KONFERENCJA DLA NAUCZYCIELI
przedmiotów ścisłych i przyrodniczych
MOSTY DO PRZYSZŁOŚCI

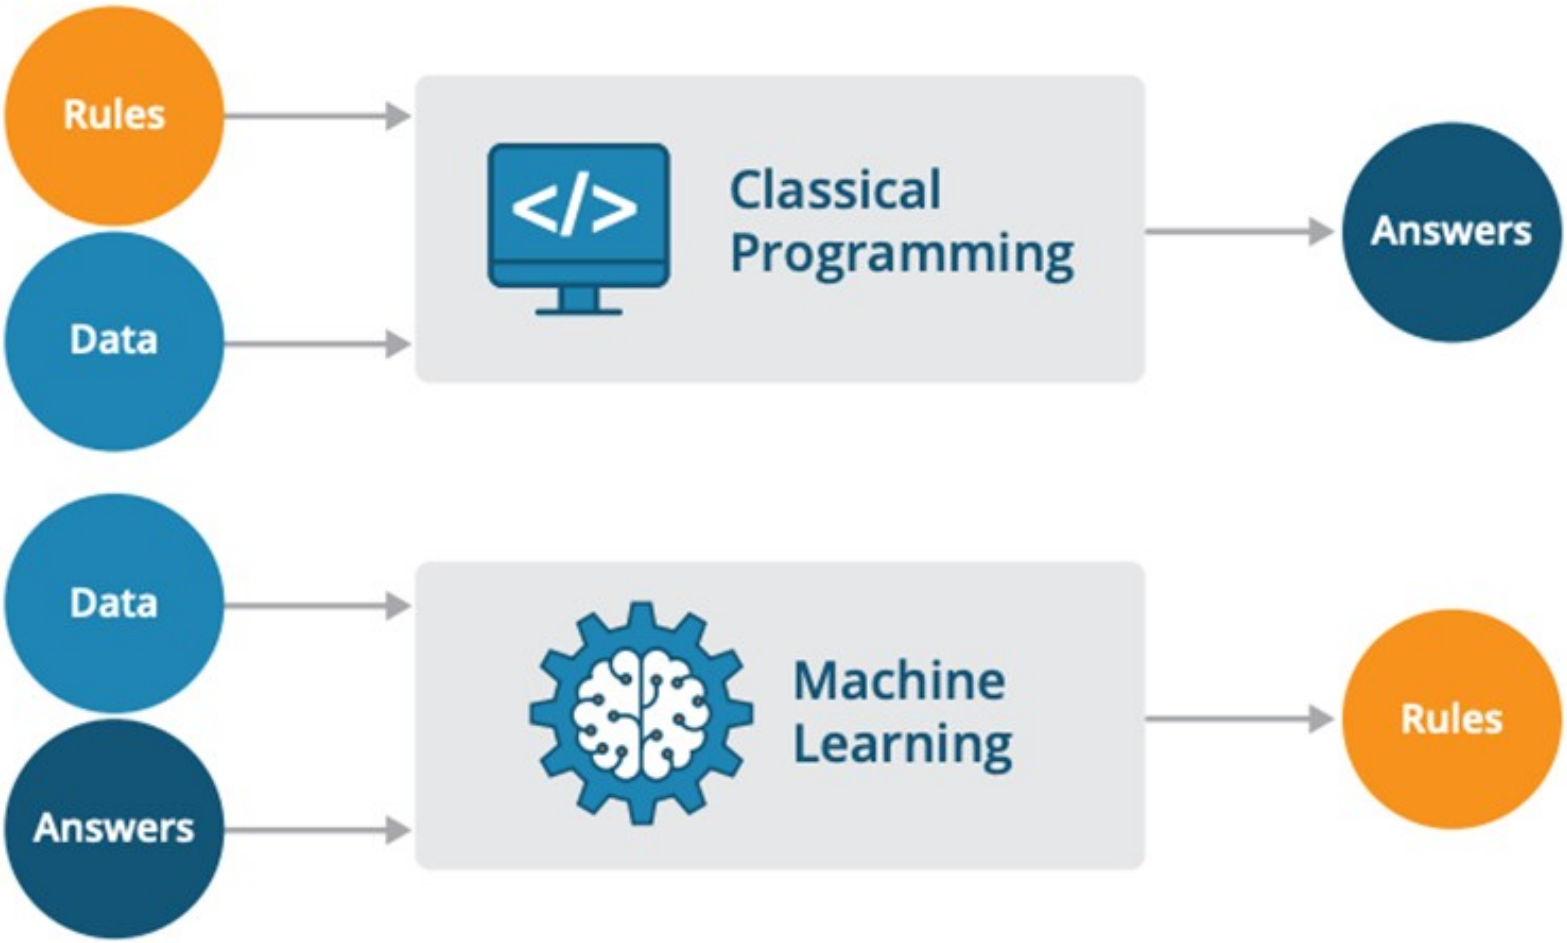
14 listopada 2026, Chorzów
Wydział Nauk Ścisłych i Technicznych

AI dla każdego: Zbuduj własną sieć neuronową bez znajomości Pythona

UNIWERSYTET ŚLĄSKI
WYDZIAŁ NAUK ŚCISŁYCH I TECHNICZNYCH

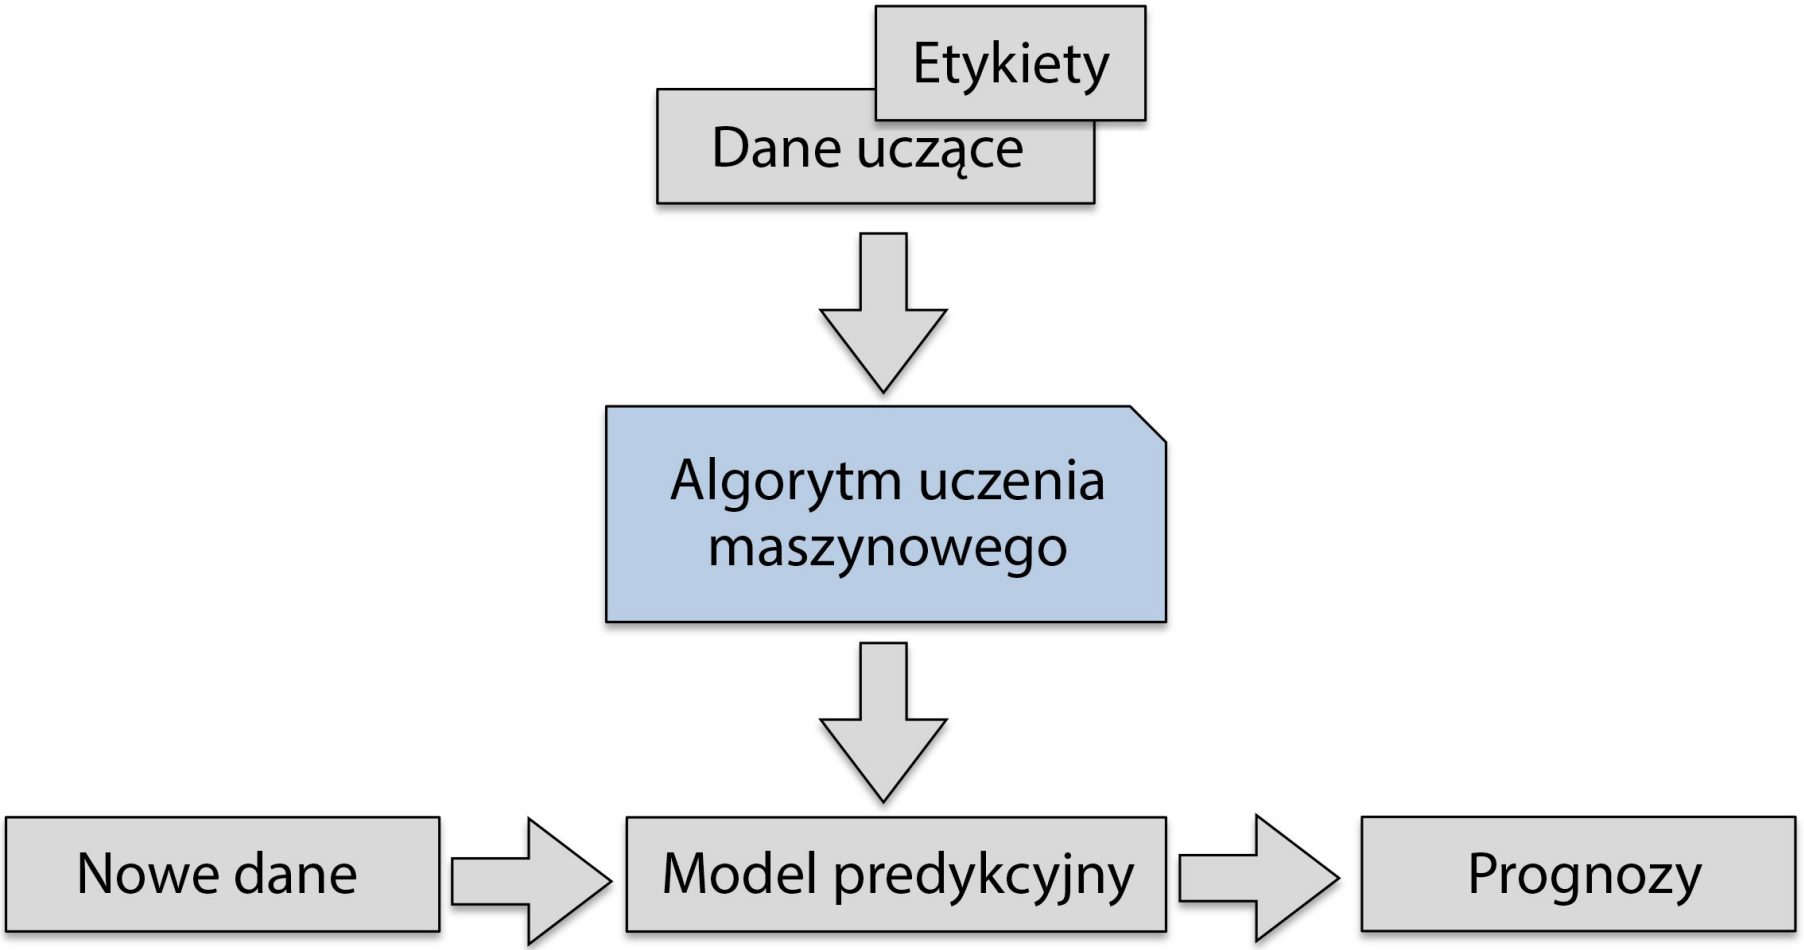
Katarzyna Schmidt

Uczenie maszynowe



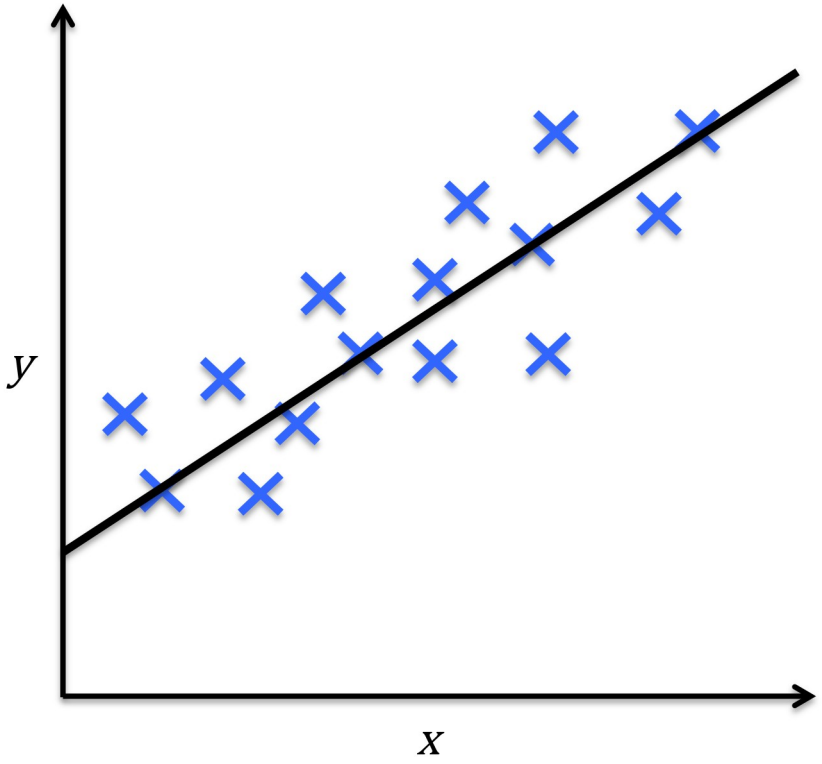
S. Raschka, „Python Uczenie maszynowe”, Helion 2018

Nadzorowane uczenie maszynowe

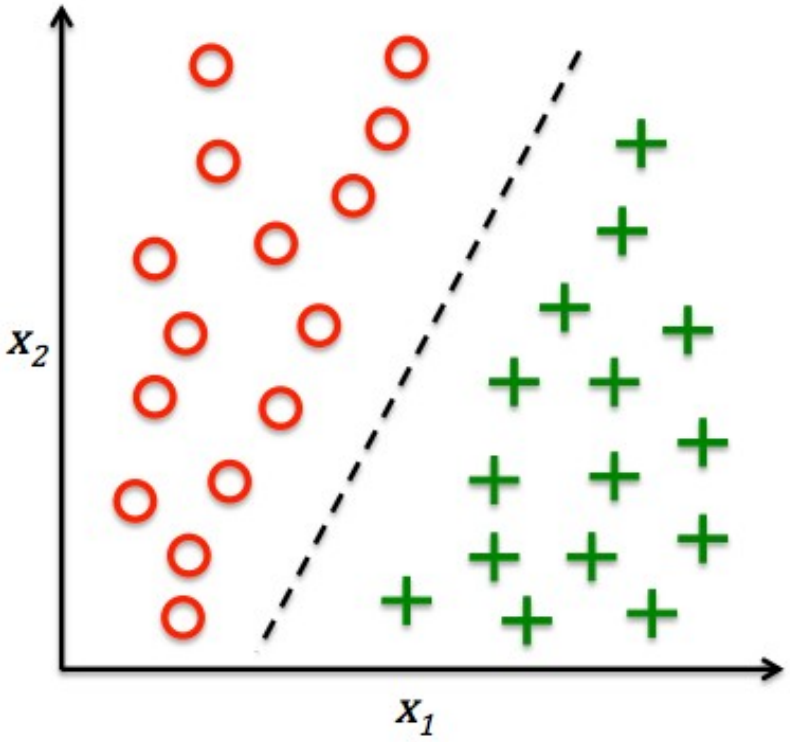


S. Raschka, „Python Uczenie maszynowe”, Helion 2018

Nadzorowane uczenie maszynowe



Przykład najprostszej regresji liniowej
$y \in R$



Przykład logistycznej regresji binarnej
$y \in N$, w tym przypadku $y \in [0,1]$

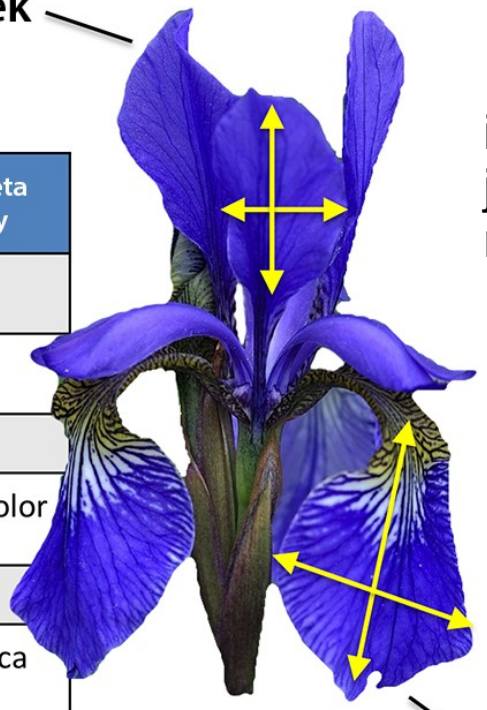
S. Raschka, „Python Uczenie maszynowe”, Helion 2018

Nadzorowane uczenie maszynowe

Próbki
(wystąpienia, obserwacje)
m – liczba próbek

	Długość działki	Szerokość działki	Długość płatka	Szerokość płatka	Etykieta klasy
1	5.1	3.5	1.4	0.2	Setosa
2	4.9	3.0	1.4	0.2	Setosa
...					
50	6.4	3.5	4.5	1.2	Versicolor
...					
150	5.9	3.0	5.0	1.8	Virginica

Płatek



Działka kielicha

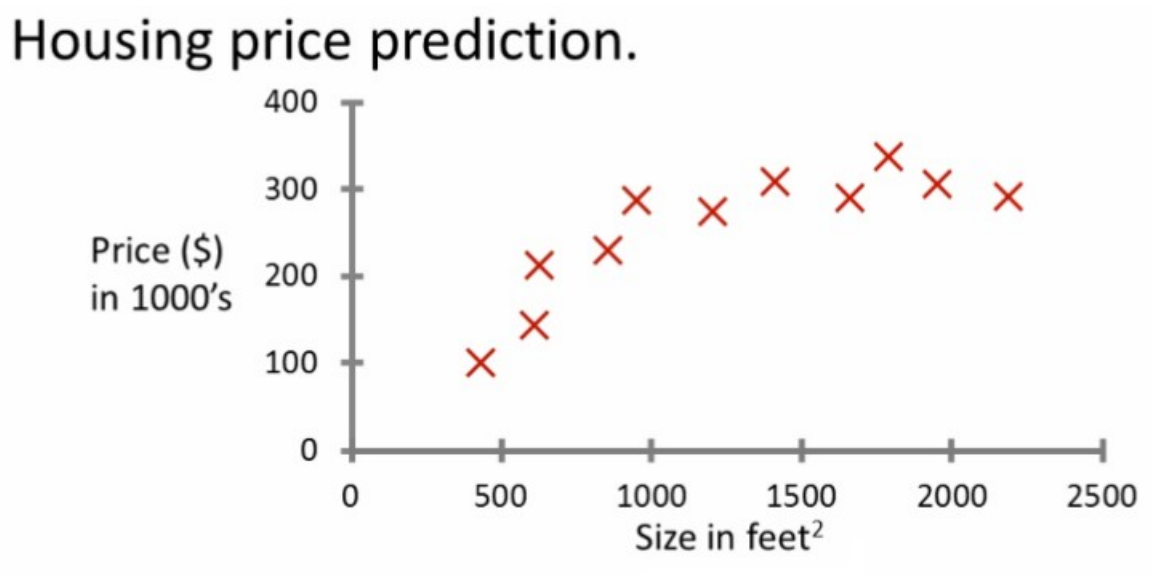
Indeksowanie:
i – po wierszach
j – po kolumnach
np. $x_{50,1} = 4.5$

Cechy zawsze oznaczane jako x
(atrybuty, pomiary, wymiary)
n – liczba cech

Etykiety klas
(cele)
zawsze oznaczane jako y

S. Raschka, „Python Uczenie maszynowe”, Helion 2018

Regresja liniowa jednej zmiennej



$y \in R$

Uczenie maszynowe nadzorowane:

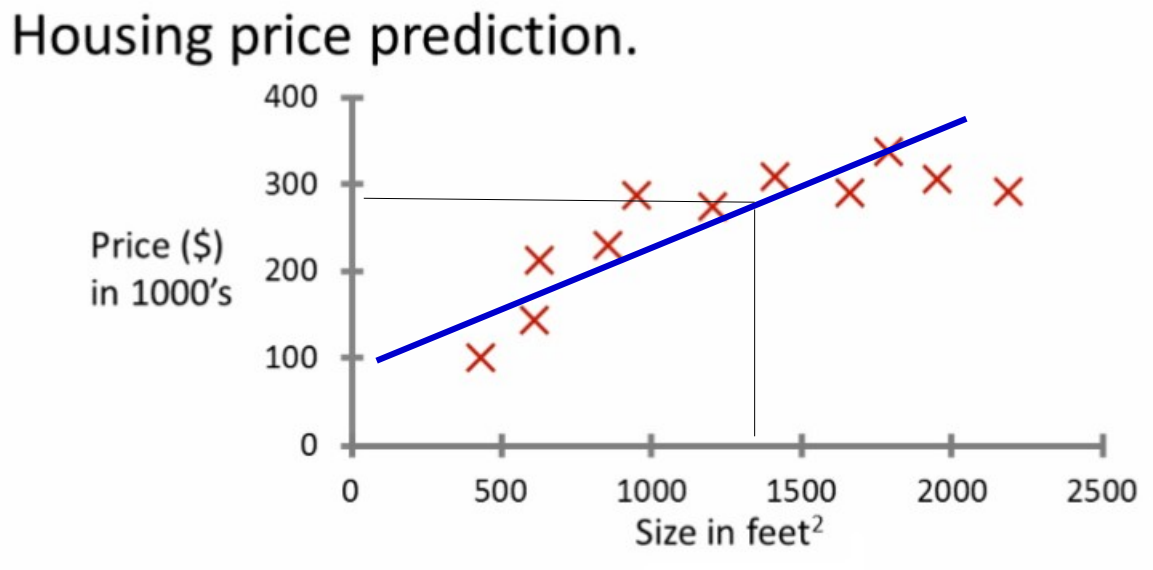
Zestaw treningowy z etykietą/wartością y, w tym wypadku z ceną mieszkania dla każdego przypadku zestawu treningowego

Size in feet² (x)	Price ($) in 1000's (y)
2104	460
1416	232
1534	315
852	178
...	...

m = 47

Machine Learning - complete course notes - Alex Holehouse [online], Alex Holehouse [dostęp październik 2019], http://www.holehouse.org/mlclass/

Regresja liniowa jednej zmiennej



Uczenie maszynowe nadzorowane:

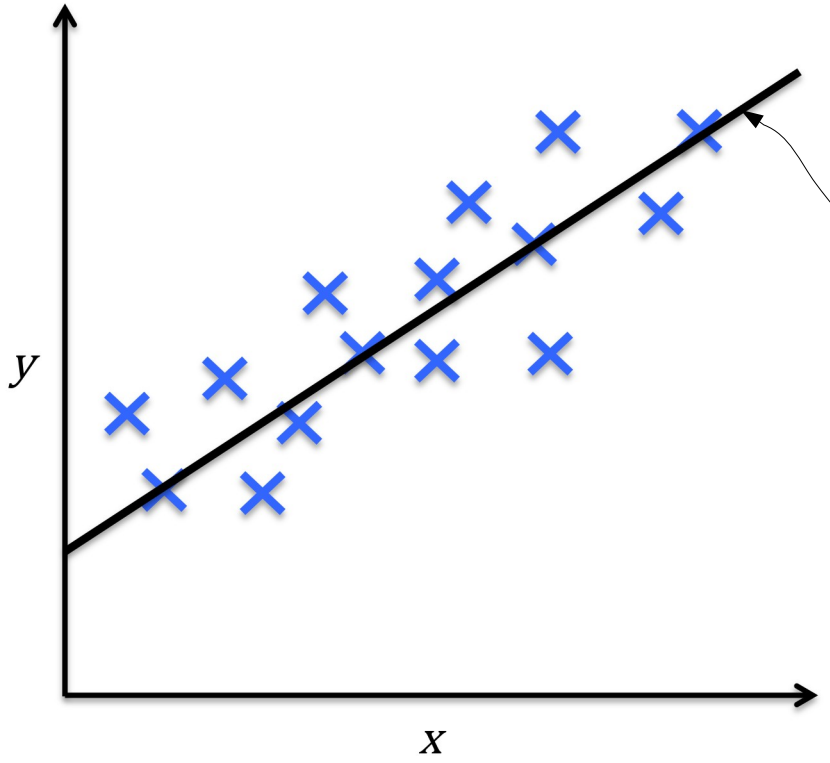
Zestaw treningowy z etykietą/wartoscią y, w tym wypadku z ceną mieszkania dla każdego przypadku zestawu treningowego

Size in feet² (x)	Price ($) in 1000's (y)
2104	460
1416	232
1534	315
852	178
...	...

m = 47

Regresja liniowa jednej zmiennej

Czym jest hipoteza?
Jaką ma postać?



$$h_\theta(x) = \theta_0 + \theta_1 x$$

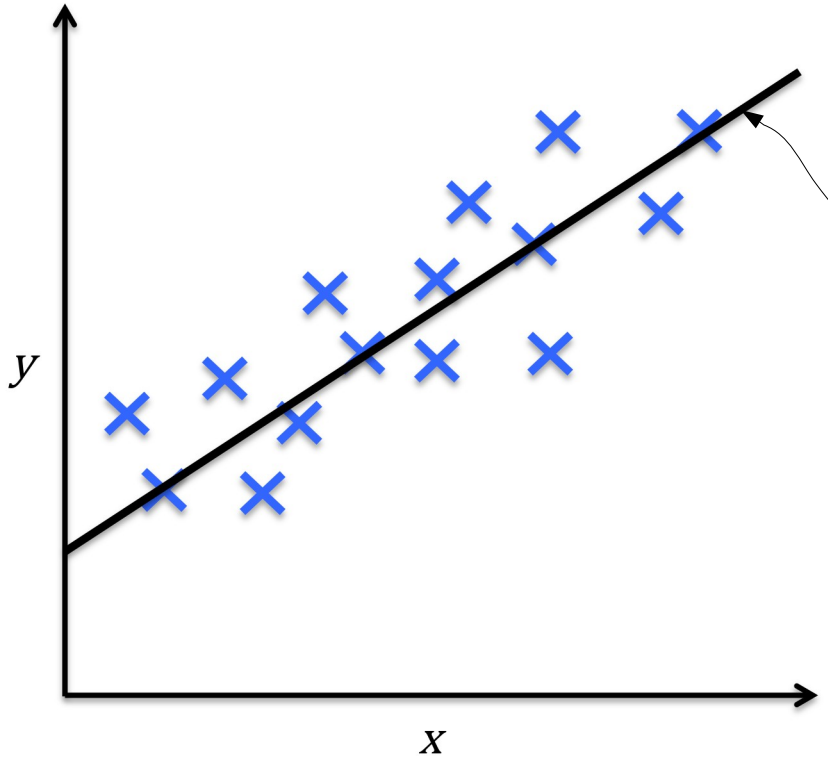
Cel:
znaleźć takie parametry Θ_0 i Θ_1 aby jak najlepiej opisywały dane treningowe.

Rysunek przedstawia sytuację, gdzie takie parametry już znaleziono.

S. Raschka, „Python Uczenie maszynowe”, Helion 2018

Regresja liniowa jednej zmiennej

Czym jest funkcja kosztu (strata)?
Jaką ma postać?



$$h_\theta(x) = \theta_0 + \theta_1 x$$

$$(\theta_0, \theta_1) = \frac{1}{2m} \sum_{i=0}^{m-1} \left(h_\theta(x_i) - y_i\right)^2$$

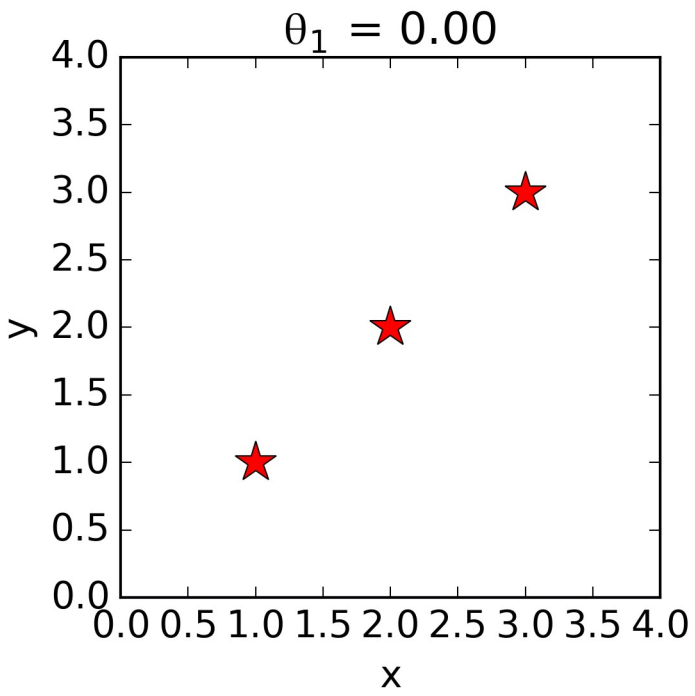
Cel:
znaleźć minimum funkcji kosztu.

S. Raschka, „Python Uczenie maszynowe”, Helion 2018

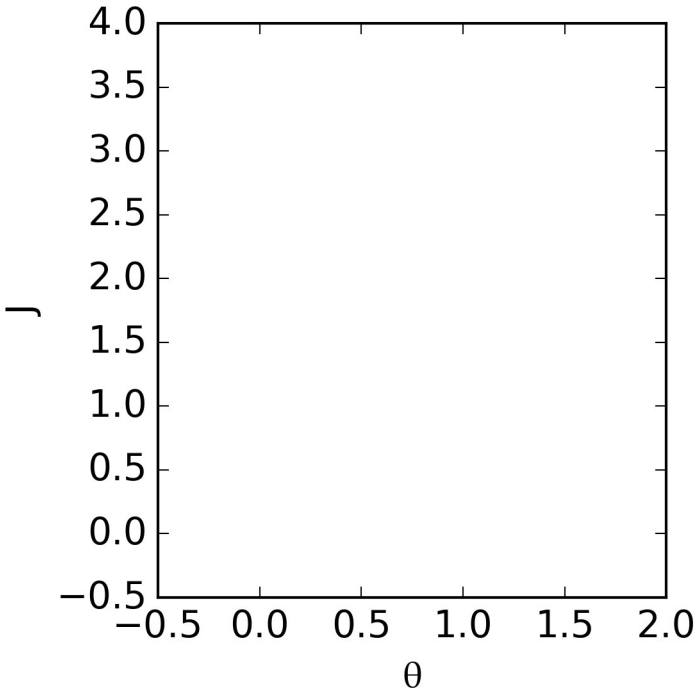
Regresja liniowa jednej zmiennej

$$J(\theta_1)=\frac{1}{2m}\sum_{i=0}^{m-1}\left(h_\theta(x_i)-y_i\right)^2 \quad gdzie: h_\theta(x)=\theta_1 x$$

$h_\theta(x)$
jest funkcją x



$J(\theta_1)$
jest funkcją θ



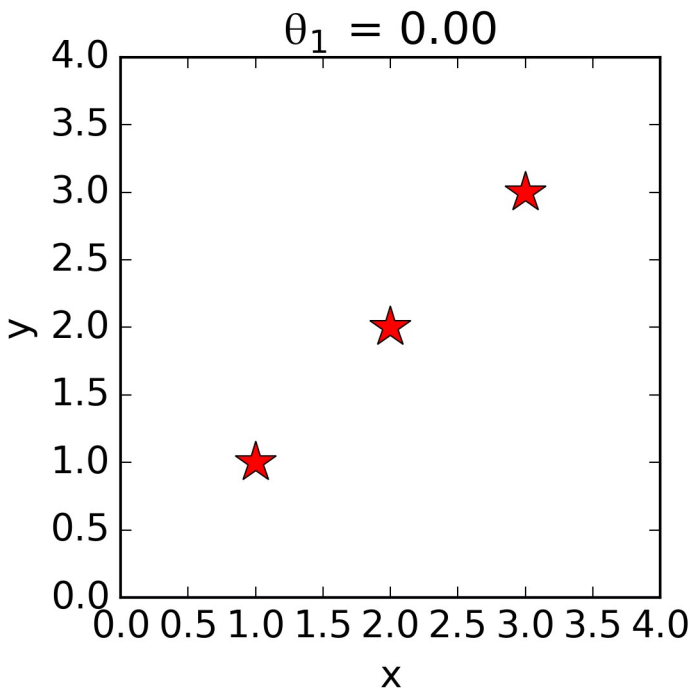
J = ?

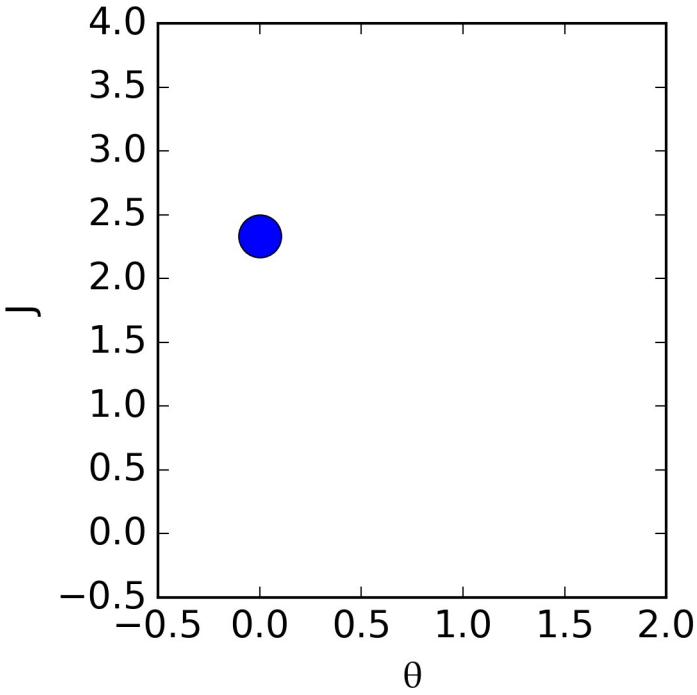
Regresja liniowa jednej zmiennej

$$J(\theta_1)=\frac{1}{2m}\sum_{i=0}^{m-1}\left(h_\theta(x_i)-y_i\right)^2 \quad gdzie: h_\theta(x)=\theta_1 x$$

$h_\theta(x)$
jest funkcją x

$J(\theta_1)$
jest funkcją θ



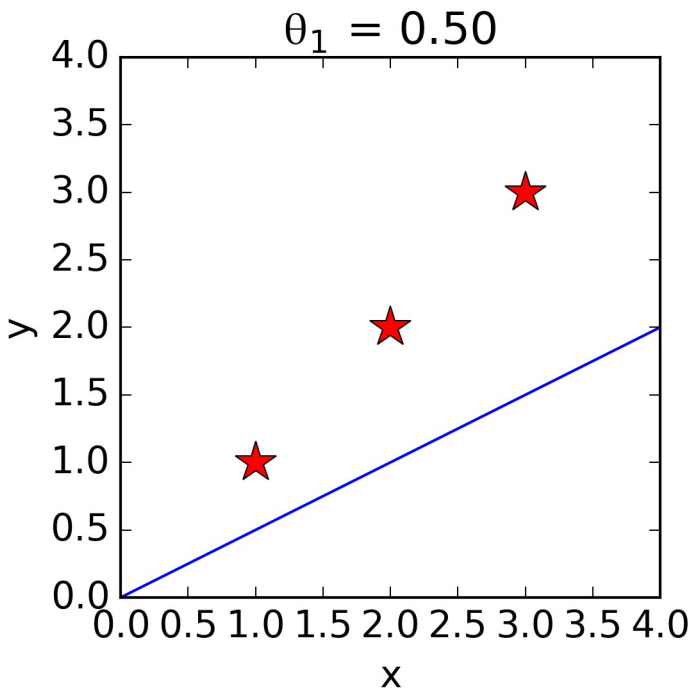


$J = ((0*1 - 1)^2 + (0*2 - 2)^2 + (0*3 - 3)^2)/6 = (1 + 4 + 9)/6 \approx 2.3$

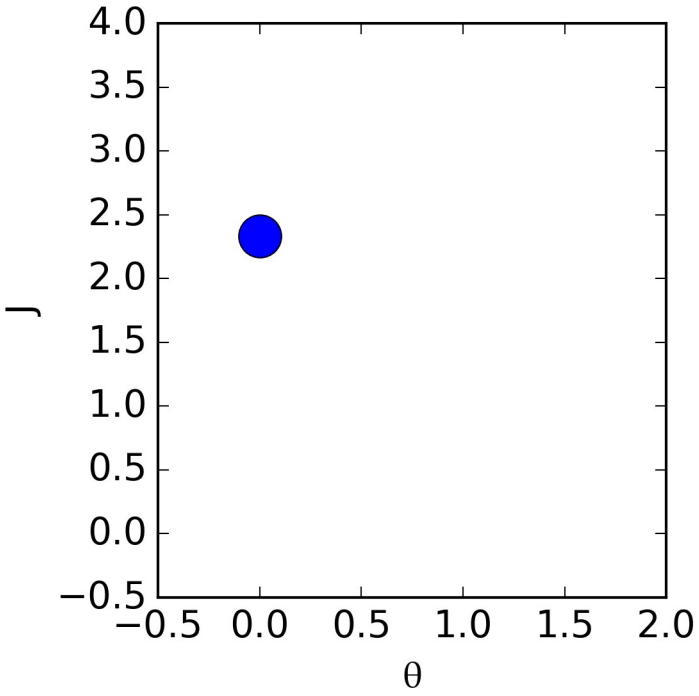
Regresja liniowa jednej zmiennej

$$J(\theta_1)=\frac{1}{2m}\sum_{i=0}^{m-1}\left(h_\theta(x_i)-y_i\right)^2 \quad gdzie: h_\theta(x)=\theta_1 x$$

$h_\theta(x)$
jest funkcją x



$J(\theta_1)$
jest funkcją θ

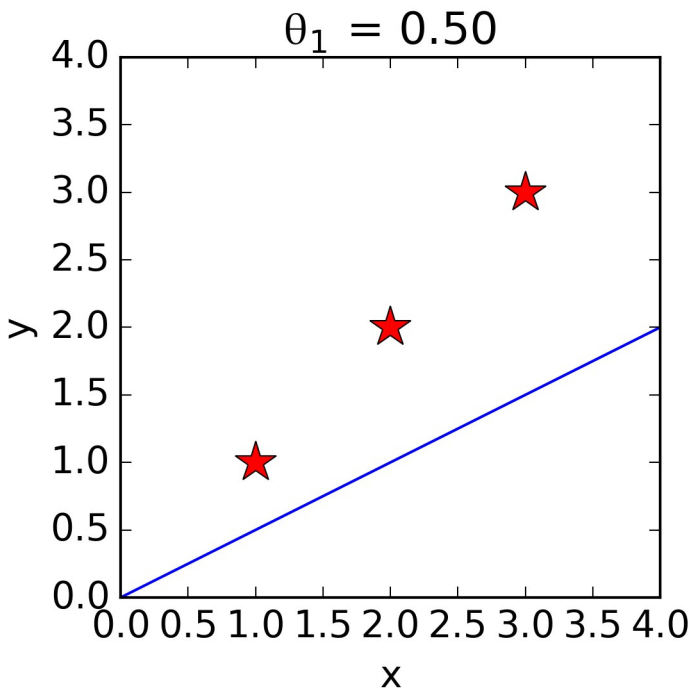


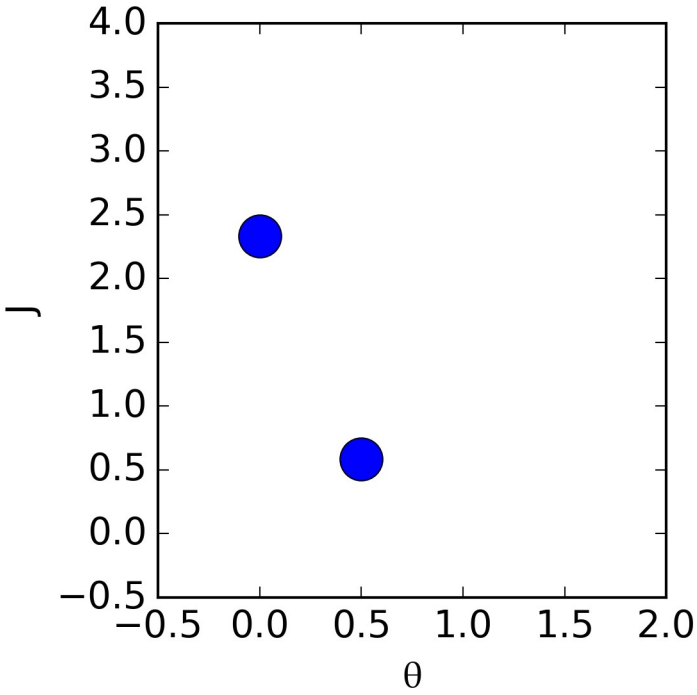
Regresja liniowa jednej zmiennej

$$J(\theta_1)=\frac{1}{2m}\sum_{i=0}^{m-1}\left(h_\theta(x_i)-y_i\right)^2 \quad gdzie: h_\theta(x)=\theta_1 x$$

$h_\theta(x)$
jest funkcją x

$J(\theta_1)$
jest funkcją θ



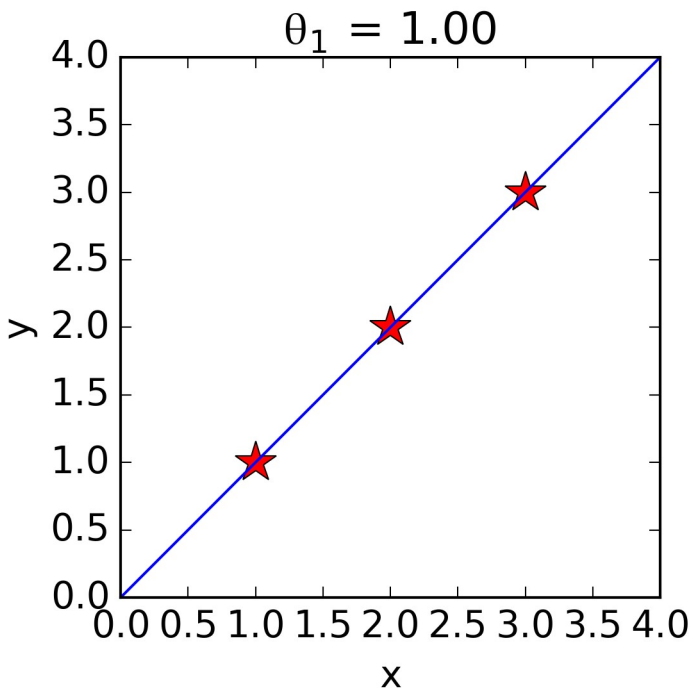


$J = ((0.5*1 - 1)^2 + (0.5*2 - 2)^2 + (0.5*3 - 3)^2)/6 = (0.25 + 1 + 2{,}25)/6 \approx 0.58$

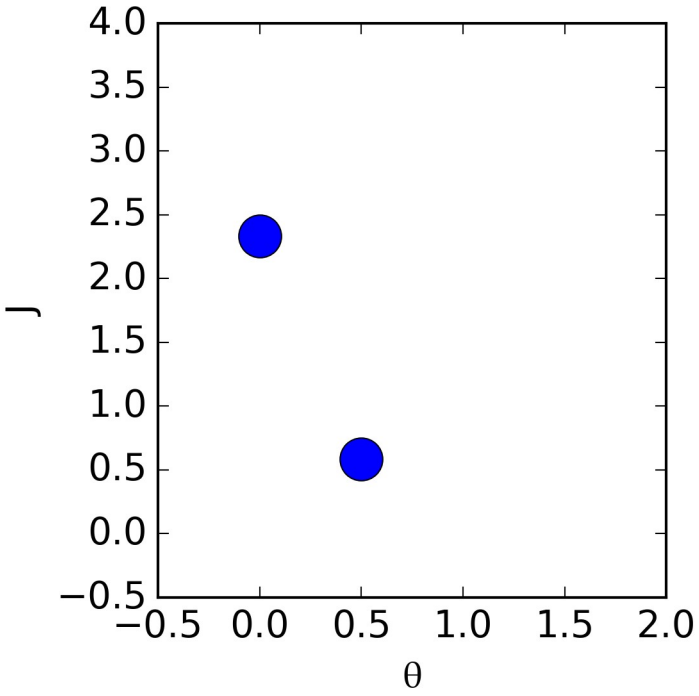
Regresja liniowa jednej zmiennej

$$J(\theta_1)=\frac{1}{2m}\sum_{i=0}^{m-1}\left(h_\theta(x_i)-y_i\right)^2 \quad gdzie: h_\theta(x)=\theta_1 x$$

$h_\theta(x)$
jest funkcją x



$J(\theta_1)$
jest funkcją θ

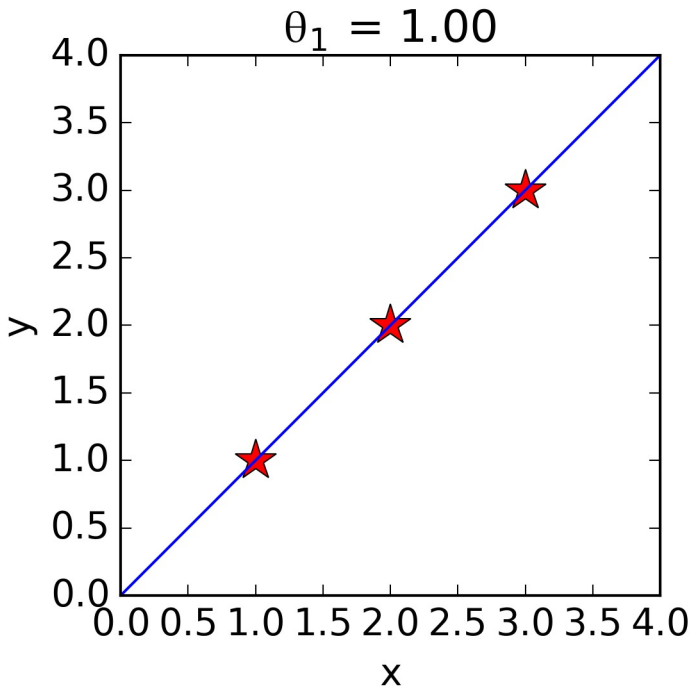


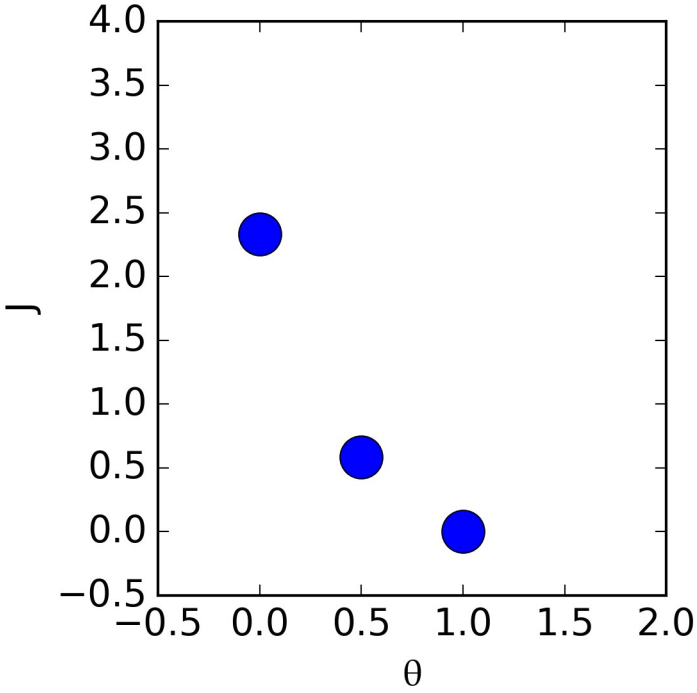
Regresja liniowa jednej zmiennej

$$J(\theta_1)=\frac{1}{2m}\sum_{i=0}^{m-1}\left(h_\theta(x_i)-y_i\right)^2 \quad gdzie: h_\theta(x)=\theta_1 x$$

$h_\theta(x)$
jest funkcją x

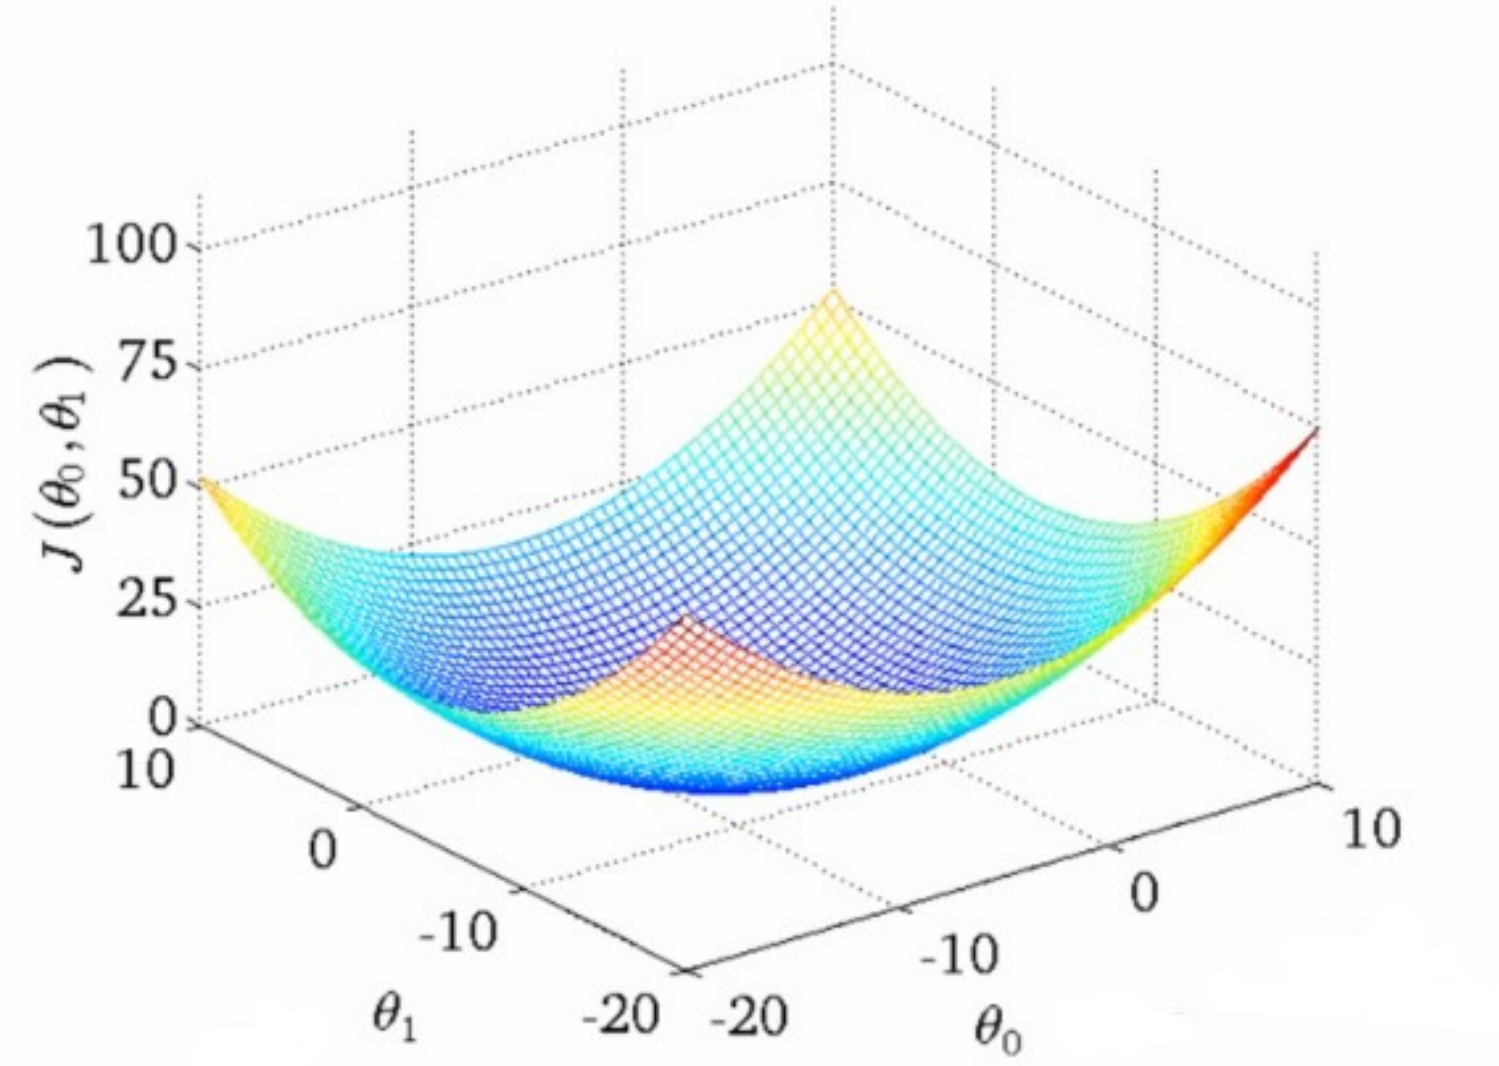
$J(\theta_1)$
jest funkcją θ





$J = ((1*1 - 1)^2 + (1*2 - 2)^2 + (1*3 - 3)^2)/6 = (0 + 0 + 0)/6 = 0$

Regresja liniowa jednej zmiennej



Regresja liniowa jednej zmiennej

Mamy funkcję straty $J(\Theta_0, \Theta_1)$
Chcemy znaleźć min $J(\Theta_0, \Theta_1)$

Zarys:

- Zacznij od jakichś wartości parametrów Θ_0, Θ_1
- Zmieniaj parametry Θ_0, Θ_1 w celu redukcji $J(\Theta_0, \Theta_1)$ aż funkcja osiągnie minimum

Algorytm spadku gradientowego

Powtarzaj, aż do zbieżności {

$$\theta_j := \theta_j - \alpha \frac{\delta}{\delta \theta_j} J(\theta_0, \theta_1)$$ *dla j = 0, 1*

}

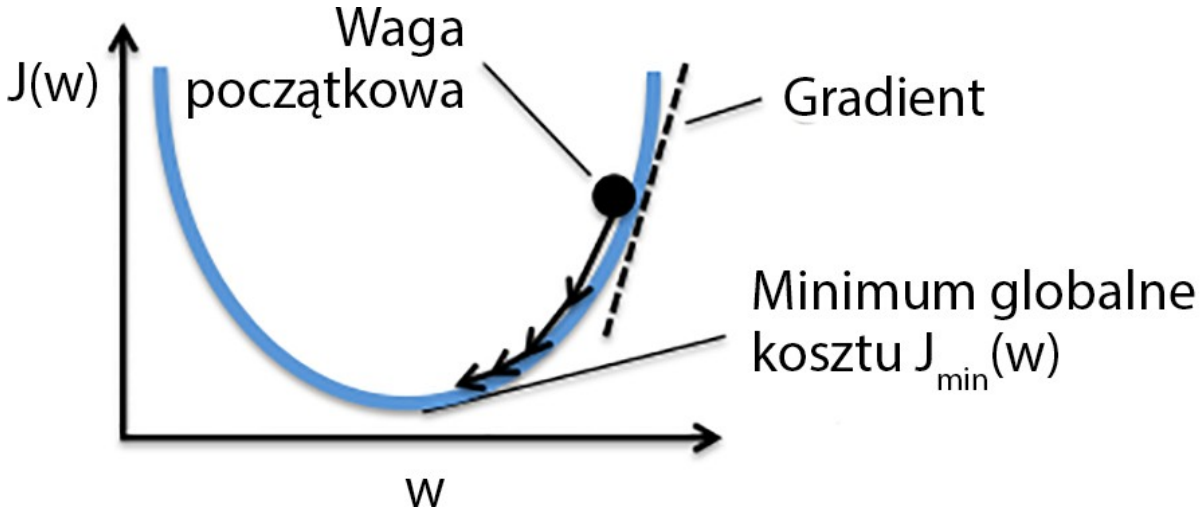
Regresja liniowa jednej zmiennej

$$\theta_j := \theta_j - \alpha \frac{\delta}{\delta \theta_j} J(\theta_0, \theta_1)$$

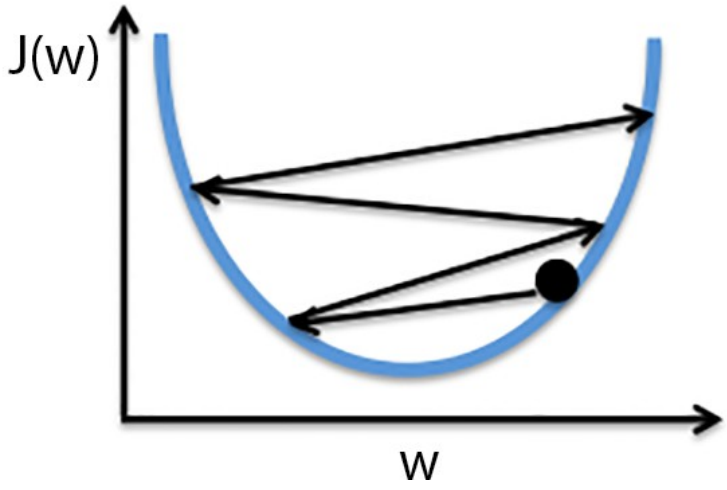
Czym jest gradient i jak wpływa na algorytm spadku gradientowego?

Co się stanie, gdy parametr θ będzie odpowiadał lokalnemu minimum?

Czym jest α i jak wpływa na algorytm spadku gradientowego?



Zbyt małe α



Zbyt duże α

S. Raschka, „Python Uczenie maszynowe”, Helion 2018

Regresja liniowa jednej zmiennej

$$\frac{\delta}{\delta\theta_j} J(\theta_0, \theta_1)$$

$$\frac{\delta}{\delta\theta_j} \frac{1}{2m} \sum_{i=0}^{m-1} \left(h_\theta(x_i) - y_i\right)^2$$

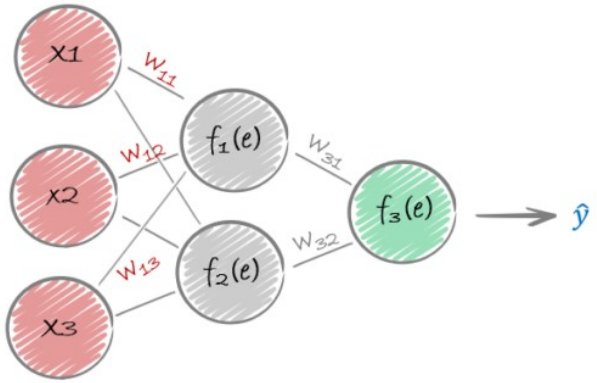
$$\frac{\delta}{\delta\theta_j} \frac{1}{2m} \sum_{i=0}^{m-1} \left(\theta_0 + \theta_1 x_i - y_i\right)^2$$

$$j=0: \quad \frac{\delta}{\delta\theta_0} J(\theta_0, \theta_1) = \frac{1}{m} \sum_{i=0}^{m-1} \left(h_\theta(x) - y\right)$$

$$j=1: \quad \frac{\delta}{\delta\theta_1} J(\theta_0, \theta_1) = \frac{1}{m} \sum_{i=0}^{m-1} \left(h_\theta(x) - y\right) x_{i1}$$

Sieci neuronowe

Czym jest i jak uczy się sieć neuronowa (Mirosław Mamczur)

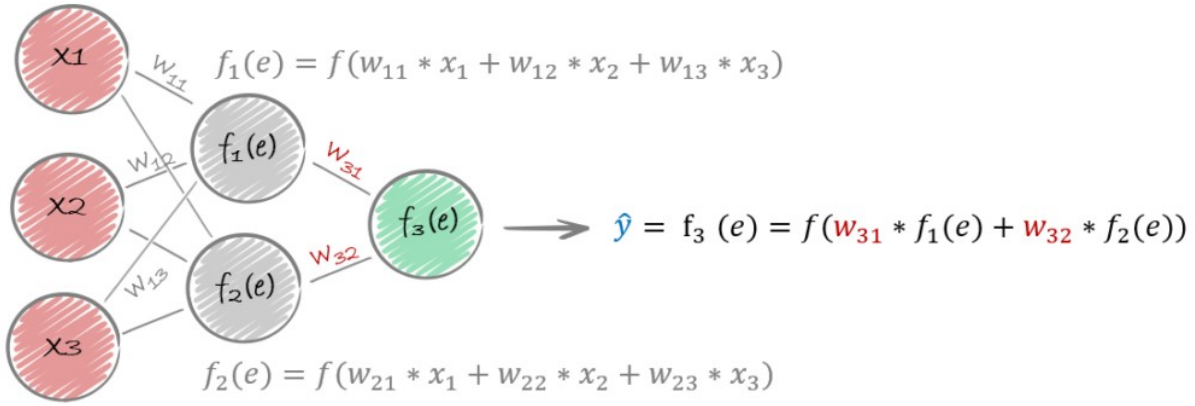


Gdzie:
Charakterystyki: x1, x2, x3
Wagi: w_{xx}
predykcja: $\hat{y}$
Blok sumujący:

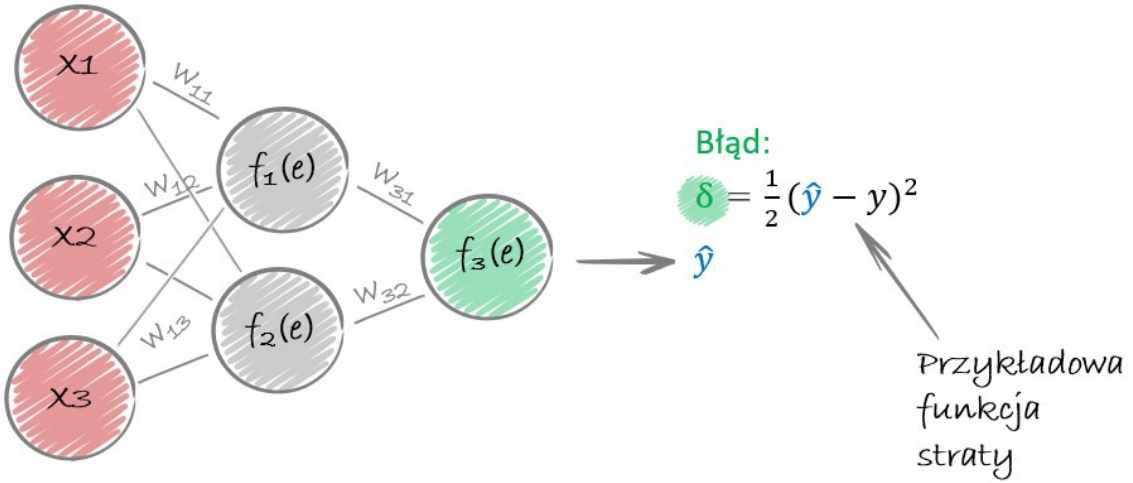
$$e = w_{11} * x_1 + w_{12} * x_2 + w_{13} * x_3$$

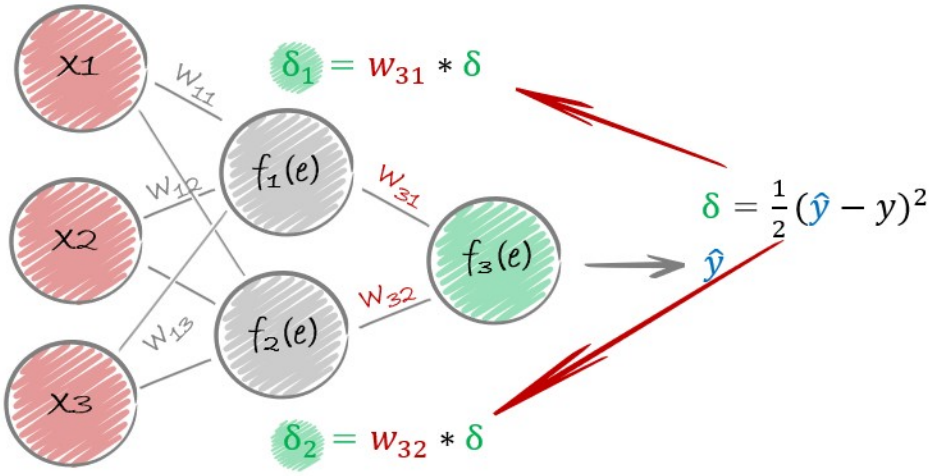
Blok aktywacji:

$$f_1(e) = f(w_{11} * x_1 + w_{12} * x_2 + w_{13} * x_3)$$



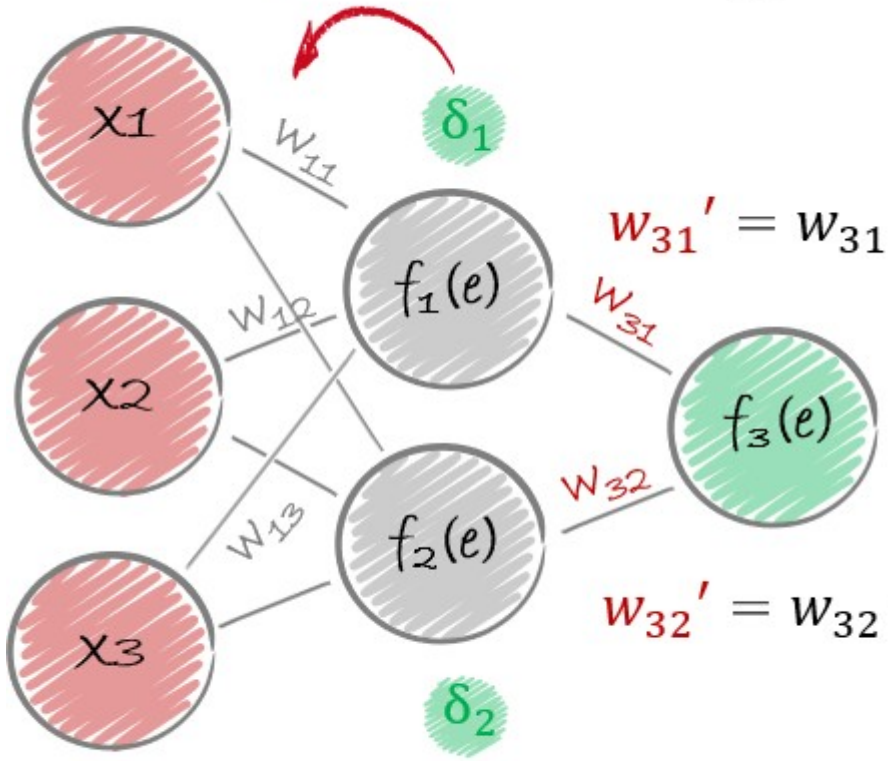
Sieci neuronowe





Sieci neuronowe

$$w_{11}' = w_{11} + \eta\delta_1 \frac{df_1(e)}{de} x_1 \qquad w_{12}' = w_{12} + \eta\delta_1 \frac{df_1(e)}{de} x_2$$



$$w_{31}' = w_{31} + \eta\delta \frac{df_3(e)}{de} f_1(e)$$

$$w_{32}' = w_{32} + \eta\delta \frac{df_3(e)}{de} f_1(e)$$

$$w_{13}' = w_{13} + \eta\delta_1 \frac{df_1(e)}{de} x_3$$

Literatura/Materiały video

- „Machine Learning Lecture Notes”, [online], Andrew Ng [dostęp październik 2019]

  http://cs229.stanford.edu/notes/

- „Machine Learning Course” [online], Andrew Ng [dostęp październik 2019]

  https://www.youtube.com/playlist?list=PLLssT5z_DsK-h9vYZkQkYNWcItqhlRJLN

- Machine Learning – complete course notes – Alex Holehouse [online], Alex Holehouse [dostęp październik 2019

  https://www.holehouse.org/mlclass/

- Sebastian Raschka, „Python Uczenie maszynowe”, Helion 2018

- Czym jest i jak uczy się sieć neuronowa, [online], Mirosław Mamczur
  https://miroslawmamczur.pl/czym-jest-i-jak-sie-uczy-sztuczna-siec-neuronowa/