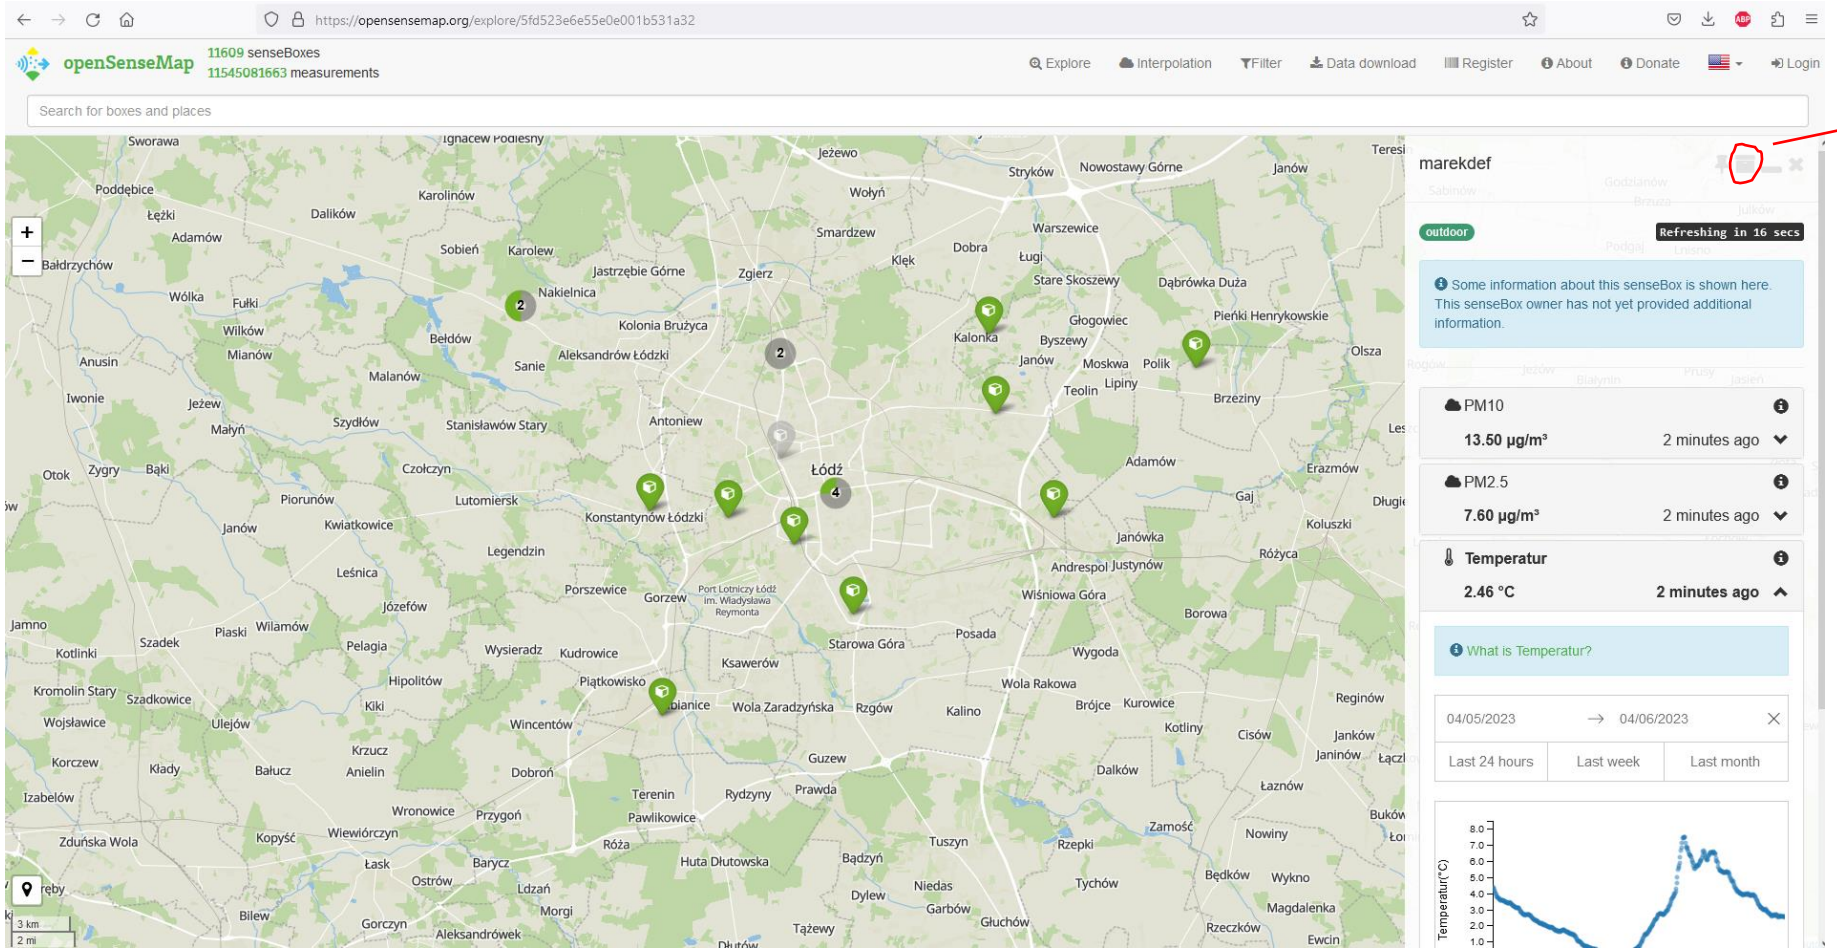

data, godzina

wartość temperatury

	A	B	C
1	createdAt	value	
2	2023-04-05T00:00:12.195Z	0.68	1
3	2023-04-05T00:03:18.825Z	0.65	2
4	2023-04-05T00:06:13.310Z	0.61	3
5	2023-04-05T00:09:04.477Z	0.58	4
6	2023-04-05T00:11:57.128Z	0.56	5
7	2023-04-05T00:14:47.522Z	0.55	6
8	2023-04-05T00:17:38.312Z	0.54	7
9	2023-04-05T00:20:29.546Z	0.51	8
10	2023-04-05T00:23:21.507Z	0.49	9
11	2023-04-05T00:26:12.169Z	0.51	10
12	2023-04-05T00:29:03.119Z	0.50	11
13	2023-04-05T00:31:53.710Z	0.48	12
14	2023-04-05T00:34:44.591Z	0.50	13
15	2023-04-05T00:37:35.309Z	0.51	14
16	2023-04-05T00:40:26.204Z	0.52	15
17	2023-04-05T00:43:16.870Z	0.51	16
18	2023-04-05T00:46:07.856Z	0.49	17
19	2023-04-05T00:48:58.693Z	0.43	18
20	2023-04-05T00:51:49.149Z	0.38	19
21	2023-04-05T00:54:40.249Z	0.34	20
22	2023-04-05T00:57:31.269Z	0.29	21
23	2023-04-05T01:00:23.195Z	0.25	22
24	2023-04-05T01:03:14.317Z	0.20	23
25	2023-04-05T01:06:11.030Z	0.12	24
26	2023-04-05T01:09:05.628Z	0.04	25

dane pobrane z jednego czujnika w Łodzi (temperatura w nocy 5.04.23)

https://opensensemap.org/

https://pl.wikipedia.org/wiki/Aproksymacja_wielomianowa

Polynomial Regression (Aproksymacja wielomianowa)

czas od 12.00 w nocy do 4.45 nad ranem (przeliczony na system dziesiętny)

wartości temperatur

określenie rozciągłości liczb po osi x – od 1 do 101

ponieważ dopasowanie modelu do danych jest dobre (R-Squared = 0.999) można na tej podstawie określić temperaturę w czasie późniejszym, niż pobrane dane (godzina ok. 4.48)

polynomialRegression.py > ...

```
1   import numpy
2   import matplotlib.pyplot as plt
3   from sklearn.metrics import r2_score
4
5   time = [
6   1,2,3,4,5,6,7,8,9,10,11,12,13,14,15,16,17,18,19,20,21,22,23,24,25,26,27,28,29,30,31,32,33,34,35,36,37,
7   38,39,40,41,42,43,44,45,46,47,48,49,50,51,52,53,54,55,56,57,58,59,60,61,62,63,64,65,66,67,68,69,70,71,
8   72,73,74,75,76,77,78,79,80,81,82,83,84,85,86,87,88,89,90,91,92,93,94,95,96,99,100,101]
9
10  temperature =[
11  0.68,0.65,0.61,0.58,0.56,0.55,0.54,0.51,0.49,0.51,0.50,0.48,0.50,0.51,0.52,0.51,0.49,0.43,0.38,0.34,0.29,0.25,
12  0.20,0.12,0.04,-0.01,-0.10,-0.16,-0.20,-0.24,-0.29,-0.32,-0.33,-0.33,-0.33,-0.32,-0.33,-0.31,-0.31,-0.31,-0.32,
13  -0.32,-0.33,-0.33,-0.33,-0.36,-0.39,-0.41,-0.43,-0.47,-0.53,-0.60,-0.68,-0.74,-0.77,-0.79,-0.82,-0.82,-0.82,
14  -0.82,-0.82,-0.81,-0.84,-0.84,-0.85,-0.91,-1.00,-1.04,-1.02,-1.06,-1.10,-1.12,-1.10,-1.09,-1.08,-1.07,-1.07,
15  -1.07,-1.09,-1.09,-1.14,-1.19,-1.22,-1.25,-1.26,-1.26,-1.25,-1.22,-1.16,-1.07,-0.97,-0.88,-0.80,-0.72,-0.69,
16  -0.63,-0.57,-0.31,0.24]
17
18  mymodel = numpy.poly1d(numpy.polyfit(time, temperature, 20))
19
20  myline = numpy.linspace(1, 101, 100)
21
22  plt.scatter(time, temperature)
23  plt.plot(myline, mymodel(myline))
24  plt.show()
25
26  print(r2_score(temperature, mymodel(time)))
27
28  temp = mymodel(102)
29  print(temp)
```

pip install scikit-learn

wyliczenie wielomianowego modelu

parametry określające dopasowanie modelu, czym większe, tym lepsze dopasowanie

time rozciąga się od 1 do 101

wyrysowanie diagramów

0.9990408357796161

R-Squared (R-Kwadrat) - określa stopień zależności wielomianowej pomiędzy zmiennymi:

- 0 oznacza brak zależności
- 1 oznacza 100% zależność

1.6768274722494845 – temperatura o godz. ok. 4.48

Polynomial Regression
(Aproksymacja wielomianowa)

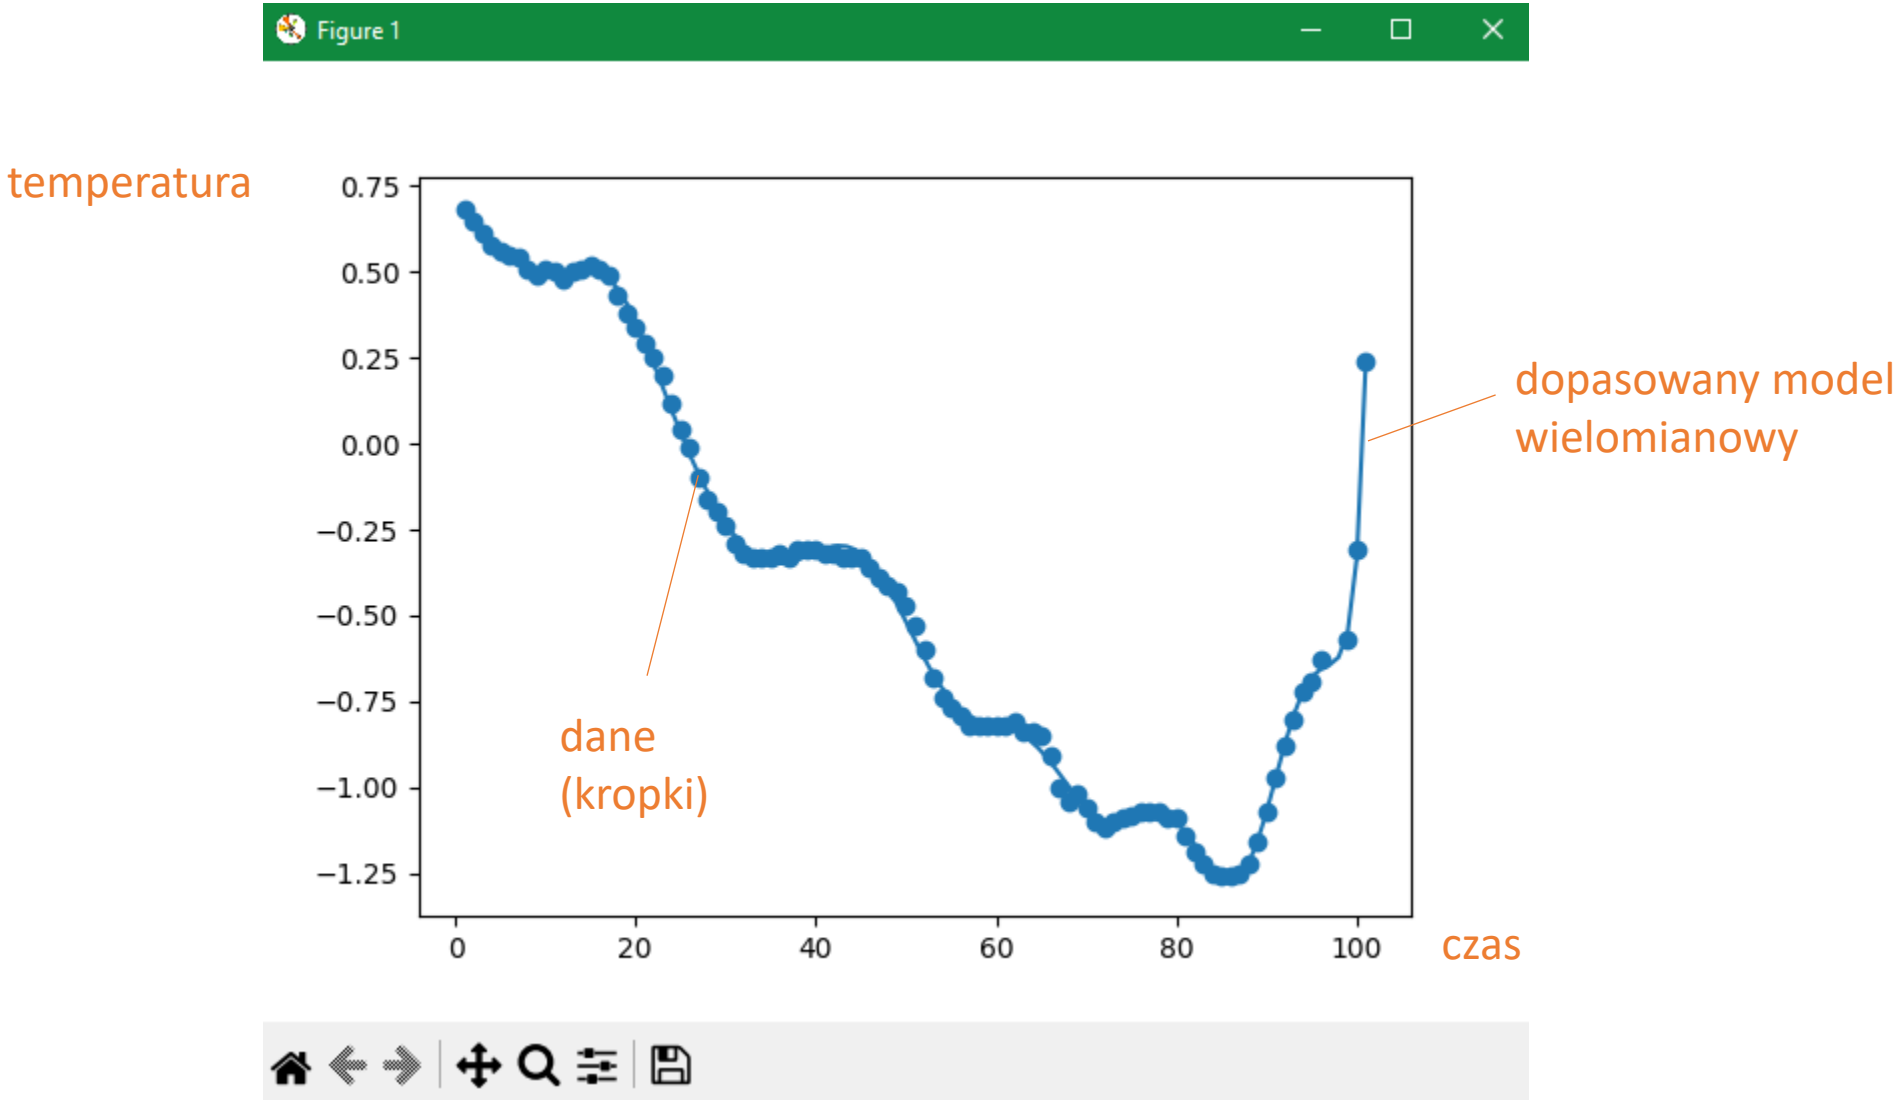

Polynomial Regression

Zadanie

Znajdź dane, które nadają się do przedstawienia w formie wykresu punktowego i zastosuj do nich regresję wielomianową.
Wylicz współczynnik korelacji R-Squared, oceń stopień zależności wielomianowej pomiędzy zmiennymi, znajdź nowe dane na podstawie wyliczonego modelu.

Multiple Regression
(Regresja wielokrotna)

Regresja wielokrotna jest podobna do regresji liniowej, ale z więcej niż jedną niezależną wartością, co oznacza, że próbujemy przewidzieć wartość na podstawie dwóch lub więcej zmiennych

import danych
w postaci pliku csv

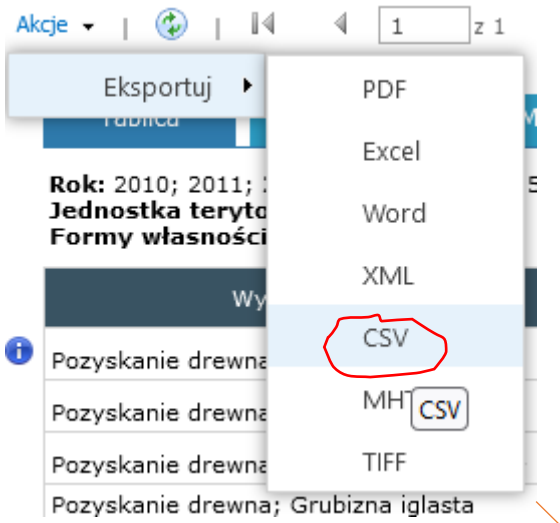

te dane zaimportujemu do słownika

dana na stronie Głównego Urzędu Statystycznego:
Użytkowanie lasu - pozyskanie drewna

SWAiD

GUS Zmień kontrast: Zmień czcionkę: Pomoc O Systemie

Strona główna | Statystyka Wielodziedzinowa | Gospodarka | Społeczeństwo | Środowisko

Użytkowanie lasu - pozyskanie drewna

Akcje | 1 z 1 | Znajdź Dalej

Tablica | Wykres | Mapa | Metadane

Rok: 2010; 2011; 2012; 2013; 2014; 2015; 2016; 2017; 2018; 2019; 2020; 2021
Jednostka terytorialna: POLSKA
Formy własności leśnej: Ogółem

Wyszczególnienie	2010	2011	2012	2013	2014	2015	2016	2017	2018	2019	2020	2021
Pozyskanie drewna; Ogółem [m³]	35 467 471	37 179 983	37 044 584	37 944 495	39 740 543	40 247 249	40 900 708	44 275 096	45 589 688	42 365 686	39 668 819	42 244 165
Pozyskanie drewna; Grubizna [m³]	33 568 291	34 877 069	34 977 961	35 796 037	37 661 503	38 327 082	39 129 329	42 698 966	43 931 540	40 637 873	38 064 321	40 691 613
Pozyskanie drewna; Grubizna iglasta [m³]	25 579 421	26 277 617	26 042 317	26 791 974	28 533 037	29 077 586	30 077 828	33 470 400	34 352 104	31 688 773	29 611 049	32 073 489
Pozyskanie drewna; Grubizna iglasta wielkowymiarowa [m³]	11 691 348	11 877 257	11 747 699	12 111 278	13 108 536	13 189 439	13 589 579	14 904 843	14 840 917	14 141 442	14 021 756	15 550 129
Pozyskanie drewna; Grubizna iglasta wielkowymiarowa ogólnego przeznaczenia [m³]	11 625 095	11 807 330	11 672 384	12 031 565	13 016 583	13 091 438	13 502 234	14 815 930	14 753 209	14 039 990	13 899 174	15 418 346
Pozyskanie drewna; Grubizna iglasta wielkowymiarowa specjalna [m³]	66 253	69 927	75 315	79 713	91 953	98 001	87 345	88 913	87 708	101 452	122 582	131 783
Pozyskanie drewna; Grubizna iglasta średniowymiarowa [m³]	12 523 720	12 832 631	12 661 021	13 026 932	13 729 067	14 154 665	14 822 316	16 738 496	17 687 342	15 978 810	14 215 003	15 231 518
Pozyskanie drewna; Grubizna iglasta średniowymiarowa dłużycowa [m³]	541 811	502 403	449 049	412 695	388 278	311 889	269 234	245 152	188 274	170 443	162 209	148 820
Pozyskanie drewna; Grubizna iglasta średniowymiarowa do przerobu przemysłowego [m³]	11 981 909	12 330 228	12 211 972	12 614 237	13 340 789	13 842 776	14 553 082	16 493 344	17 499 068	15 808 367	14 052 794	15 082 698
Pozyskanie drewna; Grubizna iglasta opałowa [m³]	1 364 383	1 567 727	1 633 598	1 653 764	1 695 433	1 733 481	1 665 931	1 827 061	1 823 848	1 568 520	1 374 291	1 291 837
Pozyskanie drewna; Grubizna liściasta [m³]	7 988 866	8 599 452	8 935 644	9 004 062	9 128 466	9 249 496	9 051 501	9 228 567	9 579 437	8 949 100	8 453 272	8 618 124
Pozyskanie drewna; Grubizna liściasta wielkowymiarowa [m³]	2 628 571	2 844 392	2 827 372	2 779 589	2 831 368	2 773 126	2 717 635	2 668 031	2 613 894	2 539 171	2 542 791	2 619 691
Pozyskanie drewna; Grubizna liściasta wielkowymiarowa ogólnego przeznaczenia [m³]	2 436 812	2 654 949	2 646 411	2 588 806	2 636 288	2 561 888	2 511 680	2 477 718	2 420 763	2 349 130	2 336 480	2 403 090
Pozyskanie drewna; Grubizna liściasta												

http://swaid.stat.gov.pl/Lesnictwo_dashboards/Raporty_predefiniowane/RAP_DBD_LES_6.aspx

https://www.w3schools.com/python/python_ml_multiple_regression.asp

Multiple Regression

Dane ze strony Urzędu Statystycznego „Użytkowanie lasu - pozyskanie drewna” zostały zaimportowane do słownika w module multiRegressionModule

słownik ma budowę:
wood = {
[klucz: wartość],
„years”:[2010,2011,…],
„ogółem”:[35467471,…],
„grubizna”:[33568291,..]
}

[42801232.27077913]

multipleRegression.py

programy > multipleRegression.py > ...

```python
import multipleRegressionModule as data # moduł do importu danych z pliku multipleRegression.txt

import pandas as pd
from sklearn import linear_model

# pobieramy dane o drewnie z pliku do słownika
wood = data.getData()

#print(wood)

# printujemy klucze ze słownika
woodKeys = wood.keys()
#print(woodKeys)
'''
dict_keys(['years', 'ogółem', 'grubizna', 'grubizna_iglasta', 'grubizna_iglasta_wielkowymiarowa', 'grubizna_iglasta_wielkowymiarowa_ogólnego_pr
zeznaczenia', 'grubizna_iglasta_wielkowymiarowa_specjalna', 'grubizna_iglasta_średniowymiarowa', 'grubizna_iglasta_średniowymiarowa_dłużycowa'
, 'grubizna_iglasta_średniowymiarowa_do_przerobu_przemysłowego', 'grubizna_iglasta_opałowa', 'grubizna_liściasta', 'grubizna_liściasta_wielkow
ymiarowa', 'grubizna_liściasta_wielkowymiarowa_ogólnego_przeznaczenia', 'grubizna_liściasta_wielkowymiarowa_specjalna', 'grubizna_liściasta_s
średniowymiarowa', 'grubizna_liściasta_średniowymiarowa_dłużycowa', 'grubizna_liściasta_średniowymiarowa_do_przerobu_przemysłowego', 'grubiz
na_liściasta_opałowa', 'drewno_małowymiarowe', 'drewno_małowymiarowe_do_przerobu_przemysłowego', 'drewno_małowymiarowe_opałowe', 'karpina'])
'''

# tworzymy obiekt DataFrame na podstawie danych w słowniku
df = pd.DataFrame(wood)
print(df)

# lista niezależnych zmiennych na podstawie których jest wyliczana zależna zmienna
X = df[['years', 'drewno_małowymiarowe_opałowe']]

# zmienna zależna, którą wyliczamy
y = df['ogółem']

# tworzymy obiekt liniowej regresji
regr = linear_model.LinearRegression()

# przekazujemy listy zależnych zmiennych i zmienną niezależną do obiektu regresji liniowej
regr.fit(X.values, y)

# sprawdzamy ile drewna będzie ogółem w roku 2024, jeśli Drewno małowymiarowe opałowe ma podaną wartość
predictedOgolem = regr.predict([[2024, 1785030]])

print(predictedOgolem)
```

```
pip install pandas
```

moduł Pandas jest używany do analizowania danych.
pandas tutorial

Multiple Regression

zawartość obiektu DataFrame (dane statystyczne dotyczące pozyskiwania drewna)

```
    years   ogółem  ...  drewno_małowymiarowe_opałowe  karpina
0    2010  35467471  ...                       1407841       70
1    2011  37179983  ...                       1785030       39
2    2012  37044584  ...                       1618597      133
3    2013  37944495  ...                       1692744     1556
4    2014  39740543  ...                       1654558     2224
5    2015  40247249  ...                       1512322      268
6    2016  40900708  ...                       1389381        0
7    2017  44275096  ...                       1239355      428
8    2018  45589688  ...                       1350067     7158
9    2019  42365686  ...                       1461952    11499
10   2020  39668819  ...                       1437412     4378
11   2021  42244165  ...                       1407423     1649

[12 rows x 23 columns]
[42801232.27077913]
```

wyliczona wartość
(ile drewna będzie ogółem w roku 2024, jeśli Drewna małowymiarowego opałowego pozyskano 1785030 m^3)

Multiple Regression

Zadanie

Znajdź dane, które mają wiele zmiennych.
Z pomocą Regresji Wielokrotnej spróbuj zbudować model oraz na jego podstawie przewidzieć nową wartość korzystając z dwóch lub więcej zmiennych.

Scale

skalowanie danych

Jeśli porównywane dane występują w różnych jednostkach np. metry i sekundy, albo mają dużą różnicę w wartościach np. 10000 oraz 1, można je przeskalować do wartości, które są łatwiejsze do porównania.

wzór na skalowanie danych metodą *standardization (normalizacja)*

$$z = (x - \mu) / \sigma$$

nowa, przeskalowana wartość

oryginalna wartość

średnia arytmetyczna danych

odchylenie standardowe danych

https://www.w3schools.com/python/python_ml_scale.asp

Scale

skalujemy dane

scale.py

programy > scale.py > ...

```python
import multipleRegressionModule as data # moduł do importu danych z pliku multipleRegression.txt

import pandas as pd
from sklearn import linear_model
from sklearn.preprocessing import StandardScaler
scale = StandardScaler()

# pobieramy dane o drewnie z pliku do słownika
wood = data.getData()

# tworzymy nowy słownik z 3 kluczami, których wartości bardzo się różnią
newWood = {'years':wood['years'],
           'ogółem':wood['ogółem'],
           'grubizna': wood['karpina']}

#print(newWood)

# skalujemy dane

# tworzymy obiekt DataFrame na podstawie danych w słowniku
df = pd.DataFrame(newWood)
print("dane przed skalowaniem: ")
print(df)

# lista zmiennych do przeskalowania
X = df[['years', 'ogółem','grubizna']]

# skalujemy wartości w kolumnach
print("dane po przeskalowaniu: ")
scaledX = scale.fit_transform(X)

print(scaledX)
```

biblioteki pomocne przy skalowaniu danych

```
dane przed skalowaniem:
    years    ogółem  grubizna
0    2010  35467471        70
1    2011  37179983        39
2    2012  37044584       133
3    2013  37944495      1556
4    2014  39740543      2224
5    2015  40247249       268
6    2016  40900708         0
7    2017  44275096       428
8    2018  45589688      7158
9    2019  42365686     11499
10   2020  39668819      4378
11   2021  42244165      1649
dane po przeskalowaniu:
[[-1.59325501 -1.63039318 -0.69447267]
 [-1.30357228 -1.04319552 -0.70351769]
 [-1.01388955 -1.08962204 -0.67609086]
 [-0.72420682 -0.78105449 -0.26089531]
 [-0.43452409 -0.16521343 -0.06598974]
 [-0.14484136  0.00852934 -0.63670126]
 [ 0.14484136  0.23259177 -0.71489691]
 [ 0.43452409  1.38962468 -0.59001729]
 [ 0.72420682  1.84038086  1.37362717]
 [ 1.01388955  0.7349133   2.64022161]
 [ 1.30357228 -0.18980664  0.5624932 ]
 [ 1.59325501  0.69324536 -0.23376025]]
```

Scale

scaleMultipleRegression.py

programy > scaleMultipleRegression.py > ...

```python
import multipleRegressionModule as data # moduł do importu danych z pliku multipleRegression.txt

import pandas as pd
from sklearn import linear_model
from sklearn.preprocessing import StandardScaler
scale = StandardScaler()


# pobieramy dane o drewnie z pliku do słownika
wood = data.getData()

# tworzymy obiekt DataFrame na podstawie danych w słowniku
df = pd.DataFrame(wood)
print("dane przed skalowaniem: ")
print(df)

# lista niezależnych zmiennych na podstawie których jest wyliczana zależna zmienna
X = df[['years', 'drewno_małowymiarowe_opałowe']]

# zmienna zależna, którą wyliczamy
y = df['ogółem']

# bierzemy same wartości bez nagłówków kolumn
X = X.values

# skalujemy wartości w kolumnach
print("dane po przeskalowaniu: ")
scaledX = scale.fit_transform(X)
print(scaledX)

# tworzymy obiekt liniowej regresji
regr = linear_model.LinearRegression()

# przekazujemy listy zależnych zmiennych i zmienną niezależną do obiektu regresji liniowej
regr.fit(scaledX, y)

# skalujemy parametry
scaled = scale.transform([[2024, 1785030]])

# sprawdzamy ile drewna będzie ogółem w roku 2024, jeśli Drewno małowymiarowe opałowe ma podaną wartość
predictedOgolem = regr.predict([scaled[0]])

print(predictedOgolem) # [42801232.27077918]
```

wyliczamy za pomocą skalowania ile drewna będzie ogółem w roku 2024, jeśli Drewna małowymiarowego opałowego pozyskano 1785030 m^3

```
dane przed skalowaniem:
    years   ogółem  ...  drewno_małowymiarowe_opałowe  karpina
0    2010  35467471  ...                       1407841       70
1    2011  37179983  ...                       1785030       39
2    2012  37044584  ...                       1618597      133
3    2013  37944495  ...                       1692744     1556
4    2014  39740543  ...                       1654558     2224
5    2015  40247249  ...                       1512322      268
6    2016  40900708  ...                       1389381        0
7    2017  44275096  ...                       1239355      428
8    2018  45589688  ...                       1350067     7158
9    2019  42365686  ...                       1461952    11499
10   2020  39668819  ...                       1437412     4378
11   2021  42244165  ...                       1407423     1649

[12 rows x 23 columns]
dane po przeskalowaniu:
[[-1.59325501 -0.57822374]
 [-1.30357228  1.88481055]
 [-1.01388955  0.79800742]
 [-0.72420682  1.28218539]
 [-0.43452409  1.03283181]
 [-0.14484136  0.10403445]
 [ 0.14484136 -0.69876706]
 [ 0.43452409 -1.67843291]
 [ 0.72420682 -0.95548645]
 [ 1.01388955 -0.22488033]
 [ 1.30357228 -0.38512588]
 [ 1.59325501 -0.58095327]]
[42801232.27077918]
```

wyliczona wartość przy użyciu skalowania danych jest prawie identyczna z tą wyliczoną bez skalowania

Scale

Zadanie

Znajdź dane, które mają wiele zmiennych.
Z pomocą Regresji Wielokrotnej i skalowania danych spróbuj zbudować model oraz na jego podstawie przewidzieć nową wartość korzystając z dwóch lub więcej zmiennych.

Train/Test

metoda ewaluacji (oceny) modelu polegająca na podziale zbioru danych na dwie części: dane treningowe(*training set*) oraz testowe(*testing set*)

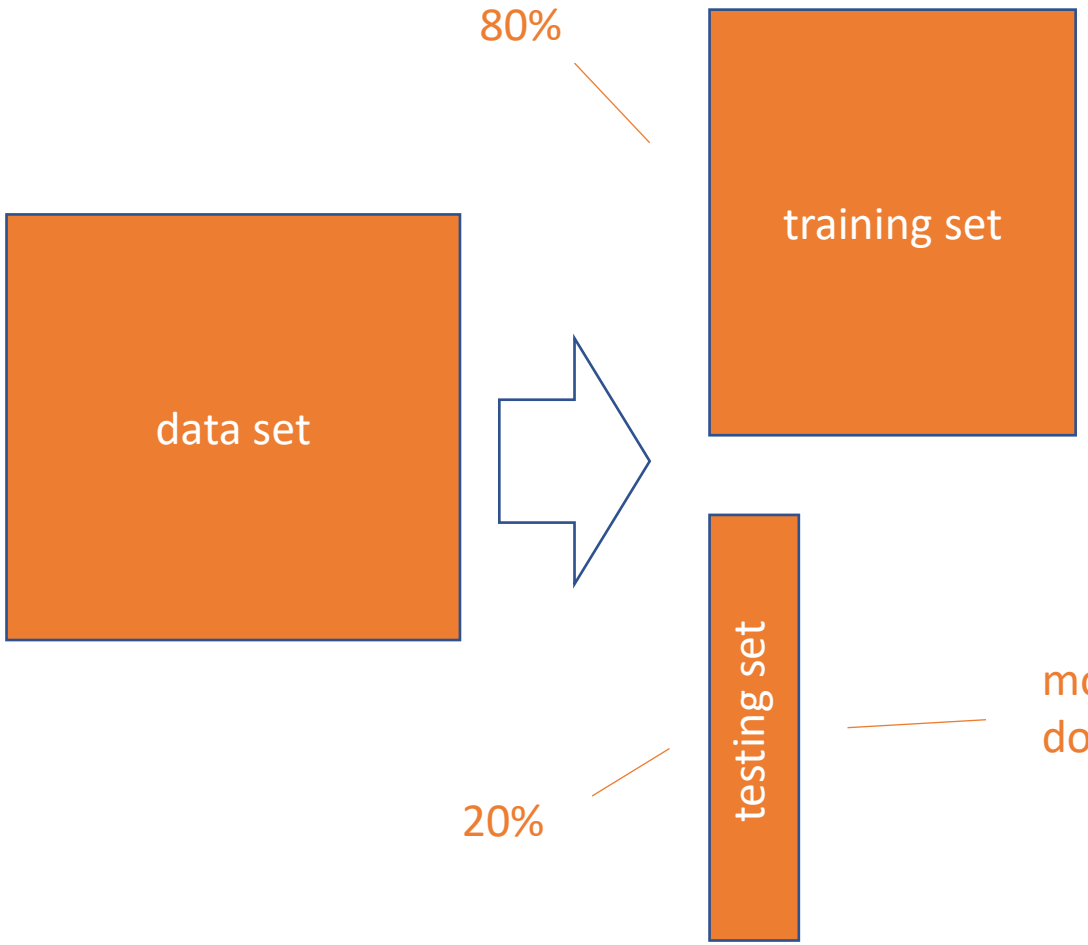

model jest trenowany (czyli tworzony) za pomocą zestawu treningowego (uczącego).

model jest testowany (czyli sprawdzany pod kątem dokładności) za pomocą zestawu testowego.

Train/Test

trainTest.py > ...

```python
import numpy
import matplotlib.pyplot as plt
from sklearn.metrics import r2_score
numpy.random.seed(2)

# ile cm rośnie drzewo/rok
x = numpy.random.normal(3, 1, 100)
# wiek drzewa w latach
y = numpy.random.normal(250, 50, 100) / x

plt.scatter(x, y)
plt.show()
```

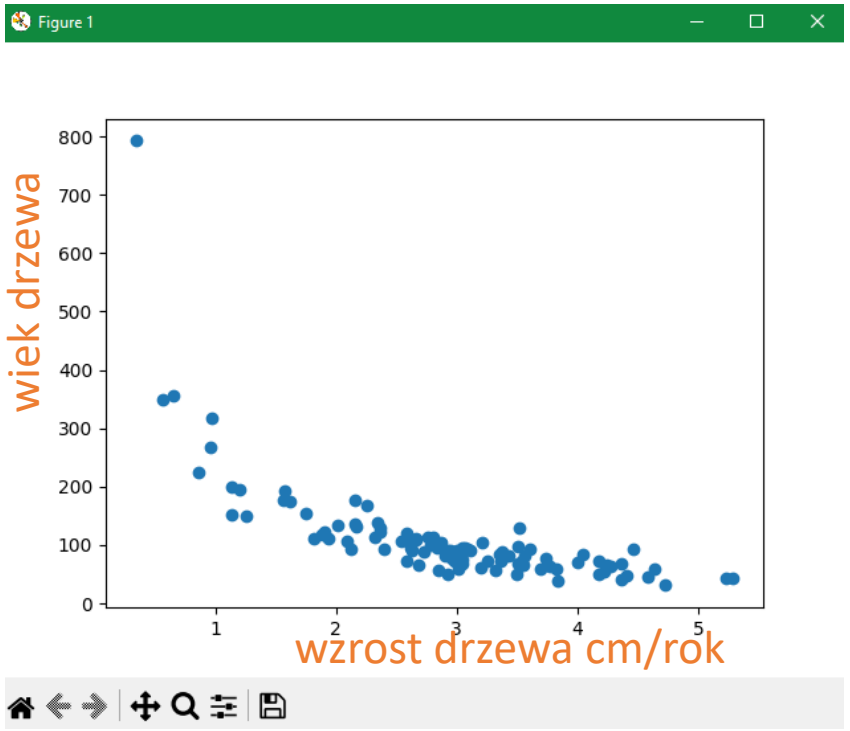

Uwaga! Dane są losowe i nie mają nic wspólnego z rzeczywistością!

https://www.w3schools.com/python/python_ml_train_test.asp

Train/Test

```
14    # tworzymy zbiór treningowy (uczący),
15    # który stanowi losowy wybór 80% oryginalnych danych
16    train_x = x[:80]
17    train_y = y[:80]
18
19    # wykres punktowy danych treningowych
20    plt.scatter(train_x, train_y)
21    plt.show()
22
23    # tworzymy zbiór testowy z pozostałych 20% danych
24    test_x = x[80:]
25    test_y = y[80:]
26
27    # wykres punktowy danych testowych
28    plt.scatter(test_x, test_y)
29    plt.show()
30
```

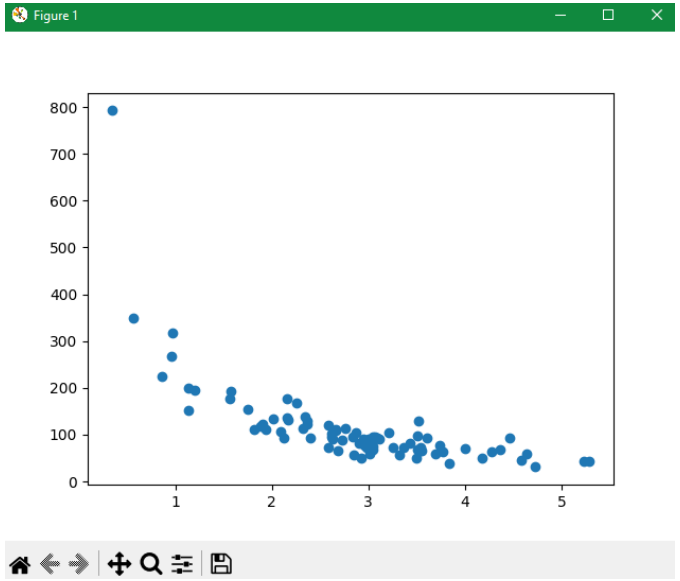

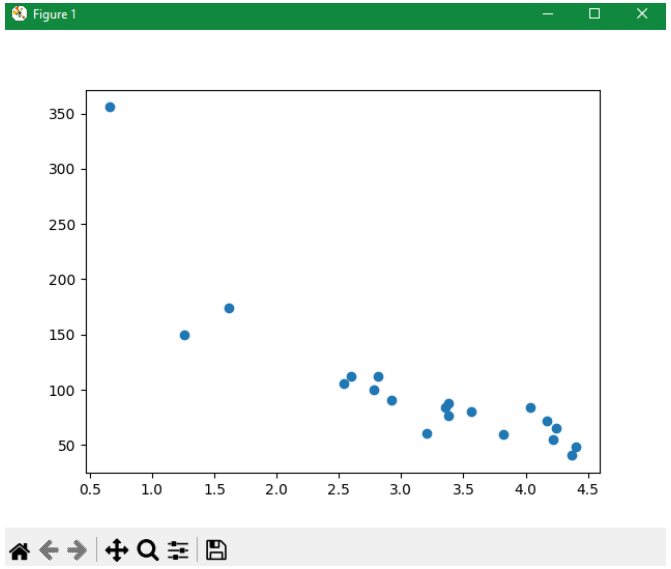

Train/Test

```
31  # tworzymy model - do aproksymacji danych używamy regresji wielomianowej
32  mymodel = numpy.poly1d(numpy.polyfit(train_x, train_y, 4))
33
34  # zakładamy, że x zmienia sie od 0 do 5
35  myline = numpy.linspace(0, 6, 100)
36
37  # wykres punktowy oraz modelu (krzywej aproksymującej dane)
38  plt.scatter(train_x, train_y)
39  plt.plot(myline, mymodel(myline))
40  plt.show()
41  # sprawdzamy poprawność modelu za pomocą
42  # współczynnika R-Kwadrat
43  # dane uczące
44  r2Train = r2_score(train_y, mymodel(train_x))
45  print(r2Train)
46
47  # dane testowe
48  r2Test = r2_score(test_y, mymodel(test_x))
49  print(r2Test)
```

0.8584727159228092

0.8663387182032407

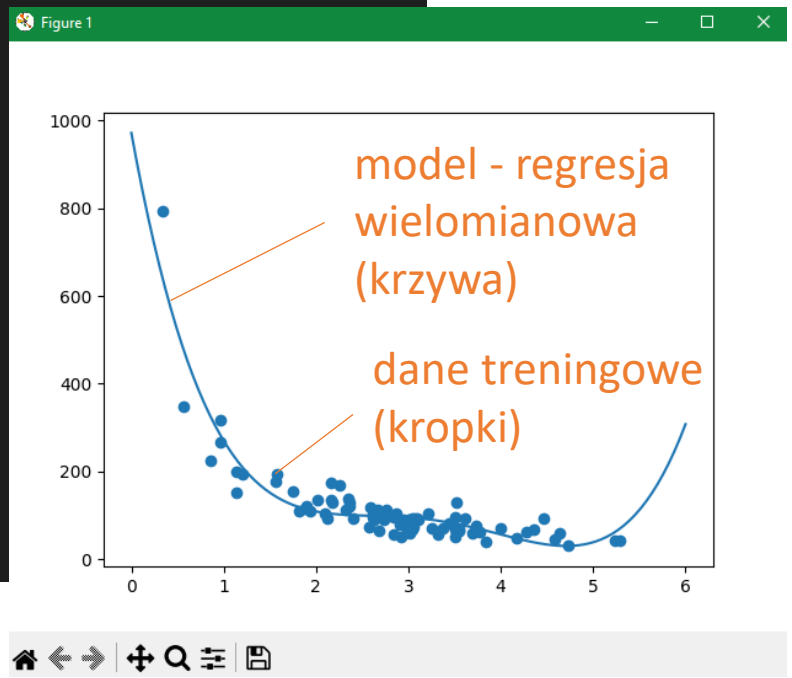

R2 (R-squared) zarówno danych testowych jak i treningowych jest bliski jedności, czyli regresja wielomianowa jest dobrze dopasowana – model jest OK

Train/Test

```
50
51    print(mymodel(0.5))
```

```
520.1426166298984
```

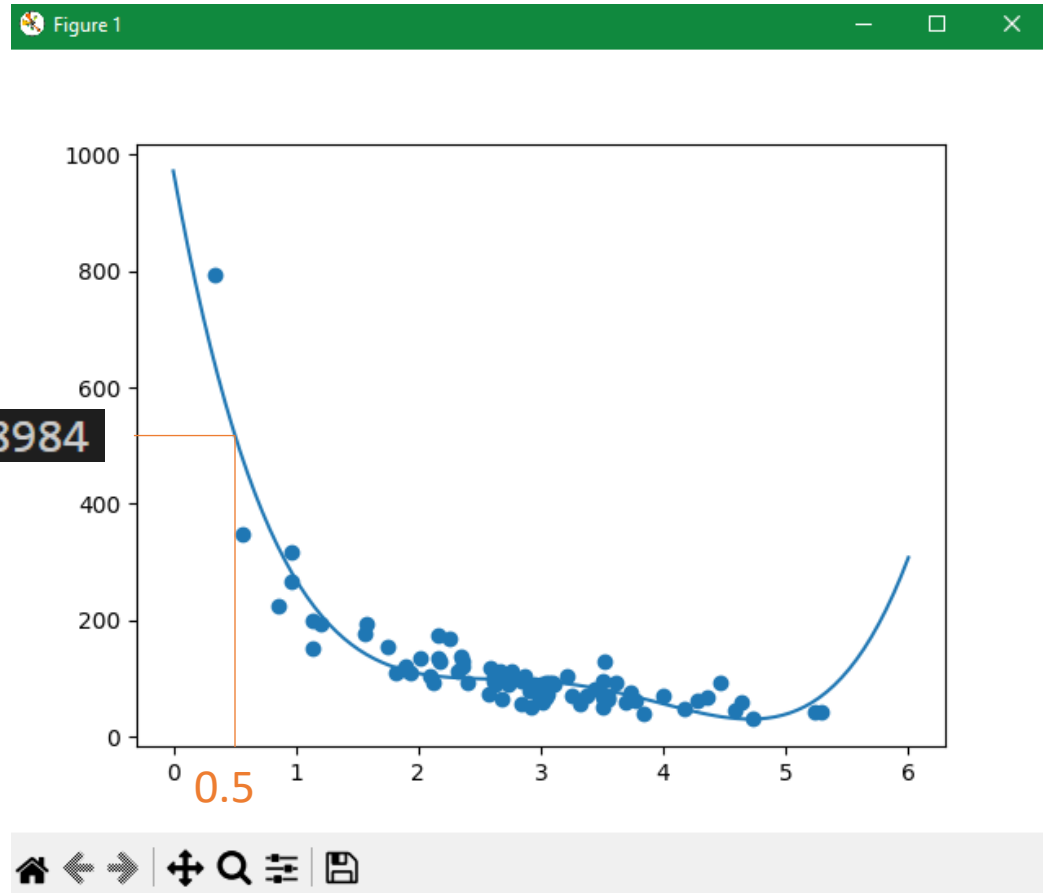

ponieważ model dobrze odwzorowuje dane,
można przewidzieć, że dla drzewa mającego ok.
520 lat jego wzrost wyniesie 0.5 cm/rok

Train/Test

Zadanie

Podziel dane na część treningowa oraz testową, zbuduj model korzystając z aproksymacji liniowej lub wielomianowej, określ stopień odwzorowania modelu za pomocą współczynnika korelacji r lub R-Kwadrat oraz (jeśli model dobrze odwzorowuje dane) wylicz nową, nieznaną wcześniej wartość.

Titanic

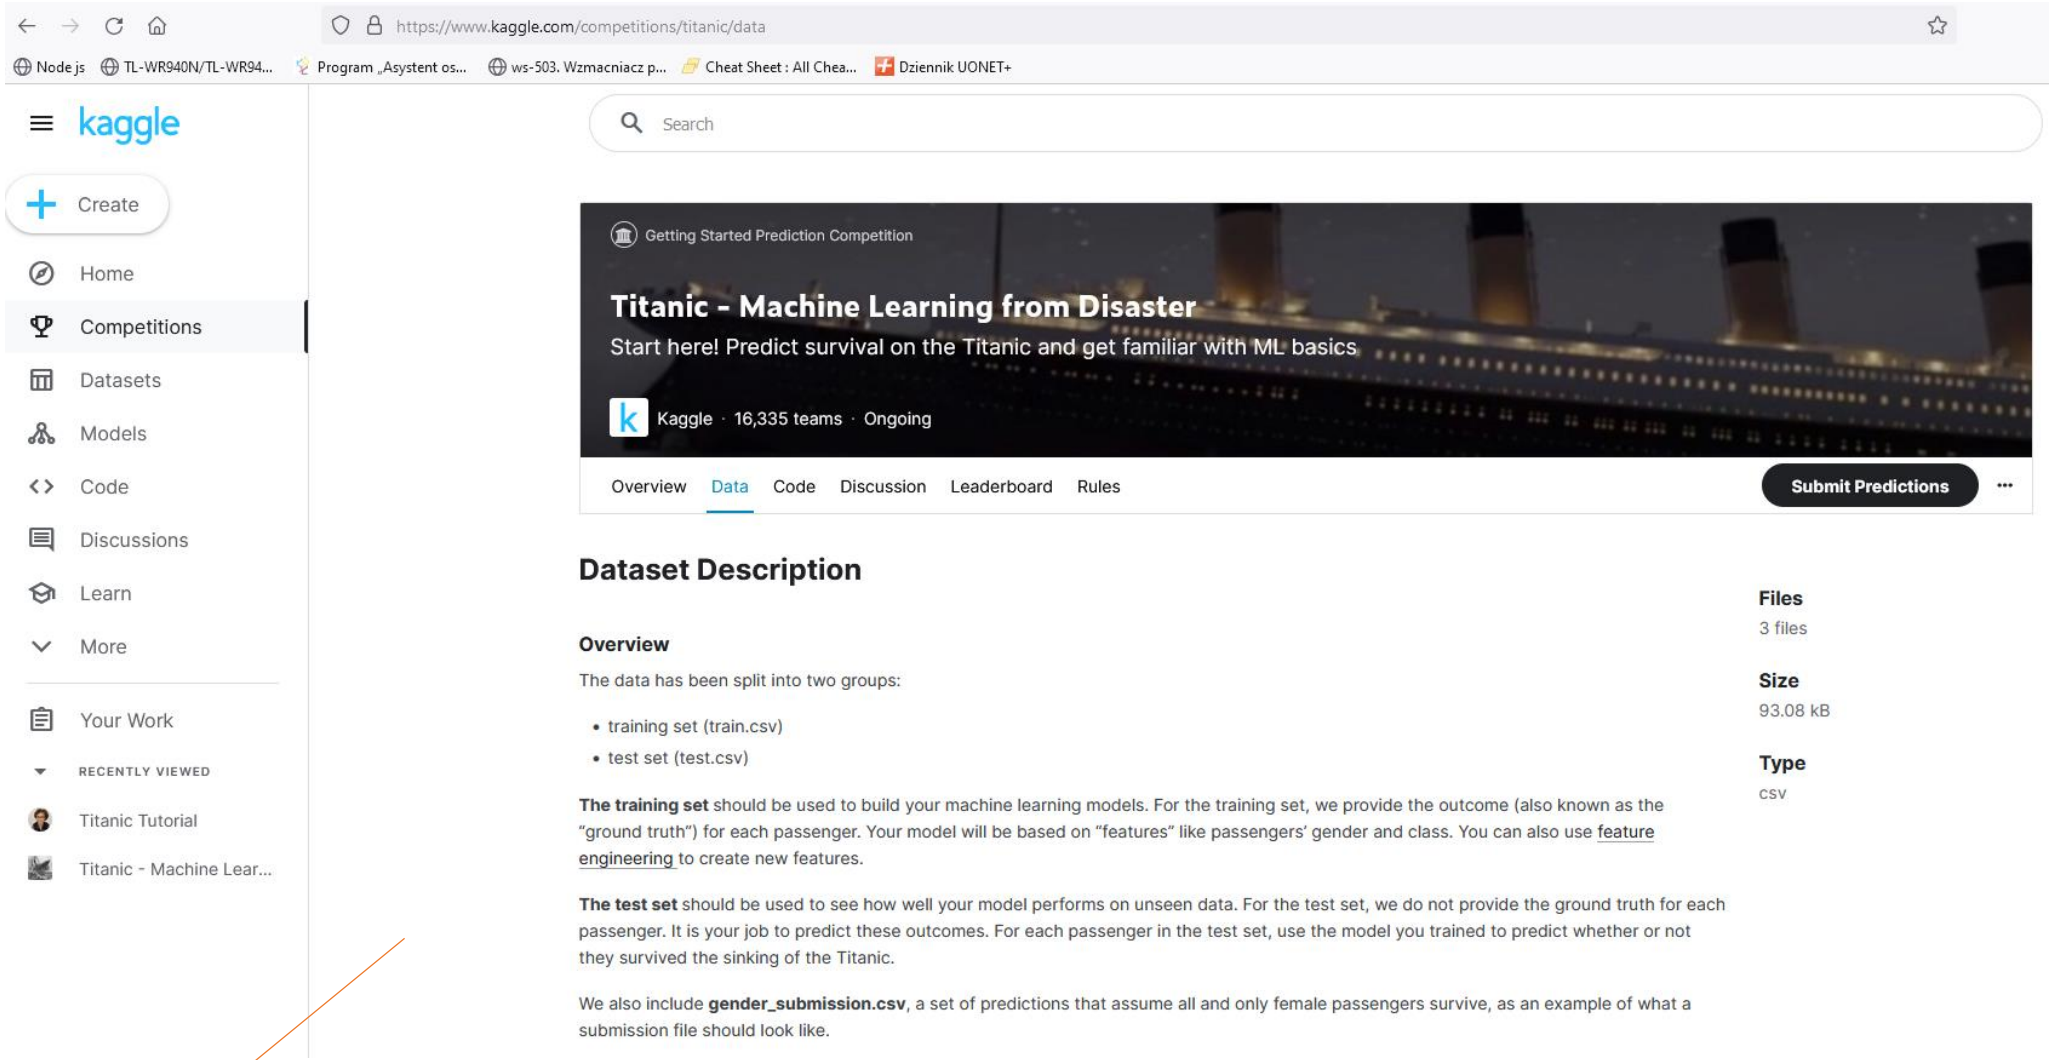

dane dotyczące pasażerów Titanica można pobrać ze strony Kaggle (po zalogowaniu)

Image Source: Kaggle

Titanic

opis danych dotyczących pasażerów Titanica

Data Dictionary

Variable	Definition	Key
survival	Survival	0 = No, 1 = Yes
pclass	Ticket class	1 = 1st, 2 = 2nd, 3 = 3rd
sex	Sex	
Age	Age in years	
sibsp	# of siblings / spouses aboard the Titanic	
parch	# of parents / children aboard the Titanic	
ticket	Ticket number	
fare	Passenger fare	
cabin	Cabin number	
embarked	Port of Embarkation	C = Cherbourg, Q = Queenstown, S = Southampton

Variable Notes

pclass: A proxy for socio-economic status (SES)
1st = Upper
2nd = Middle
3rd = Lower
age: Age is fractional if less than 1. If the age is estimated, is it in the form of xx.5
sibsp: The dataset defines family relations in this way...
Sibling = brother, sister, stepbrother, stepsister
Spouse = husband, wife (mistresses and fiancés were ignored)
parch: The dataset defines family relations in this way...
Parent = mother, father
Child = daughter, son, stepdaughter, stepson
Some children travelled only with a nanny, therefore parch=0 for them.

Image Source: Kaggle

Titanic

titanic > titanic.py > ...

```
50
51  # import danych
52  df = pd.read_csv("titanicData/train.csv")
53  #print(df)
54
55  # printujemy klucze
56  keys = df.keys()
57  #print(keys)
58  #['PassengerId', 'Survived', 'Pclass', 'Name', 'Sex', 'Age', 'SibSp',
59  #       'Parch', 'Ticket', 'Fare', 'Cabin', 'Embarked'],
60
61  # zmieniamy wartości typu string w kolumnie płeć 'Sex' na wartości typu integer
62  # tworzymy lista zmiennych niezależnych
63  X = transformSexFromCategoricalToNumerical()
64
65  # usuwamy puste wartości w kolumnie 'Age'
66  X = removeNanFromAge(X)
67
68  # zmienna zależna, którą wyliczamy
69  # (czy przeżył)
70  y = df['Survived']
71
72  # tworzymy obiekt liniowej regresji
73  regr = linear_model.LinearRegression()
74
75  # przekazujemy listy zależnych zmiennych i zmienną niezależną do obiektu regresji liniowej
76  regr.fit(X.values, y)
77
78  # przewidujemy, czy dla podanych parametrów osoba przeżyłaby na Titanicu:
79  # klasa biletu -  1,2,3
80  # wiek - np.20
81  # kobieta - 0 lub 1
82  # mężczyzna - 0 lub 1
83  predicted = regr.predict([[1, 20, 1, 0]])
84
85  print(predicted) # [0.9875129]
```

program analizujący czy pasażer przeżył w zależności od płci, wieku oraz klasy biletu. Program korzysta z Multiple Regression.

przy założeniu, że pasażerem byłaby kobieta w wieku 20 lat w klasie 1, miałaby duże szanse przeżycia

Titanic

titanic > titanic.py > ...

```python
import pandas as pd
from sklearn import linear_model
import numpy as np

# wypełnia puste wartości (NaN) w kolumnie 'Age'
# wartościami randomowymi w zakresie
# <średnia - odchylenie standardowe, średnnia + odchylenie standardowe>
def removeNanFromAge(X):
    # w kolumnie 'Age' są puste wartości NaN w ilości:
    ageNanCount = X['Age'].isnull().sum() # 177

    # średnia
    ageMean = df['Age'].mean()
    # odchylenie standardowe
    ageStd = df['Age'].std()

    # tworzymy tablicę o wielkości ageNanCount z wartościami randomowymi  w zakresie
    # <średnia - odchylenie standardowe, średnnia + odchylenie standardowe>
    randomTab = np.random.randint(ageMean - ageStd, ageMean + ageStd, size=ageNanCount)

    # wymieniamy wartości NaN w kolumnie 'Age' na te z tablicy randomTab
    X.loc[X['Age'].isnull(), 'Age'] = randomTab

    # sprawdzamy, czy zostały wartości NaN w kolumnie 'Age'
    # print("Pozostałe wartości NaN: {}".format(X['Age'].isnull().sum()))

    # zwracamy X
    return X
```

dane pasażerów Titanica nie są kompletne, np. kolumna Age ma puste wartości, które wypełniamy wartościami randomowymi

Titanic

```
29
30  # zmiana wartości typu string w kolumnie płeć 'Sex' na wartości typu integer
31  # za pomocą metody One Hot Encoding
32  def transformSexFromCategoricalToNumerical():
33      # kolumna 'Sex' ma wartości typu string: 'female', 'male'
34      # zamieniamy ją na dwie kolumny Sex_female, Sex_male z wartościami 1 oraz 0
35      # Sex       =>  Sex_female      Sex_male
36      # 'female'          1               0
37      # 'male'            0               1
38      sex_female_male = pd.get_dummies(df[['Sex']],dtype=int)
39
40      # print(sex_female_male.to_string())
41
42      # tworzymy listę niezależnych zmiennych 'Pclass','Age'
43      # oraz Sex_female, Sex_male
44      X = pd.concat([df[['Pclass','Age']], sex_female_male], axis=1)
45
46      #print(X)
47
48      return X
49
50
```

zamiana danych typu string dane typu numerycznego w kolumnie płeć

Categorical Data

Decision Tree

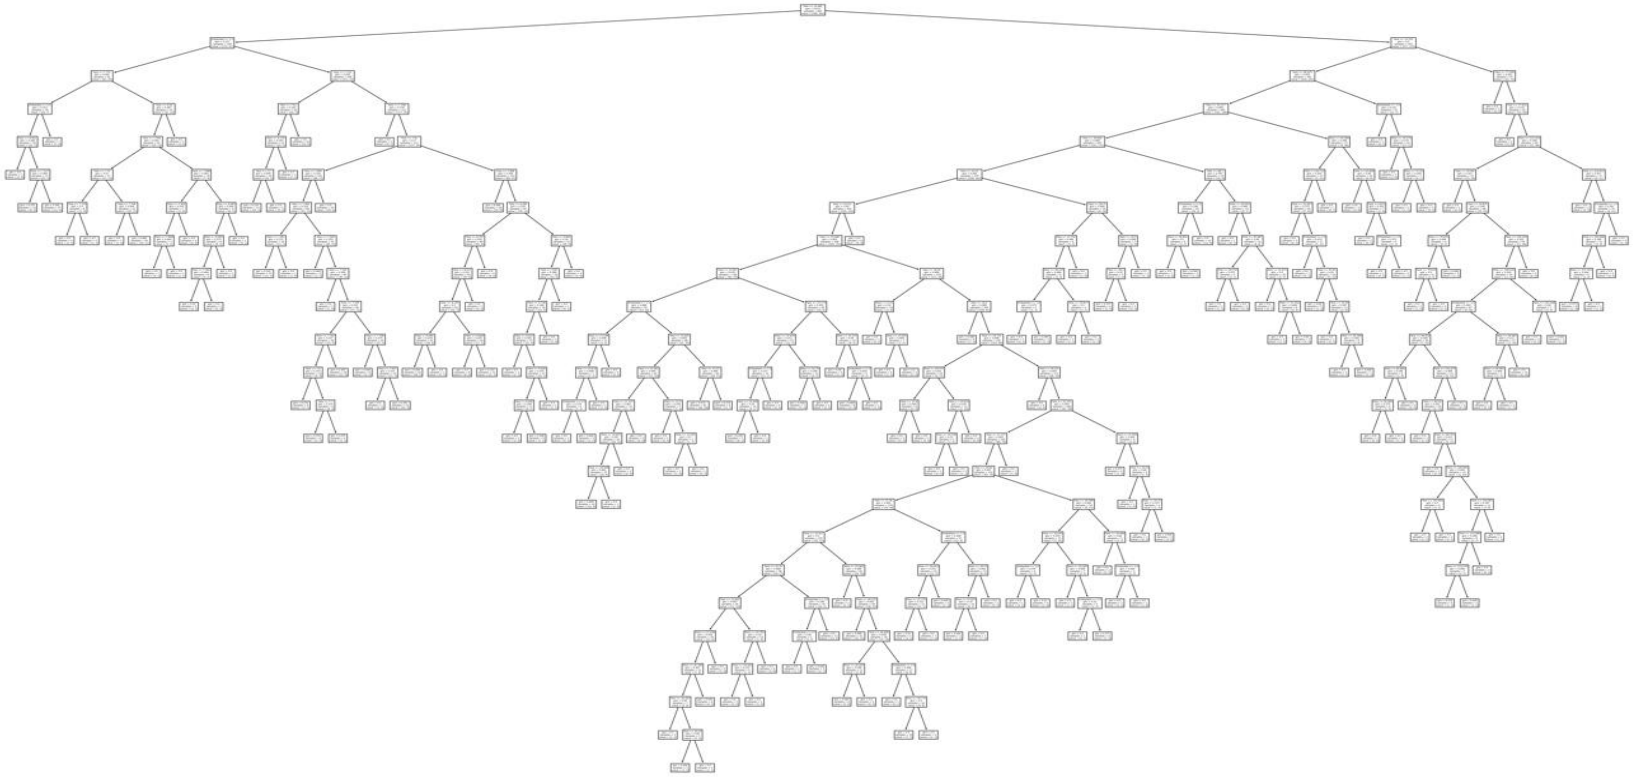

Drzewo decyzyjne to schemat blokowy, który może pomóc w podejmowaniu decyzji na podstawie wcześniejszych doświadczeń. Stosowane jest w uczeniu maszynowym do pozyskiwania wiedzy na podstawie danych.

https://pl.wikipedia.org/wiki/Drzewo_decyzyjne

https://www.w3schools.com/python/python_ml_decision_tree.asp

Decision Tree

tworzymy drzewo decyzyjne na podstawie danych pasażerów z Titanica

zakładamy, że zmiennymi niezależnymi są:'Fare’ (oplata) , 'Embarked’ (miejsce zaokrętowania), a zmienną zależną 'Survived’ (czy pasażer przeżył)

titanic > titanicDecisionTree.py > ...

```python
import pandas as pd
from sklearn import tree
from sklearn.tree import DecisionTreeClassifier
import matplotlib.pyplot as plt
import numpy as np


# import danych
df = pd.read_csv("titanicData/train.csv")
#print(df)

# zamiana stringów w kolumnie 'Embarked' - port zaokrętowania - na wartości liczbowe
# C = Cherbourg, Q = Queenstown, S = Southampton
d = {'C': 0, 'Q': 1, 'S': 2}
df['Embarked'] = df['Embarked'].map(d)
# print(df['Embarked'])

# tworzymy listę niezależnych zmiennych 'Fare','Embarked'
X = df[['Fare','Embarked']]
# print(X)

# zmienna zależna, którą wyliczamy
# (czy przeżył)
y = df['Survived']

embarkedNanCount = X['Embarked'].isnull().sum() # 2

# print(embarkedNanCount)

# wymieniamy wartości NaN w kolumnie 'Embarked' na te z tablicy [0,1] - zahardkodowane wartości
X.loc[X['Embarked'].isnull(), 'Embarked'] = [0,1]

# sprawdzamy czy zostały NaN
# print(X['Embarked'].isnull().sum())

# printujemy Decision Tree do pliku tree.png
features = ['Fare','Embarked']

dtree = DecisionTreeClassifier()
dtree = dtree.fit(X, y)

plt.figure(figsize=(50,30))

tree.plot_tree(dtree, feature_names=features)

plt.savefig('tree.png', dpi=300)

plt.clf()
```

mapowanie zaokrętowania:
0 = Cherbourg,
1 = Queenstown,
2 = Southampton

Decision Tree

pasażerowie, którzy zaokrętowali się w 0 (Cherbourg) lub 1 (Queenstown) są rozpatrywani dalej po lewej (True)

pasażerowie, którzy płacili poniżej 10.481 są rozpatrywani po lewej (True), reszta po prawej (False)

obliczenie współczynnika gini

$$gini = 1 - (x/n)^2 - (y/n)^2 =$$
$$= 1 - (549/891)^2 - (342/891)^2 =$$
$$= 1 - 0.379 - 0.147 = 0.473$$

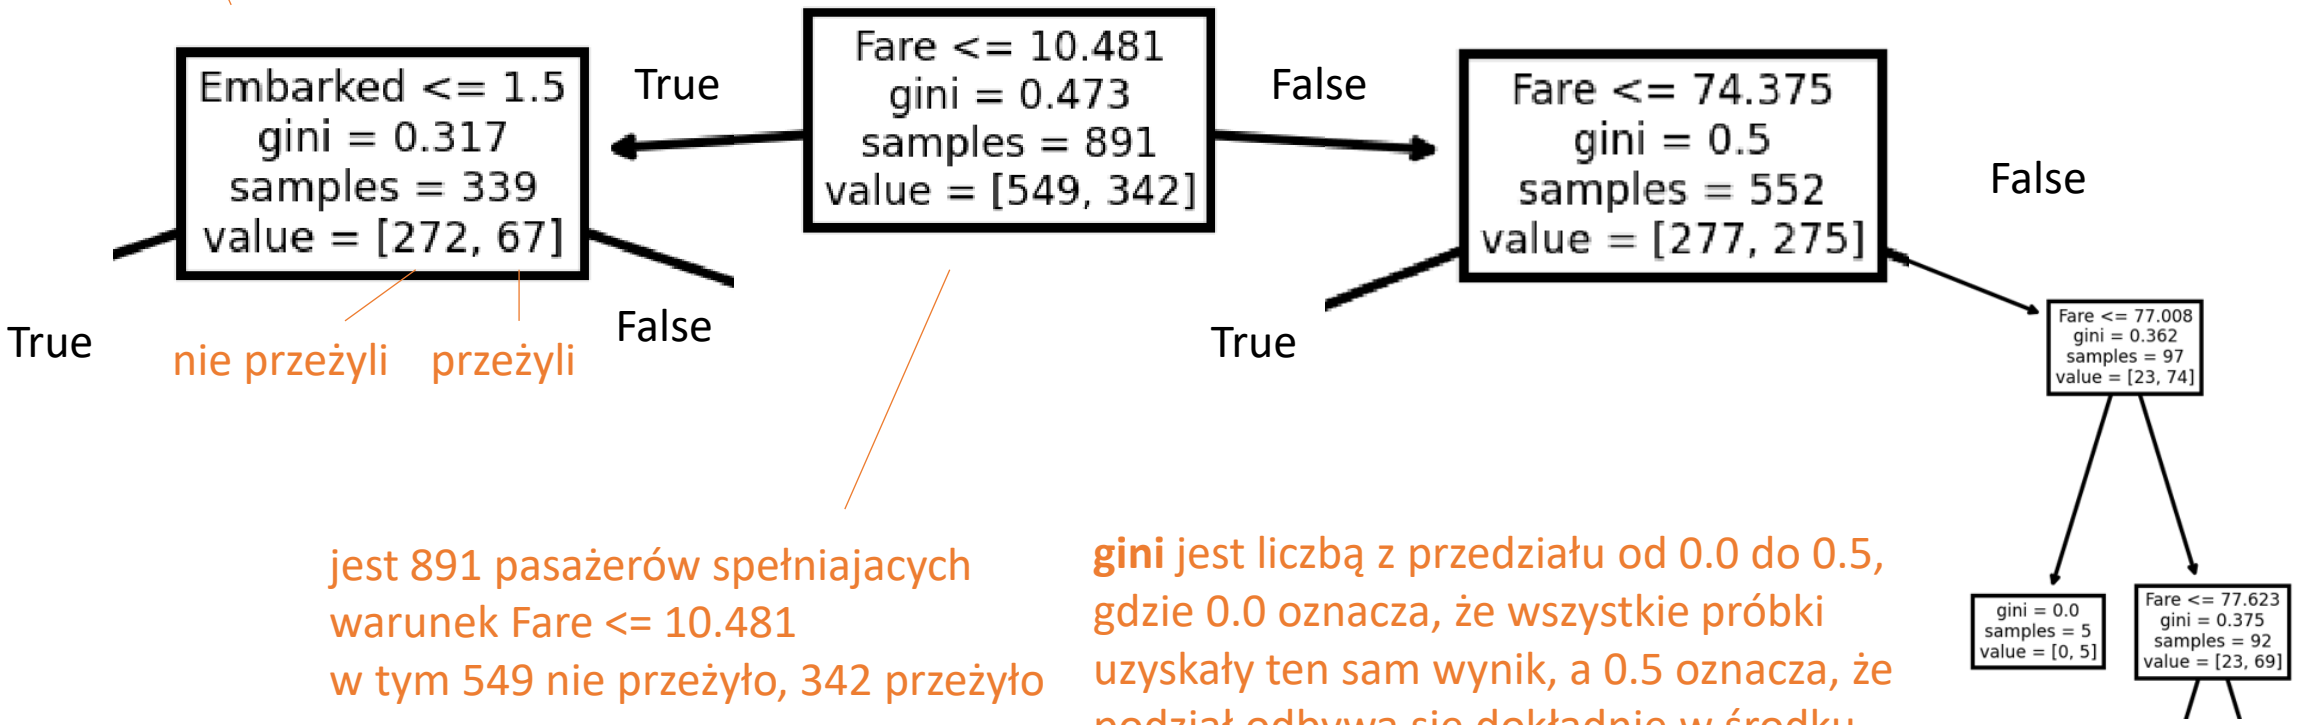

jest 891 pasażerów spełniajacych warunek Fare <= 10.481
w tym 549 nie przeżyło, 342 przeżyło

gini jest liczbą z przedziału od 0.0 do 0.5, gdzie 0.0 oznacza, że wszystkie próbki uzyskały ten sam wynik, a 0.5 oznacza, że podział odbywa się dokładnie w środku.

Decision Tree

po stworzeniu drzewa decyzyjnego można na jego podstawie przewidzieć przeżycie pasażera o założonych parametrach

```
51
52   # przewidujemy, czy ktoś przeżyje w zależności od zapłaconej
53   # sumy za bilet oraz portu zaokrętowania
54   print(dtree.predict([[80000, 1]]))
55   print("[1] -  przeżył")
56   print("[0]  - nie przeżył")
```

```
[1]
[1] -  przeżył
[0]  - nie przeżył
```

osoba płacąca 80000 oraz zaokrętowana w Queenstown najprawdopodobniej by przeżyła.

Titanic

Zadanie

Przeanalizuj dane pasażerów Titanica według własnego pomysłu.

Analiza danych pasażerów Titanica w Internecie:

https://ttsteiger.github.io/projects/titanic_report.html#Feature-description

https://betterprogramming.pub/titanic-survival-prediction-using-machine-learning-4c5ff1e3fa16

https://medium.com/@melodyyip_/titanic-survival-prediction-using-machine-learning-89a779656113

https://www.analyticsvidhya.com/blog/2021/05/titanic-survivors-a-guide-for-your-first-data-science-project/

Confusion Matrix

tabela z wizualną oceną dotyczącą błędów w modelu.

rzeczywisty stan pacjentów

numer pacjenta

stan zdrowia:
1: chory
0: zdrowy

1	2	3	4	5	6	7	8	9	10
1	1	1	1	1	1	1	0	0	0

przewidywany stan pacjentów (przykład działania hipotetycznego modelu))

numer pacjenta

stan zdrowia:
1: chory
0: zdrowy

1	2	3	4	5	6	7	8	9	10
1	1	0	0	1	1	1	1	0	0
TP	TP	FN	FN	TP	TP	TP	FP	TN	TN

TP: True Positive
TN: True Negative

FP: False Positive
FN: False Negative

https://en.wikipedia.org/wiki/Confusion_matrix

Confusion Matrix

		Predicted condition	
	Total population = P + N	**Positive (PP)**	**Negative (PN)**
Actual condition	**Positive (P)**	**True positive (TP)**	**False negative (FN)**
	Negative (N)	**False positive (FP)**	**True negative (TN)**

tabela z wizualną oceną dotyczącą błędów w modelu (Confusion Matrix wg. wikipedii)

		Przewidywany stan pacjenta	
	Wszyscy 7+3=10	**Chory** 6	**Zdrowy** 4
Rzeczywisty stan pacjenta	**Chory** 7	5	2
	Zdrowy 3	1	2

https://en.wikipedia.org/wiki/Confusion_matrix

wartości prawdziwe

wartości błędne

Confusion Matrix

Wskaźniki wydajności

dokładność modelu
Accuracy = (True Positive + True Negative) / Total Predictions

jakość pozytywnych prognoz
Precision = True Positive / (True Positive + False Positive)

na ile model jest dokładny w przewidywaniu pozytywnych prognoz TP
Sensitivity (Recall) = True Positive / (True Positive + False Negative)

# na ile model jest dokładny w przewidywaniu negatywnych prognoz
Specificity = True Negative / (True Negative + False Positive)

średnia harmoniczna Precision oraz Sensitivity
F-score = 2 * ((Precision * Sensitivity) / (Precision + Sensitivity))

Confusion Matrix

confusionMatrix.py > ...

```python
import matplotlib.pyplot as plt
from sklearn import metrics

actual = [1,1,1,1,1,1,1,0,0,0]
predicted = [1,1,0,0,1,1,1,1,0,0]

confusion_matrix = metrics.confusion_matrix(actual, predicted)

cm_display = metrics.ConfusionMatrixDisplay(confusion_matrix = confusion_matrix, display_labels = [False, True])

cm_display.plot()
plt.show()

# Wskaźniki wydajności
Accuracy = metrics.accuracy_score(actual, predicted)
Precision = metrics.precision_score(actual, predicted)
Sensitivity_recall = metrics.recall_score(actual, predicted)
Specificity = metrics.recall_score(actual, predicted, pos_label=0)
F1_score = metrics.f1_score(actual, predicted)

print("\nAccuracy: " + str(Accuracy) +
      "\nPrecision: " + str(Precision) +
      "\nSensitivity_recall: " + str(Sensitivity_recall) +
      "\nSpecificity: " + str(Specificity) +
      "\nF1_score: " + str(F1_score))
```

lista z rzeczywistym stanem zdrowia pacjentów

lista z przewidywanym stanem zdrowia pacjentów

wskaźniki wydajności

```
Accuracy: 0.7
Precision: 0.8333333333333334
Sensitivity_recall: 0.7142857142857143
Specificity: 0.6666666666666666
F1_score: 0.7692307692307692
```

https://www.w3schools.com/python/python_ml_confusion_matrix.asp

Confusion Matrix

tabela z wizualną oceną dotyczącą błędów w modelu (Confusion Matrix wg. w3schools)

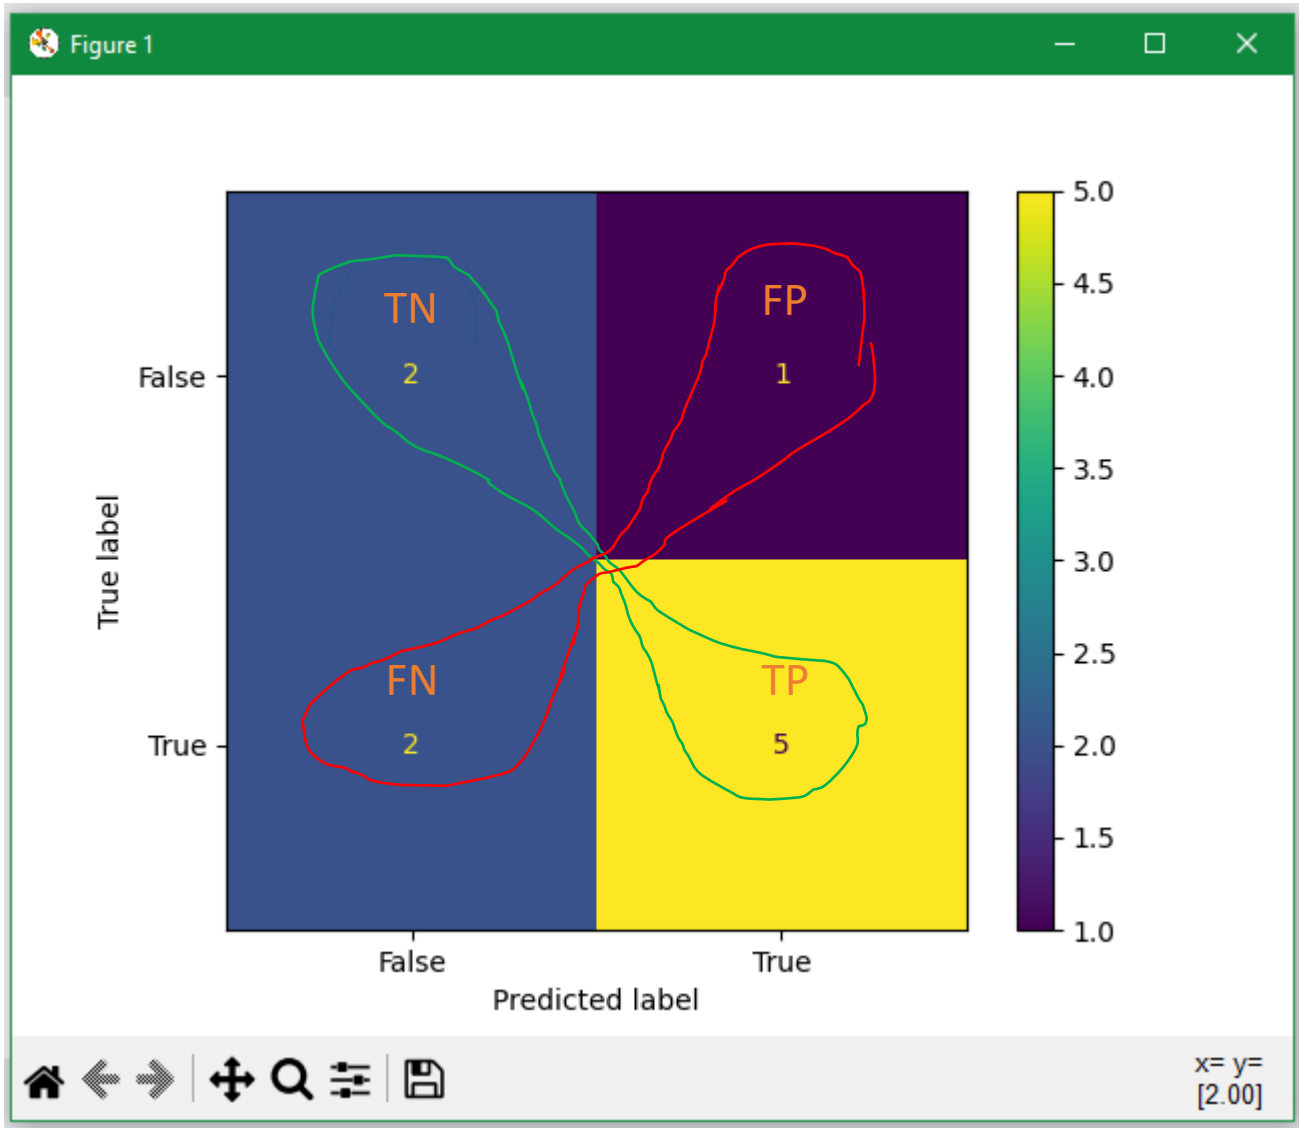

Confusion Matrix

Zadanie

Oblicz Confusion Matrix oraz wskaźniki wydajności dla wybranych danych oraz zastosowanego modelu.

ML js

ML tutorial js

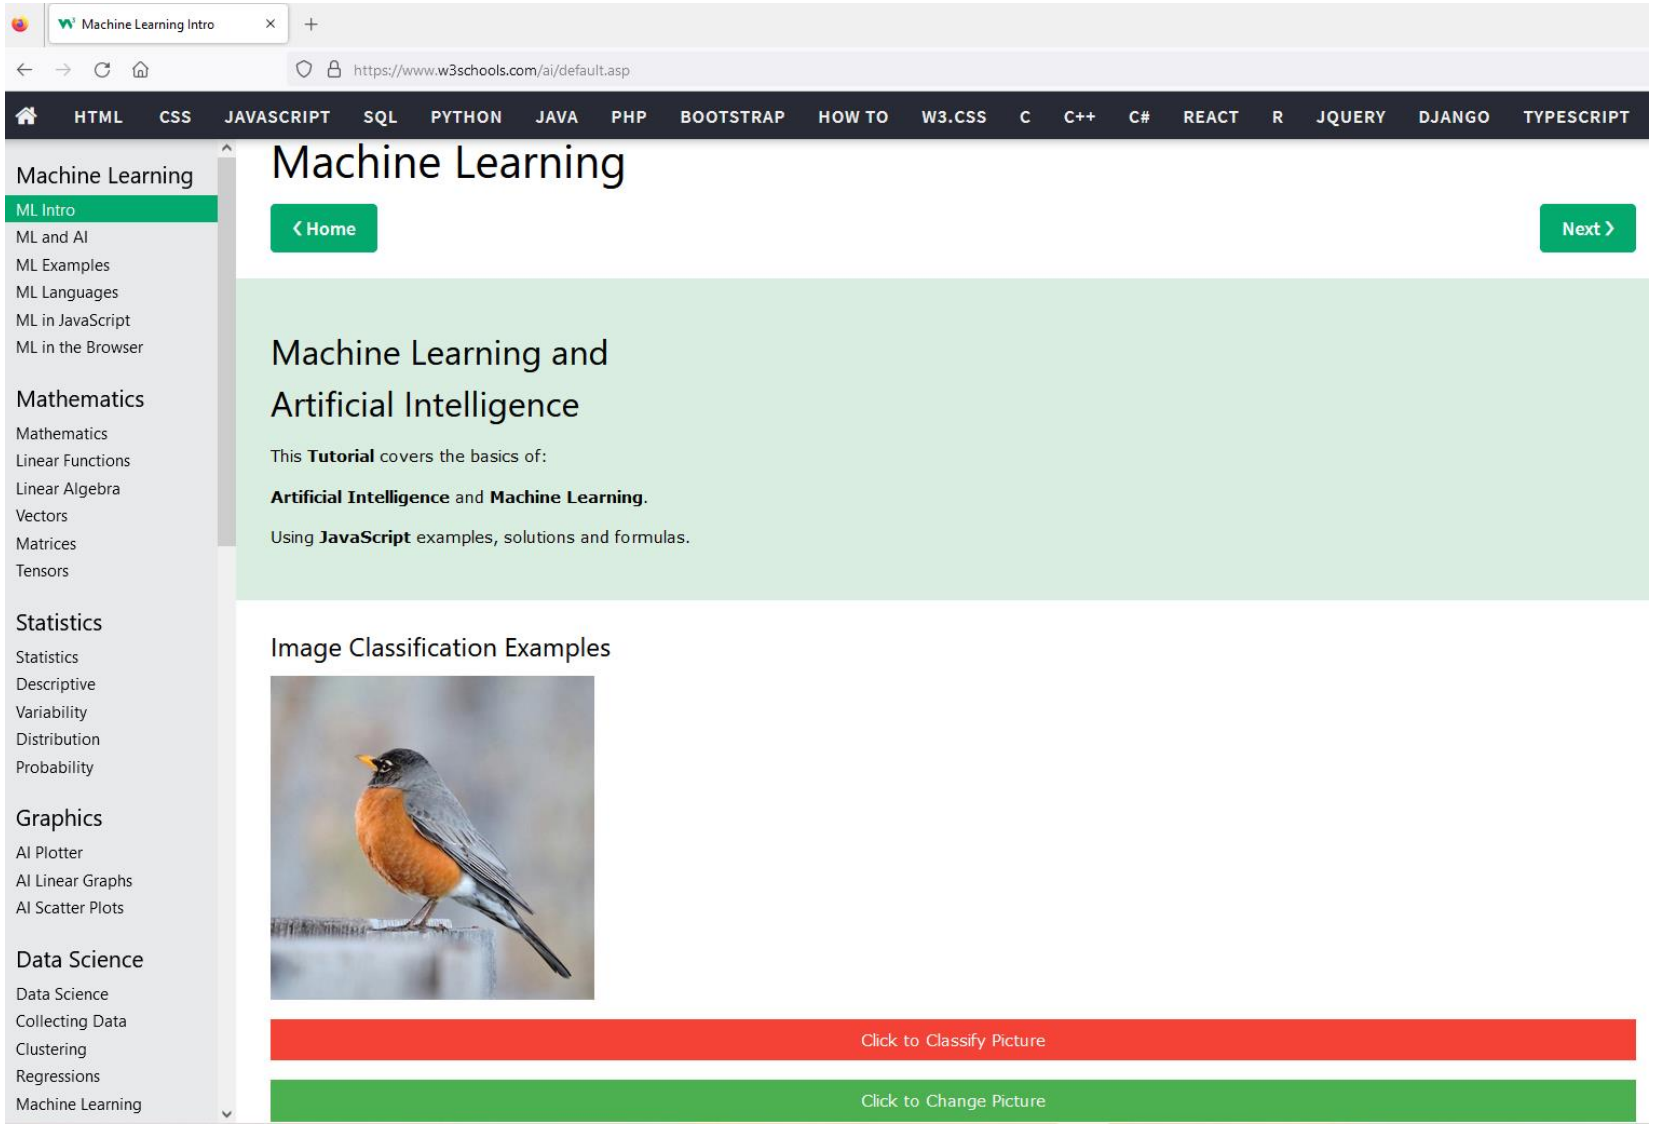

https://www.w3schools.com/ai/default.asp

ML js

różne zastosowania ML

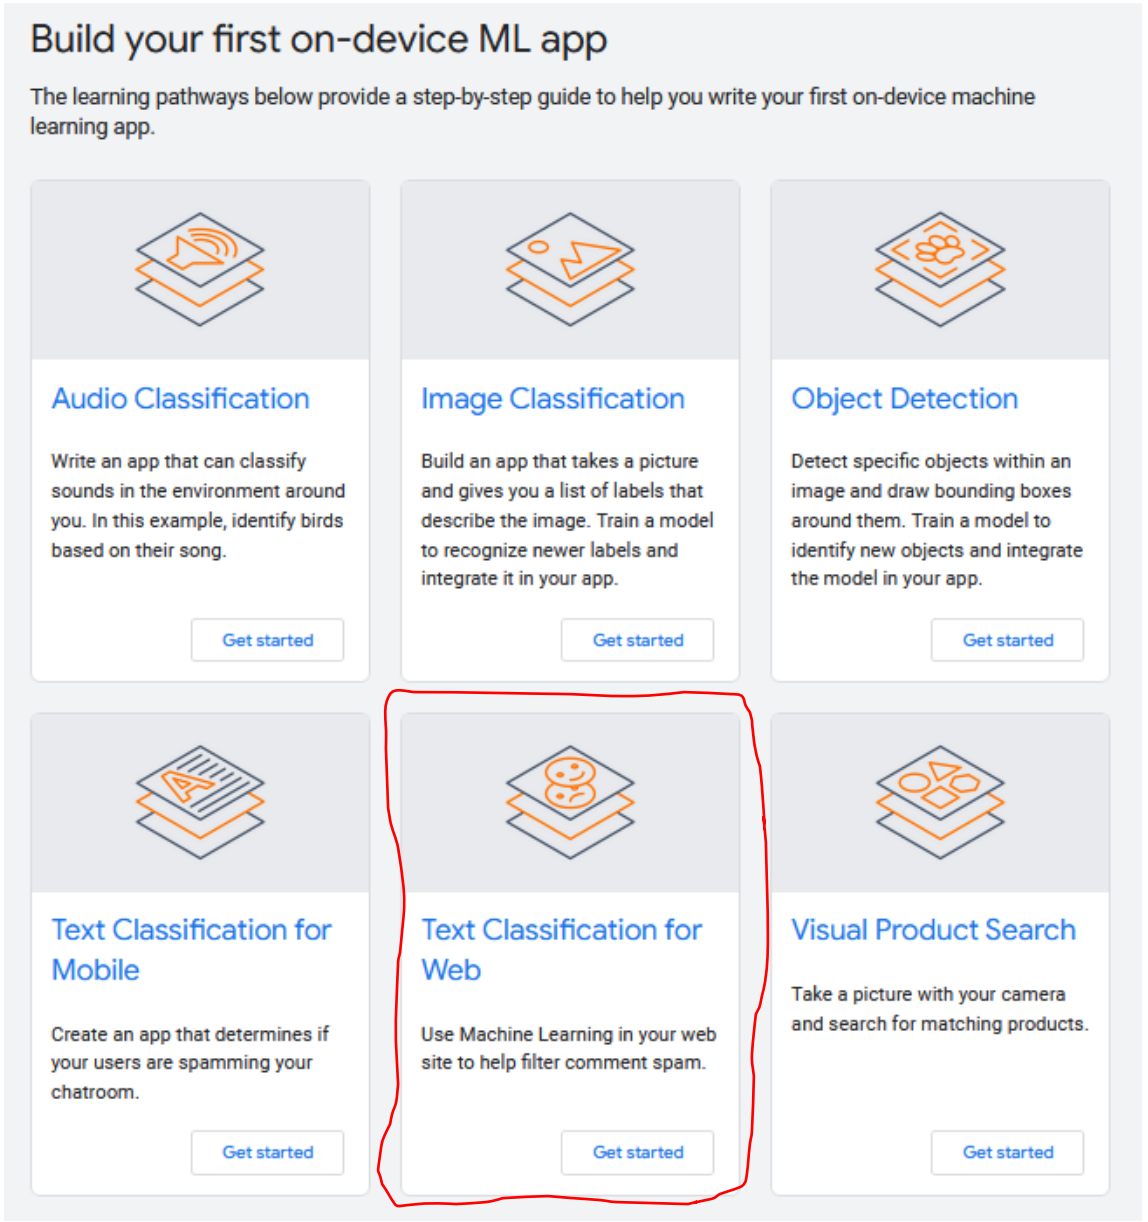

https://developers.google.com/learn/topics/on-device-ml

ML js

ON-DEVICE MACHINE LEARNING

Text Classification for Web

Learn how to create and use a machine learning model that detects comment spam in the browser using TensorFlow.js

Get started with comment spam detection

Learn the fundamentals of making custom text classification models for your web apps using TensorFlow.js.

4 activities

Explore

Go further with comment spam detection - model retraining

Learn how to retrain your comment spam model to account for edge cases it may miss when using the default pre-made model.

3 activities

Explore

detektor spamu w js

https://developers.google.com/learn/pathways/on-device-ml-6

Czym jest uczenie maszynowe (machine learning)?

źródło: www.w3schools.com/