

zumz182a

March 10, 2018

0.1 Uczenie maszynowe UMZ 2017/2018

1 2. Regresja logistyczna

1.0.1 Cz 1

1.1 2.1. Metoda gradientu prostego w praktyce

1.1.1 Kryterium stopu

Na wykresie zobaczymy porównanie regresji dla różnych wartości eps

```
In [1]: import numpy as np
        import matplotlib
        import matplotlib.pyplot as pl
        import ipywidgets as widgets

%matplotlib inline
%config InlineBackend.figure_format = 'svg'

from IPython.display import display, Math, Latex

# Wywietlanie macierzy w LaTeX-u
def LatexMatrix(matrix):
    ltx = r'\left[\begin{array}'
    m, n = matrix.shape
    ltx += '{' + ("r" * n) + '}'
    for i in range(m):
        ltx += r" & ".join([('%.4f' % j.item()) for j in matrix[i]]) + r" \\ "
    ltx += r'\end{array}\right]'
    return ltx

# Wczytwanie danych z pliku za pomocą numpy
data = np.loadtxt('data_company.csv', delimiter=',')
m, n_plus_1 = data.shape
n = n_plus_1 - 1
Xn = data[:, 0:n].reshape(m, n)

# Dodaj kolumnę jedynek do macierzy
```

```

XMx = np.matrix(np.concatenate((np.ones((m, 1)), Xn), axis=1)).reshape(m, n_plus_1)
yMx = np.matrix(data[:, 1]).reshape(m, 1)

# Hipoteza (wersja macierzowa)
def hMx(theta, X):
    return X * theta

# Wykres danych (wersja macierzowa)
def regdotsMx(X, y, xlabel='Populacja', ylabel='Zysk'):
    fig = pl.figure(figsize=(16*.6, 9*.6))
    ax = fig.add_subplot(111)
    fig.subplots_adjust(left=0.1, right=0.9, bottom=0.1, top=0.9)
    ax.scatter([X[:, 1]], [y], c='r', s=50, label='Dane')

    ax.set_xlabel(xlabel)
    ax.set_ylabel(ylabel)
    ax.margins(.05, .05)
    pl.ylim(y.min() - 1, y.max() + 1)
    pl.xlim(np.min(X[:, 1]) - 1, np.max(X[:, 1]) + 1)
    return fig

# Wykres krzywej regresji (wersja macierzowa)
def reglineMx(fig, fun, theta, X):
    ax = fig.axes[0]
    x0 = np.min(X[:, 1]) - 1.0
    x1 = np.max(X[:, 1]) + 1.0
    L = [x0, x1]
    LX = np.matrix([1, x0, 1, x1]).reshape(2, 2)
    ax.plot(L, fun(theta, LX), linewidth='2',
            label=r'$y={\theta}_0\cdot 2\{op\}{\theta}_1\cdot 2x$'.format(
                theta0=float(theta[0][0]),
                theta1=(float(theta[1][0]) if theta[1][0] >= 0 else float(-theta[1][0])),
                op='+' if theta[1][0] >= 0 else '-')))

# Legenda wykresu
def legend(fig):
    ax = fig.axes[0]
    handles, labels = ax.get_legend_handles_labels()
    # try-except block is a fix for a bug in Poly3DCollection
    try:
        fig.legend(handles, labels, fontsize='15', loc='lower right')
    except AttributeError:
        pass

# Wersja macierzowa funkcji kosztu
def JMx(theta,X,y):
    m = len(y)
    J = 1.0 / (2.0 * m) * ((X * theta - y).T * (X * theta - y))

```

```

    return J.item()

# Wersja macierzowa gradientu funkcji kosztu
def dJMx(theta,X,y):
    return 1.0 / len(y) * (X.T * (X * theta - y))

# Implementacja algorytmu gradientu prostego za pomoc numpy i macierzy
def GDMx(fJ, fdJ, theta, X, y, alpha=0.1, eps=10**-3):
    current_cost = fJ(theta, X, y)
    logs = [[current_cost, theta]]
    while True:
        theta = theta - alpha * fdJ(theta, X, y) # implementacja wzoru
        current_cost, prev_cost = fJ(theta, X, y), current_cost
        if current_cost > 10000:
            break
        if abs(prev_cost - current_cost) <= eps:
            break
        logs.append([current_cost, theta])
    return theta, logs

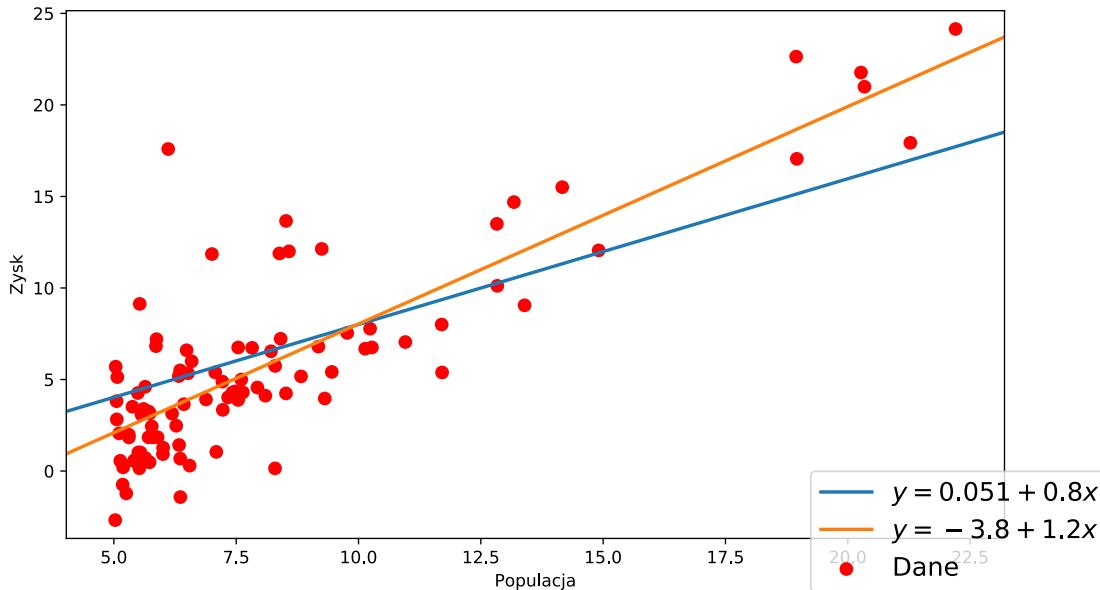
thetaStartMx = np.matrix([0, 0]).reshape(2, 1)

```

```

In [2]: fig = regdotsMx(XMx, yMx)
theta_e1, logs1 = GDMx(JMx, dJMx, thetaStartMx, XMx, yMx, alpha=0.01, eps=0.01)
reglineMx(fig, hMx, theta_e1, XMx)
theta_e2, logs2 = GDMx(JMx, dJMx, thetaStartMx, XMx, yMx, alpha=0.01, eps=0.000001)
reglineMx(fig, hMx, theta_e2, XMx)
legend(fig)

```



```
In [3]: display(Math(r'\theta_{10^{-2}} = ' + LatexMatrix(theta_e1) +
r'\quad\theta_{10^{-6}} = ' + LatexMatrix(theta_e2)))
```

$$\theta_{10^{-2}} = \begin{bmatrix} 0.0511 \\ 0.7957 \end{bmatrix} \quad \theta_{10^{-6}} = \begin{bmatrix} -3.8407 \\ 1.1875 \end{bmatrix}$$

1.1.2 Dugo kroku (α)

```
In [4]: # Jak zmienia si koszt w kolejnych krokach w zalenoci od alfa
```

```
def costchangeplot(logs):
    fig = plt.figure(figsize=(16*.6, 9*.6))
    ax = fig.add_subplot(111)
    fig.subplots_adjust(left=0.1, right=0.9, bottom=0.1, top=0.9)
    ax.set_xlabel('krok')
    ax.set_ylabel(r'$J(\theta)$')

    X = np.arange(0, 100, 1)
    Y = [logs[step][0] if step < len(logs) else None for step in X]
    ax.plot(X, Y, linewidth='2', label=(r'$J(\theta)$'))
    return fig

def slide1(alpha):
    best_theta, logs = GDMx(JMx, dJMx, thetaStartMx, XMx, yMx, alpha=alpha, eps=0.0001)
    fig = costchangeplot(logs)
    legend(fig)

    sliderAlpha1 = widgets.FloatSlider(min=0.01, max=0.03, step=0.001, value=0.02, description=r'$\alpha$')

In [5]: widgets.interact_manual(slide1, alpha=sliderAlpha1)
```

```
interactive(children=(FloatSlider(value=0.02, description=u'$\alpha$', max=0.03, min=0.01, step=0.001),
```

Out[5]: <function __main__.slide1>

1.2 2.2. Normalizacja danych

Uyjemy danych z Gratka flats challenge 2017".

Rozwamy model $h(x) = \theta_0 + \theta_1 x_1 + \theta_2 x_2$, w którym cena mieszkania prognozowana jest na podstawie liczby pokoi x_1 i metrau x_2 :

```
In [6]: # Wczytanie danych przy pomocy biblioteki pandas
import pandas
alldata = pandas.read_csv('data_flats.tsv', header=0, sep='\t',
                           usecols=['price', 'rooms', 'sqrMetres'])
alldata[:10]
```

```
Out[6]:    price  rooms  sqrMetres
0   476118.00      3       78
1   459531.00      3       62
2   411557.00      3       15
3   496416.00      4       14
4   406032.00      3       15
5   450026.00      3       80
6   571229.15      2       39
7   325000.00      3       54
8   268229.00      2       90
9   604836.00      4       40
```

```
In [7]: def show_mins_and_maxs(XMx):
    mins = np.amin(XMx, axis=0).tolist()[0] # wartoci minimalne
    maxs = np.amax(XMx, axis=0).tolist()[0] # wartoci maksymalne
    for i, (xmin, xmax) in enumerate(zip(mins, maxs)):
        display(Math(
            r'${:.2F} \leq x_{} \leq {:.2F}'.format(xmin, i, xmax)))
```

In [8]: # Przygotowanie danych

```
import numpy as np

%matplotlib inline

data2 = np.matrix(alldata[['rooms', 'sqrMetres', 'price']])

m, n_plus_1 = data2.shape
n = n_plus_1 - 1
Xn = data2[:, 0:n]

XMx2 = np.matrix(np.concatenate((np.ones((m, 1)), Xn), axis=1)).reshape(m, n_plus_1)
yMx2 = np.matrix(data2[:, -1]).reshape(m, 1) / 1000.0
```

Cechy w danych treningowych przyjmuj wartoci z zakresu:

In [9]: show_mins_and_maxs(XMx2)

$$1.00 \leq x_0 \leq 1.00$$

$$2.00 \leq x_1 \leq 7.00$$

$$12.00 \leq x_2 \leq 196.00$$

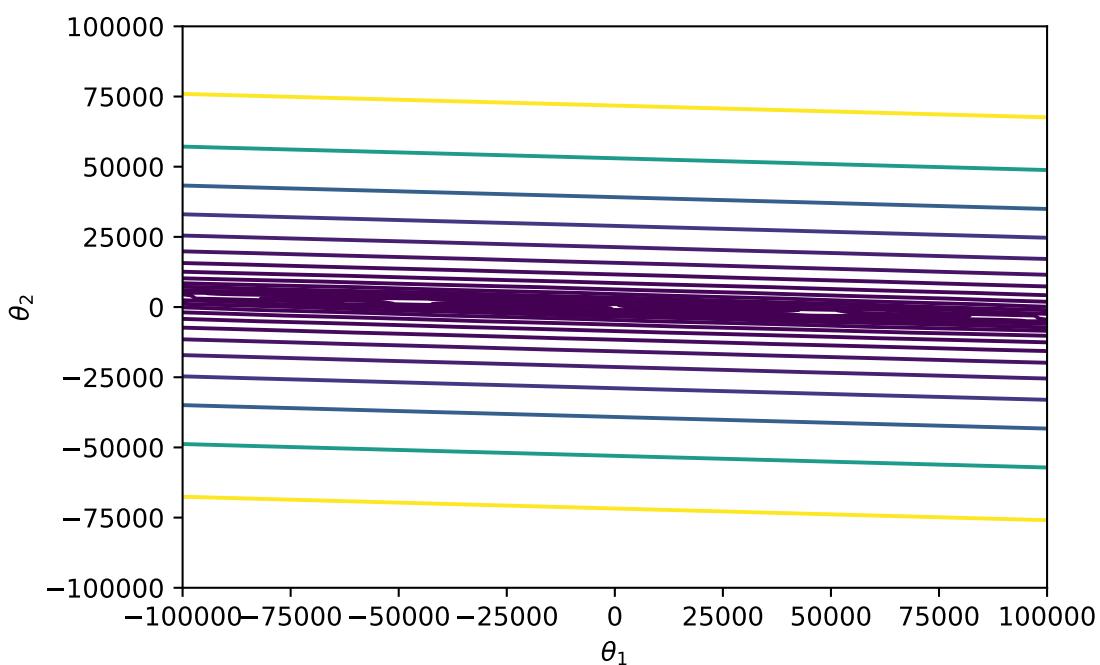
Jak widzimy, x_2 przyjmuje wartoci duo wiksze ni x_1 . Powoduje to, e wykres funkcji kosztu jest bardzo spaszczony" wzdu jednej z osi:

```
In [10]: def contour_plot(X, y, rescale=10**8):
    theta0_vals = np.linspace(-100000, 100000, 100)
    theta1_vals = np.linspace(-100000, 100000, 100)

    J_vals = np.zeros(shape=(theta0_vals.size, theta1_vals.size))
    for t1, element in enumerate(theta0_vals):
        for t2, element2 in enumerate(theta1_vals):
            thetaT = np.matrix([1.0, element, element2]).reshape(3,1)
            J_vals[t1, t2] = JMx(thetaT, X, y) / rescale

    pl.figure()
    pl.contour(theta0_vals, theta1_vals, J_vals.T, np.logspace(-2, 3, 20))
    pl.xlabel(r'$\theta_1$')
    pl.ylabel(r'$\theta_2$')

In [11]: contour_plot(XMx2, yMx2, rescale=10**10)
```



1.2.1 Skalowanie

Będziemy dy do tego, aby kada z cech przyjmowala wartości w podobnym zakresie.

W tym celu przeskalujemy wartości każdej z cech, dzieląc je przez wartość maksymalną:

$$\hat{x}_i^{(j)} := \frac{x_i^{(j)}}{\max_j x_i^{(j)}}$$

```
In [12]: XMx2_scaled = XMx2 / np.amax(XMx2, axis=0)

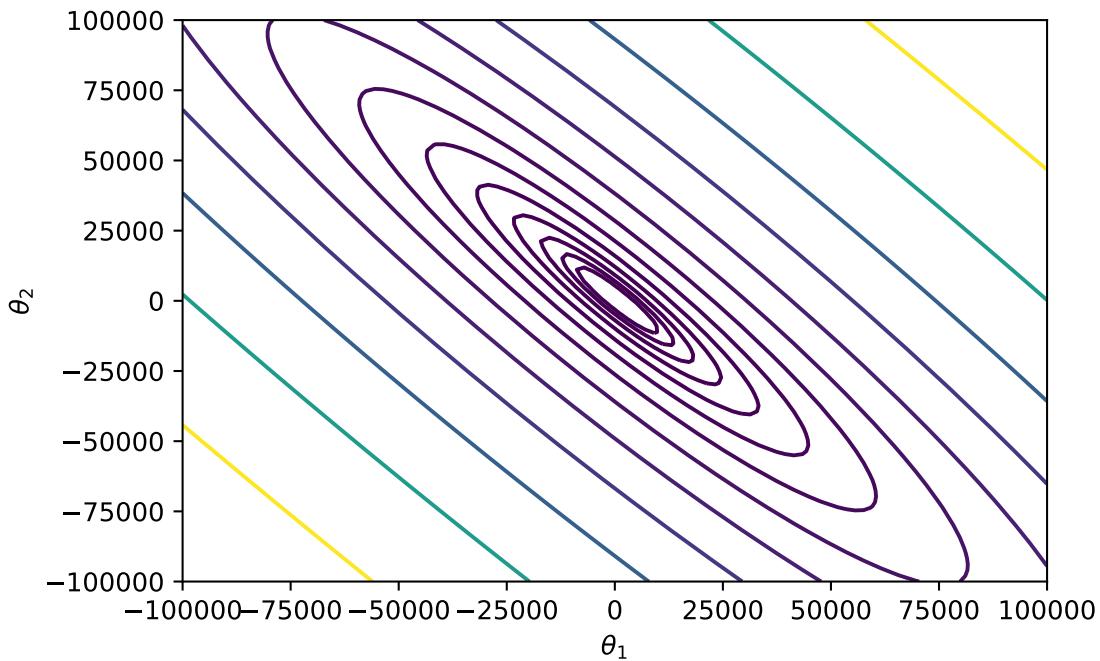
show_mins_and_maxs(XMx2_scaled)
```

$$1.00 \leq x_0 \leq 1.00$$

$$0.29 \leq x_1 \leq 1.00$$

$$0.06 \leq x_2 \leq 1.00$$

```
In [13]: contour_plot(XMx2_scaled, yMx2)
```



1.2.2 Normalizacja redniej

Bdziemy dy do tego, eby dodatkowo rednia warta kadej z cech bya w okolicach 0.

W tym celu oprócz przeskalowania odejmiemy warto redniej od wartoci kadej z cech:

$$\hat{x}_i^{(j)} := \frac{x_i^{(j)} - \mu_i}{\max_j x_i^{(j)}}$$

```
In [17]: XMx2_norm = (XMx2 - np.mean(XMx2, axis=0)) / np.amax(XMx2, axis=0)

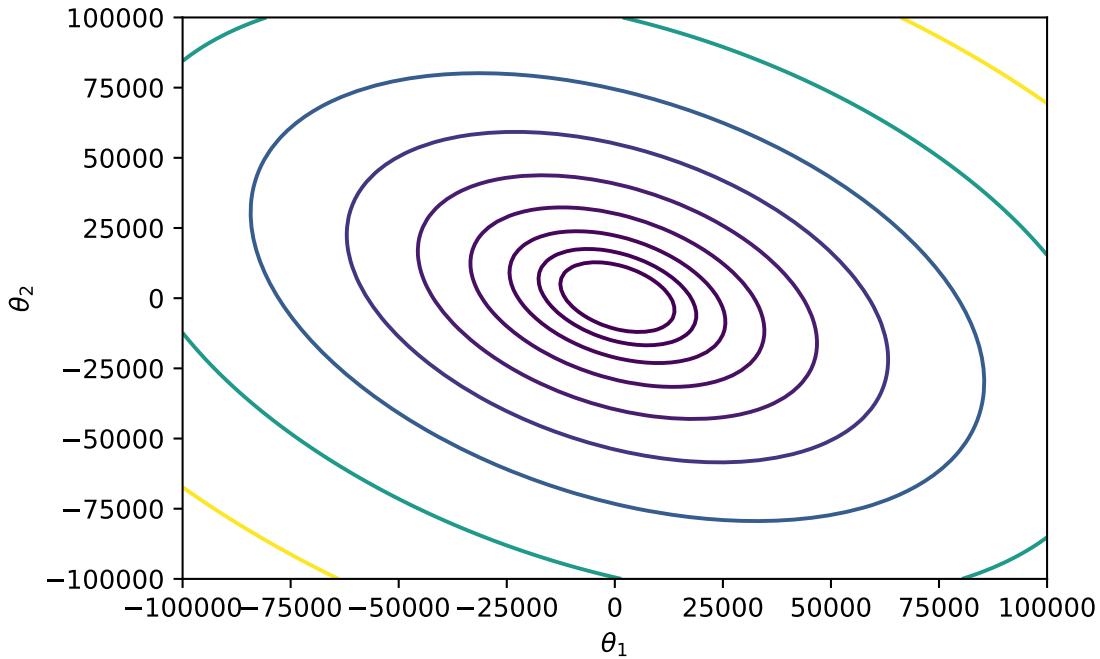
show_mins_and_maxs(XMx2_norm)
```

$$0.00 \leq x_0 \leq 0.00$$

$$-0.10 \leq x_1 \leq 0.62$$

$$-0.23 \leq x_2 \leq 0.70$$

```
In [18]: contour_plot(XMx2_norm, yMx2)
```



1.3 2.3. Regresja logistyczna

- Uwaga: *regresja* logistyczna jest algorytmem dla problemów *klasyfikacji* (nie *regresji*, wbrew nazwie)!

1.3.1 Klasyfikacja dwuklasowa

1.3.2 Przykaz: kosaciec szczecinkowy (*Iris setosa*)

Mamy dane dotyczące dugoci patków i chcielibyśmy na tej podstawie określić, czy jest to roślina z gatunku *Iris setosa*

```
In [21]: import pandas
data_iris_setosa = (
    pandas.read_csv('iris.csv', usecols=['p.d.', 'Gatunek'])
    .apply(lambda x: [x[0], 1 if x[1] == 'Iris-setosa' else 0], axis=1))
data_iris_setosa.columns = ['d. patka', 'Iris setosa?']
data_iris_setosa[:6]
```

```
Out[21]: d. patka Iris setosa?
0      1.4      1.0
1      1.5      1.0
2      5.6      0.0
3      5.1      0.0
4      4.5      0.0
5      5.1      0.0
```

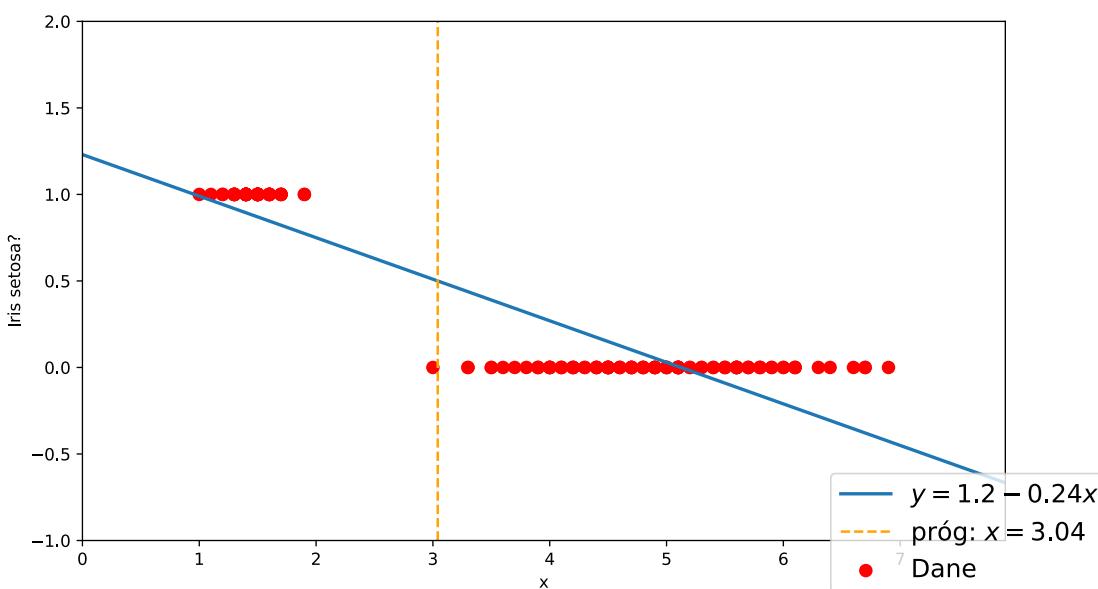
```
In [22]: # Rysowanie progu
def threshold(fig, theta):
    x_thr = (0.5 - theta.item(0)) / theta.item(1)
    ax = fig.axes[0]
    ax.plot([x_thr, x_thr], [-1, 2],
            color='orange', linestyle='dashed',
            label=u'próg: $x={:.2F}$'.format(x_thr))
```

Spróbujmy zastosować regresję liniową:

```
In [23]: m, n_plus_1 = data_iris_setosa.values.shape
n = n_plus_1 - 1
Xn = data_iris_setosa.values[:, 0:n].reshape(m, n)

XMx3 = np.matrix(np.concatenate((np.ones((m, 1)), Xn), axis=1)).reshape(m, n_plus_1)
yMx3 = np.matrix(data_iris_setosa.values[:, 1]).reshape(m, 1)

In [24]: fig = regdotsMx(XMx3, yMx3, xlabel='x', ylabel='Iris setosa?')
theta_e3, logs3 = GDMx(JMx, dJMx, thetaStartMx, XMx3, yMx3, alpha=0.03, eps=0.000001)
reglineMx(fig, hMx, theta_e3, XMx3)
threshold(fig, theta_e3)
legend(fig)
```



- Krzywa regresji liniowej jest niezbyt dopasowana do danych klasyfikacyjnych.
- Zastosowanie progu $y = 0.5$ nie zawsze pomaga uzyska sensowny rezultat.
- $h(x)$ moe przyjmowa wartoci mniejsze od 0 i wiksze od 1 – jak interpretowa takie wyniki?

Wniosek: w przypadku problemów klasyfikacyjnych regresja liniowa nie wydaje si najlepszym rozwizaniem.

Funkcja logistyczna (sigmoidalna):

$$g(x) = \frac{1}{1 + e^{-x}}$$

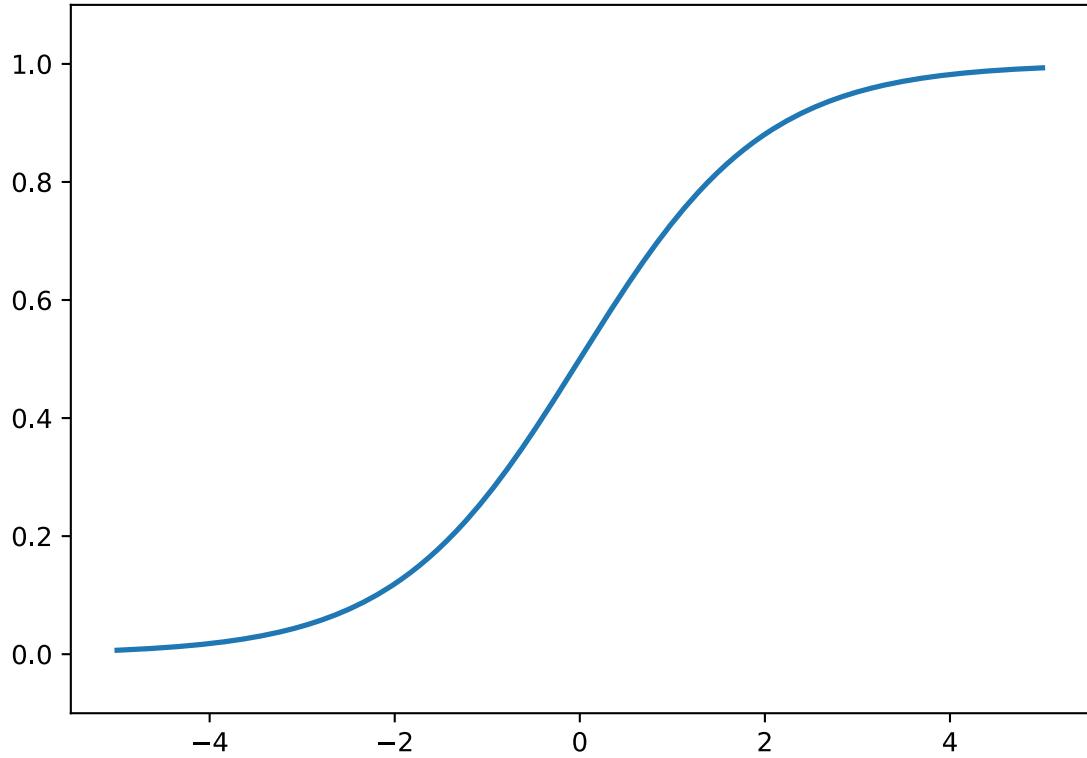
```
In [25]: def logistic(x):
    return 1.0 / (1.0 + np.exp(-x))
```

```
In [26]: import matplotlib.pyplot as plt
def plot_logistic():
    x = np.linspace(-5,5,200)
    y = logistic(x)

    fig = plt.figure(figsize=(7,5))
    ax = fig.add_subplot(111)
    plt.ylim(-.1,1.1)
    ax.plot(x, y, linewidth='2')
```

Wykres funkcji logistycznej $g(x) = \frac{1}{1 + e^{-x}}$:

```
In [27]: plot_logistic()
```



Funkcja regresji logistycznej:

$$h_\theta(x) = g(\theta^T x) = \frac{1}{1 + e^{-\theta^T x}}$$

Wersja macierzowa:

$$h_\theta(X) = g(X \theta) = \frac{1}{1 + e^{-X\theta}}$$

```
In [28]: # Funkcja regresji logistycznej
def h(theta, X):
    return 1.0/(1.0 + np.exp(-X * theta))
```

Funkcja kosztu dla regresji logistycznej:

$$J(\theta) = -\frac{1}{m} \left(\sum_{i=1}^m y^{(i)} \log h_\theta(x^{(i)}) + (1 - y^{(i)}) \log (1 - h_\theta(x^{(i)})) \right)$$

Gradient dla regresji logistycznej (wersja macierzowa):

$$\nabla J(\theta) = \frac{1}{|\vec{y}|} X^T (h_\theta(X) - \vec{y})$$

(Jedyna różnica między gradientem dla regresji logistycznej a gradientem dla regresji liniowej to postać h_θ).

```
In [29]: # Funkcja kosztu dla regresji logistycznej
def J(h, theta, X, y):
    m = len(y)
    h_val = h(theta, X)
    s1 = np.multiply(y, np.log(h_val))
    s2 = np.multiply((1 - y), np.log(1 - h_val))
    return -np.sum(s1 + s2, axis=0) / m

In [30]: # Gradient dla regresji logistycznej
def dJ(h, theta, X, y):
    return 1.0 / len(y) * (X.T * (h(theta, X) - y))

In [31]: # Metoda gradientu prostego dla regresji logistycznej
def GD(h, fJ, fdJ, theta, X, y, alpha=0.01, eps=10**-3, maxSteps=10000):
    errorCurr = fJ(h, theta, X, y)
    errors = [[errorCurr, theta]]
    while True:
        # oblicz nowe theta
        theta = theta - alpha * fdJ(h, theta, X, y)
        # raportuj poziom bdu
        errorCurr, errorPrev = fJ(h, theta, X, y), errorCurr
        # kryteria stopu
        if abs(errorPrev - errorCurr) <= eps:
            break
        if len(errors) > maxSteps:
            break
        errors.append([errorCurr, theta])
    return theta, errors

In [32]: # Uruchomienie metody gradientu prostego dla regresji logistycznej
thetaBest, errors = GD(h, J, dJ, thetaStartMx, XMx3, yMx3,
                       alpha=0.1, eps=10**-7, maxSteps=1000)
print("error =", errors[-1][0])
print("theta =", thetaBest)

('error =', matrix([[ 0.05755617]]))
('theta =', matrix([[ 5.02530461],
                   [-1.99174803]]))

In [33]: # Funkcja regresji logistycznej (wersja skalarowa)
def scalar_logistic_regression_function(theta, x):
    return 1.0 / (1.0 + np.exp(-(theta.item(0) + theta.item(1) * x)))

# Rysowanie progu
def threshold_val(fig, x_thr):
    ax = fig.axes[0]
    ax.plot([x_thr, x_thr], [-1, 2],
            color='orange', linestyle='dashed',
```

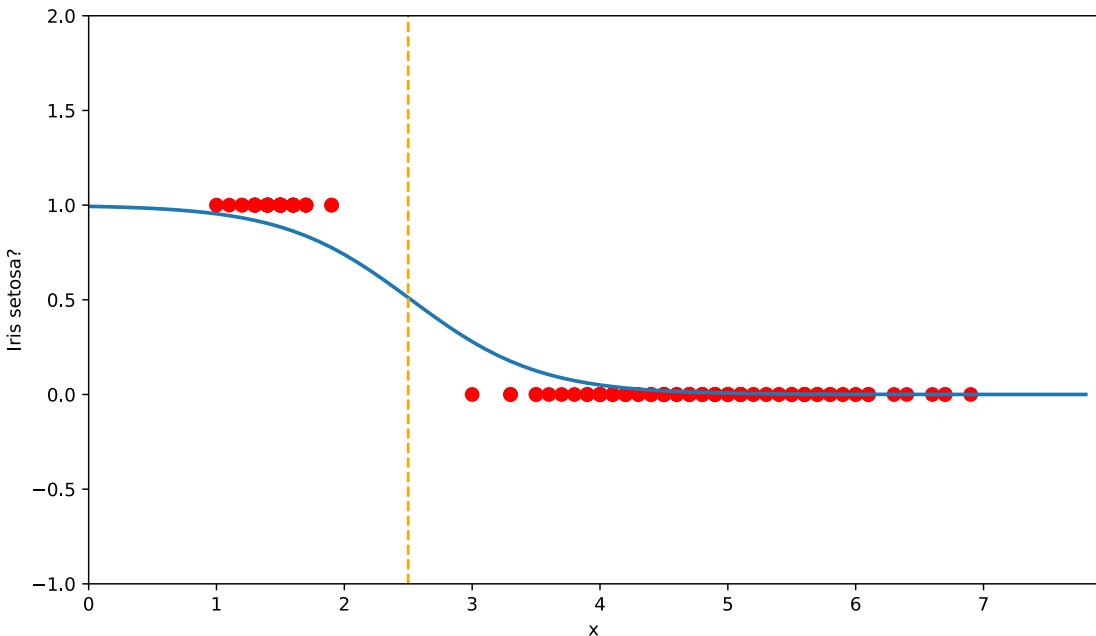
```

label=u'próg: $x={:.2F}$.format(x_thr))

# Wykres krzywej regresji logistycznej
def logistic_reglne(fig, theta, X):
    ax = fig.axes[0]
    x0 = np.min(X[:, 1]) - 1.0
    x1 = np.max(X[:, 1]) + 1.0
    Arg = np.arange(x0, x1, 0.1)
    Val = scalar_logistic_regression_function(theta, Arg)
    ax.plot(Arg, Val, linewidth='2')

In [34]: fig = regdotsMx(XMx3, yMx3, xlabel='x', ylabel='Iris setosa?')
logistic_reglne(fig, thetaBest, XMx3)
threshold_val(fig, 2.5)

```



Traktujemy warto $h_\theta(x)$ jako prawdopodobieństwo, że cecha przyjmie warto pozytywną:

$$h_\theta(x) = P(y = 1 | x; \theta)$$

1.3.3 Dwuklasowa regresja logistyczna: więcej cech

Wemy pod uwagę następujące cechy: * dugo dzieek kielicha * szeroko dziaek kielicha * dugo patka * szeroko patka

```

In [39]: import pandas
src_cols = ['sl', 'sw', 'pl', 'pw', 'Gatunek']
trg_cols = ['sl', 'sw', 'pl', 'pw', 'Iris setosa?']

```

```

data_iris_setosa_multi = (
    pandas.read_csv('iris.csv', usecols=src_cols)
    .apply(lambda x: [x[0], x[1], x[2], x[3], 1 if x[4] == 'Iris-setosa' else 0], axis=1)
data_iris_setosa_multi.columns = trg_cols
data_iris_setosa_multi[:6]

```

Out [39]:

	sl	sw	pl	pw	Iris setosa?
0	5.2	3.4	1.4	0.2	1.0
1	5.1	3.7	1.5	0.4	1.0
2	6.7	3.1	5.6	2.4	0.0
3	6.5	3.2	5.1	2.0	0.0
4	4.9	2.5	4.5	1.7	0.0
5	6.0	2.7	5.1	1.6	0.0

In [40]: %matplotlib inline

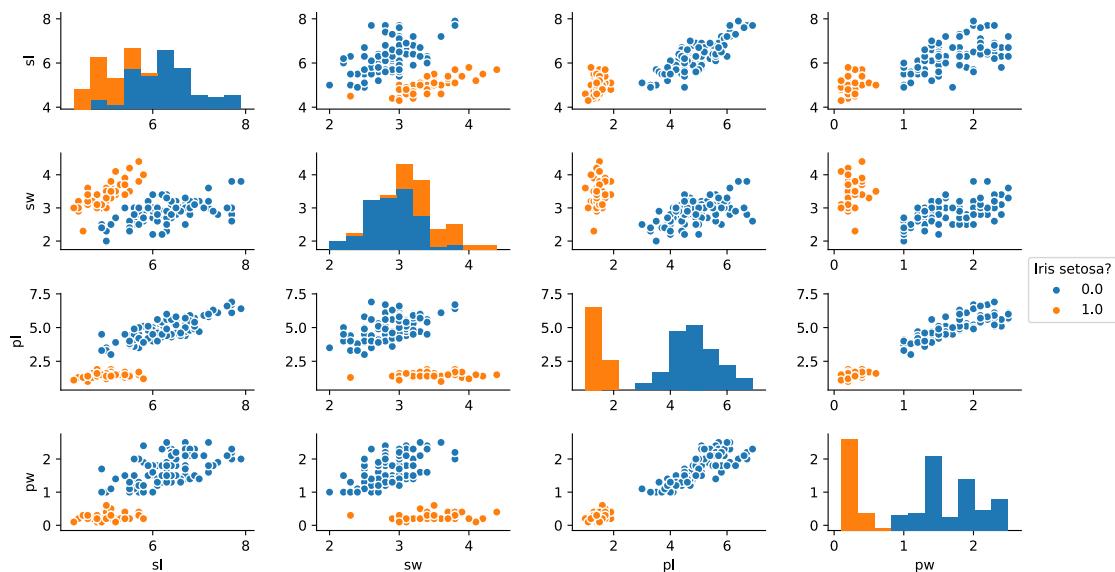
```

import matplotlib.pyplot as plt
import seaborn

```

In [41]: seaborn.pairplot(
 data_iris_setosa_multi,
 vars=[c for c in data_iris_setosa_multi.columns if c != 'Iris setosa?'],
 hue='Iris setosa?', size=1.5, aspect=1.75)

Out [41]: <seaborn.axisgrid.PairGrid at 0x7f279e68c510>



In [42]: # Przygotowanie danych
m, n_plus_1 = data_iris_setosa_multi.values.shape
n = n_plus_1 - 1

```

Xn = data_iris_setosa_multi.values[:, 0:n].reshape(m, n)

XMx4 = np.matrix(np.concatenate((np.ones((m, 1)), Xn), axis=1)).reshape(m, n_plus_1)
yMx4 = np.matrix(data_iris_setosa_multi.values[:, n]).reshape(m, 1)

print(XMx4[:6])
print(yMx4[:6])

[[ 1.   5.2   3.4   1.4   0.2]
 [ 1.   5.1   3.7   1.5   0.4]
 [ 1.   6.7   3.1   5.6   2.4]
 [ 1.   6.5   3.2   5.1   2. ]
 [ 1.   4.9   2.5   4.5   1.7]
 [ 1.   6.    2.7   5.1   1.6]]
[[ 1.]
 [ 1.]
 [ 0.]
 [ 0.]
 [ 0.]
 [ 0.]]]

In [43]: # Podzia danych na zbiór trenujcy i testowy
XTrain, XTest = XMx4[:100], XMx4[100:]
yTrain, yTest = yMx4[:100], yMx4[100:]

# Macierz parametrów poczatkowych
thetaTemp = np.ones(5).reshape(5,1)

In [45]: thetaBest, errors = GD(h, J, dJ, thetaTemp, XTrain, yTrain,
                           alpha=0.1, eps=10**-7, maxSteps=1000)
print("error =", errors[-1][0])
print("theta =", thetaBest)

('error =', matrix([[ 0.006797]]))
('theta =', matrix([[ 1.11414027],
 [ 0.14887292],
 [ 2.13284493],
 [-2.89324615],
 [-0.66543637]]))

```

1.3.4 Funkcja decyzyjna regresji logistycznej

$$c = \begin{cases} 1, & \text{gdy } P(y = 1 | x; \theta) > 0.5 \\ 0 & \text{w przeciwnym przypadku} \end{cases}$$

$$P(y = 1 | x; \theta) = h_{\theta}(x)$$

```
In [48]: def classifyBi(theta, X):
    prob = h(theta, X).item()
    return (1, prob) if prob > 0.5 else (0, prob)

    print("theta =", thetaBest)
    print("x0 =", XTest[0])
    print("h(x0) =", h(thetaBest, XTest[0]).item())
    print("c(x0) =", classifyBi(thetaBest, XTest[0]), "\n")

('theta =', matrix([[ 1.11414027],
   [ 0.14887292],
   [ 2.13284493],
   [-2.89324615],
   [-0.66543637]]))
('x0 =', matrix([[ 1.,  7.3,  2.9,  6.3,  1.8]]))
('h(x0) =', 1.606143695982493e-05)
('c(x0) =', (0, 1.606143695982493e-05), '\n')
```

1.3.5 Skuteczno

```
In [49]: acc = 0.0
    for i, rest in enumerate(yTest):
        cls, prob = classifyBi(thetaBest, XTest[i])
        if i < 10:
            print(int(yTest[i].item()), "<=>", cls, "-- prob:", round(prob, 4))
        acc += cls == yTest[i].item()

    print("\nAccuracy:", acc / len(XTest))

(0, '<=>', 0, '-- prob:', 0.0)
(1, '<=>', 1, '-- prob:', 0.9816)
(0, '<=>', 0, '-- prob:', 0.0001)
(0, '<=>', 0, '-- prob:', 0.0005)
(0, '<=>', 0, '-- prob:', 0.0001)
(1, '<=>', 1, '-- prob:', 0.9936)
(0, '<=>', 0, '-- prob:', 0.0059)
(0, '<=>', 0, '-- prob:', 0.0992)
(0, '<=>', 0, '-- prob:', 0.0001)
(0, '<=>', 0, '-- prob:', 0.0001)
('Accuracy:', 1.0)
```

1.4 2.4. Wieloklasowa regresja logistyczna

1.4.1 Przykad: gatunki irysów (kosaców)

Kosaciec szczecinkowy (*Iris setosa*)

Kosaciec amerykaski (*Iris virginica*)

Kosaciec rónobarwny (*Iris versicolor*)

Cechy: * dugo dziek kielicha * szeroko dziek kielicha * dugo patka * szeroko patka
Wczytanie danych

```
In [50]: import pandas
         data_iris = pandas.read_csv('iris.csv')
         data_iris[:6]
```

```
Out[50]:    sl   sw   pl   pw      Gatunek
0  5.2  3.4  1.4  0.2    Iris-setosa
1  5.1  3.7  1.5  0.4    Iris-setosa
2  6.7  3.1  5.6  2.4  Iris-virginica
3  6.5  3.2  5.1  2.0  Iris-virginica
4  4.9  2.5  4.5  1.7  Iris-virginica
5  6.0  2.7  5.1  1.6 Iris-versicolor
```

Przygotowanie danych

```
In [51]: import numpy as np

        features = ['sl', 'sw', 'pl', 'pw']
        m = len(data_iris)
        X = np.matrix(data_iris[features])
        X0 = np.ones(m).reshape(m, 1)
        X = np.hstack((X0, X))
        y = np.matrix(data_iris[['Gatunek']]).reshape(m, 1)

        print("X = ", X[:4])
        print("y = ", y[:4])

('X = ', matrix([[ 1. ,  5.2,  3.4,  1.4,  0.2,
                   [ 1. ,  5.1,  3.7,  1.5,  0.4],
                   [ 1. ,  6.7,  3.1,  5.6,  2.4],
                   [ 1. ,  6.5,  3.2,  5.1,  2. ]]))
('y = ', matrix([['Iris-setosa'],
                 ['Iris-setosa'],
                 ['Iris-virginica'],
                 ['Iris-virginica']], dtype=object))
```

Zamiemy etykiety tekstowe w tablicy y na wektory jednostkowe (*one-hot vectors*):

$$\begin{array}{ll} \text{"Iris-setosa"} & \mapsto \begin{bmatrix} 1 & 0 & 0 \end{bmatrix} \\ \text{"Iris-virginica"} & \mapsto \begin{bmatrix} 0 & 1 & 0 \end{bmatrix} \\ \text{"Iris-versicolor"} & \mapsto \begin{bmatrix} 0 & 0 & 1 \end{bmatrix} \end{array}$$

Wówczas zamiast wektora y otrzymamy macierz Y :

$$y = \begin{bmatrix} y^{(1)} \\ y^{(2)} \\ y^{(3)} \\ y^{(4)} \\ y^{(5)} \\ \vdots \end{bmatrix} = \begin{bmatrix} "Iris-setosa" \\ "Iris-setosa" \\ "Iris-virginica" \\ "Iris-versicolor" \\ "Iris-virginica" \\ \vdots \end{bmatrix} \mapsto Y = \begin{bmatrix} 1 & 0 & 0 \\ 1 & 0 & 0 \\ 0 & 1 & 0 \\ 0 & 0 & 1 \\ 0 & 1 & 0 \\ \vdots & \vdots & \vdots \end{bmatrix}$$

```
In [52]: def mapY(y, cls):
    m = len(y)
    yBi = np.matrix(np.zeros(m)).reshape(m, 1)
    yBi[y == cls] = 1.
    return yBi

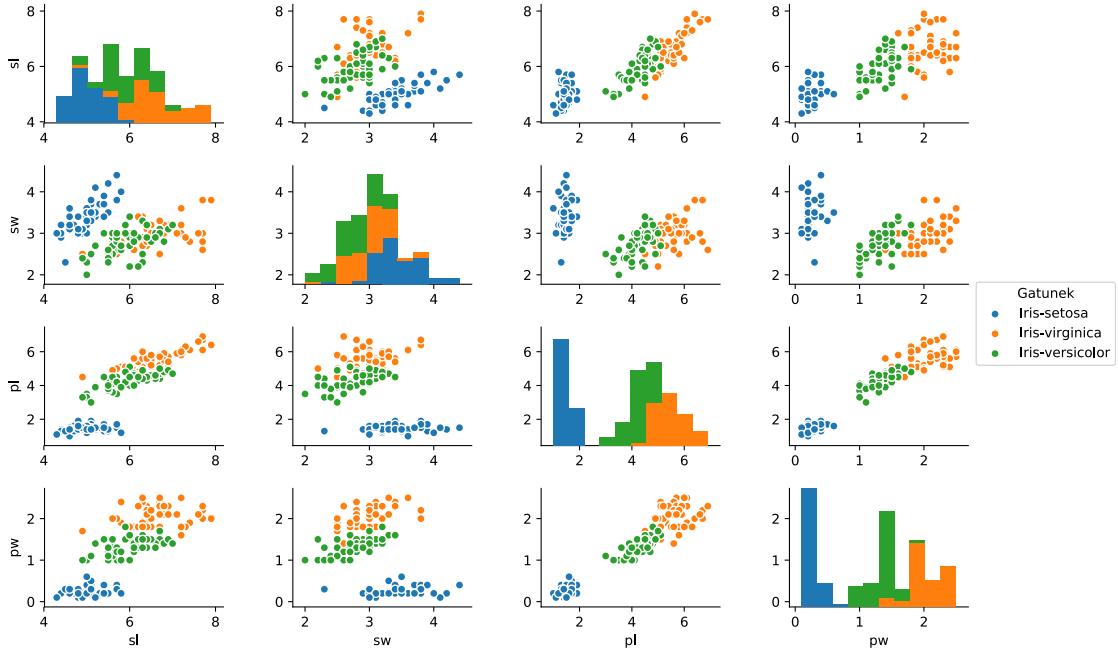
def indicatorMatrix(y):
    classes = np.unique(y.tolist())
    m = len(y)
    k = len(classes)
    Y = np.matrix(np.zeros((m, k)))
    for i, cls in enumerate(classes):
        Y[:, i] = mapY(y, cls)
    return Y

# one-hot matrix
Y = indicatorMatrix(y)
```

```
In [53]: # Podzia danych na zbiór trenujcy i testowy
XTrain, XTest = X[:100], X[100:]
YTrain, YTest = Y[:100], Y[100:]

# Macierz parametrów poczatkowych
thetaTemp = np.ones(5).reshape(5,1)
```

```
In [54]: g = seaborn.pairplot(data_iris, hue='Gatunek', size=1.75, aspect=1.5)
```



1.4.2 Od regresji logistycznej dwuklasowej do wieloklasowej

- Irysów s przydzielone do trzech klas: *Iris-setosa* (0), *Iris-versicolor* (1), *Iris-virginica* (2).
- Wiemy, jak stworzyć klasyfikatory typu *Iris-setosa* vs. *Nie-Iris-setosa* (tzw. *one-vs-all*).
- Moemy stworzyć trzy klasyfikatory $h_{\theta_1}, h_{\theta_2}, h_{\theta_3}$ (otrzymując trzy zestawy parametrów θ) i wybra klas o największym prawdopodobieństwie.

1.4.3 Funkcja softmax

Odpowiednikiem funkcji logistycznej dla wieloklasowej regresji logistycznej jest funkcja softmax:

$$\text{softmax}(k, x_1, \dots, x_n) = \frac{e^{x_k}}{\sum_{i=1}^n e^{x_i}}$$

$$P(y = c | x; \theta_1, \dots, \theta_k) = \text{softmax}(c, \theta_1^T x, \dots, \theta_k^T x)$$

```
In [55]: # Zapis macierzowy funkcji softmax
def softmax(X):
    return np.exp(X) / np.sum(np.exp(X))

X5 = X[:3]
print("X5 =", X5)
print("softmax =", softmax(X5))

('X5 =', matrix([[ 1.,  5.2,  3.4,  1.4,  0.2],
[ 1.,  5.1,  3.7,  1.5,  0.4],
```

```

[ 1. ,  6.7,  3.1,  5.6,  2.4]])))
('softmax =', matrix([[ 0.00175241,  0.11686208,  0.01931717,  0.0026143 ,  0.00078741],
   [ 0.00175241,  0.10574119,  0.02607546,  0.00288924,  0.00096175],
   [ 0.00175241,  0.52373952,  0.01431051,  0.17433774,  0.00710639]]))

```

```

In [56]: XN = np.matrix([2.1, 0.5, 0.8, 0.9, 3.2]).reshape(5,1)
P = softmax(XN)
print(XN)
print("Suma X =", np.sum(XN), "\n")
print(P)
print("Suma P =", np.sum(P))

[[ 2.1]
 [ 0.5]
 [ 0.8]
 [ 0.9]
 [ 3.2]]
('Suma X =', 7.500000000000009, '\n')
[[ 0.20921428]
 [ 0.04223963]
 [ 0.05701754]
 [ 0.06301413]
 [ 0.62851442]]
('Suma P =', 0.9999999999999989)

```

```

In [57]: def trainMaxEnt(X, Y):
    n = X.shape[1]
    thetas = []
    for c in range(Y.shape[1]):
        YBi = Y[:,c]
        theta = np.matrix(np.random.random(n)).reshape(n,1)
        thetaBest, errors = GD(h, J, dJ, theta,
                               X, YBi, alpha=0.1, eps=10**-4)
        thetas.append(thetaBest)
    return thetas

    thetas = trainMaxEnt(XTrain, YTrain);
    for theta in thetas:
        print(theta, "\n")

(matrix([[ 0.5672792 ],
   [ 0.34410521],
   [ 1.21453693],
   [-2.06603751],
   [-0.71099741]]), '\n')
(matrix([[ 0.40938528],
   [ 0.07134866],

```

```

[-0.93345289],
[ 0.62108863],
[-0.8021439 ]]), '\n')
(matrix([[ -0.13931903],
[-1.53046299],
[-2.02411945],
[ 2.24311323],
[ 2.75874817]]), '\n')

```

1.4.4 Funkcja decyzyjna wieloklasowej regresji logistycznej

$$c = \arg \max_{i \in \{1, \dots, k\}} P(y = i | x; \theta_1, \dots, \theta_k)$$

```

In [58]: def classify(thetas, X, debug=False):
    regs = np.array([(X*theta).item() for theta in thetas])
    if debug:
        print("regs =", regs)
    probs = softmax(regs)
    if debug:
        print("probs =", np.around(probs, decimals=3))
    return np.argmax(probs), probs

    print("YTest =", YTest[:6])
    YTestCls = YTest * np.matrix((0,1,2)).T
    print("YTestCls =", YTestCls[:6], "\n")

('YTest =', matrix([[ 0.,  0.,  1.],
[ 1.,  0.,  0.],
[ 0.,  0.,  1.],
[ 0.,  0.,  1.],
[ 0.,  0.,  1.],
[ 1.,  0.,  0.]]))
('YTestCls =', matrix([[ 2.],
[ 0.],
[ 2.],
[ 2.],
[ 2.],
[ 0.]]) , '\n')

```

1.4.5 Ewaluacja

```

In [59]: acc = 0.0
for i in range(len(YTestCls)):
    cls, probs = classify(thetas, XTest[i], i < 6)
    correctCls = int(YTestCls[i].item())
    if i < 6:

```

```

        print(correctCls, " <=>", cls, " -- ", cls == correctCls, np.round(probs, 4)
        acc += correctCls == cls
    print("\nAccuracy =", acc/len(XTest))

('regs  =', array([-7.69442729,  0.69221651,  1.91571479]))
('probs =', array([ 0.     ,  0.227,  0.773]))
(2, ' <=>', 2, ' -- ', True, [0.0001, 0.2273, 0.7726])
('regs  =', array([ 2.75684328, -1.41961889, -9.58991675]))
('probs =', array([ 0.985,  0.015,  0.     ]))
(0, ' <=>', 0, ' -- ', True, [0.9849, 0.0151, 0.0])
('regs  =', array([-7.02867886,  0.09552286,  1.9497746 ]))
('probs =', array([ 0.     ,  0.135,  0.865]))
(2, ' <=>', 2, ' -- ', True, [0.0001, 0.1354, 0.8645])
('regs  =', array([-5.57547589, -0.24632327,  1.16421515]))
('probs =', array([ 0.001,  0.196,  0.803]))
(2, ' <=>', 2, ' -- ', True, [0.001, 0.196, 0.8031])
('regs  =', array([-6.74108941,  0.77272949,  1.68582768]))
('probs =', array([ 0.     ,  0.286,  0.714]))
(2, ' <=>', 2, ' -- ', True, [0.0002, 0.2863, 0.7135])
('regs  =', array([ 3.36547865, -2.11080509, -11.38109326]))
('probs =', array([ 0.996,  0.004,  0.     ]))
(0, ' <=>', 0, ' -- ', True, [0.9958, 0.0042, 0.0])
('Accuracy =', 1.0)

```