

# Systemy agentowe

## Klasyfikacja

Jędrzej Potoniec


# Klasyfikacja

## Zadanie klasyfikacji binarnej

Dla danego wektora cech  $\mathbf{x}$  opisującego obiekt przewidzieć czy obiekt należy do klasy *pozytywnej*  $y = 1$  czy *negatywnej*  $y = 0$  (lub  $y = -1$ ).

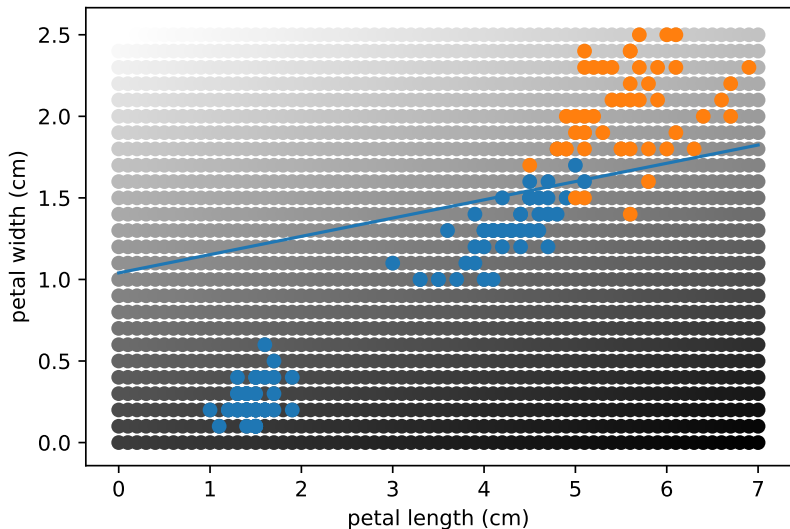
# Irysy

Pomarańczowy: Iris Virginica, niebieski: pozostałe

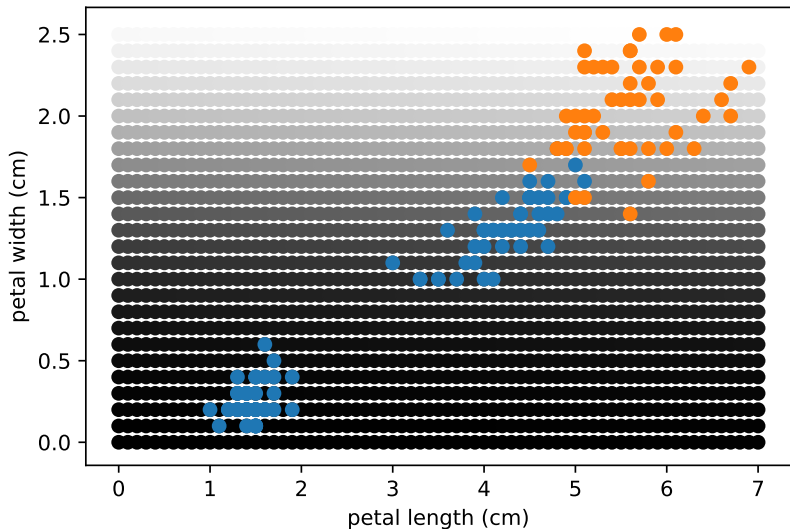


# Przewidywanie prawdopodobieństwa – regresja liniowa


Punkty w tle: prawd. Iris Virginica (jaśniej=wyzsze)



# Przewidywanie prawdopodobieństwa – regresja logistyczna




# Granica decyzyjna (ang. decision boundary)




A. Géron, *Hands-On Machine Learning with Scikit-Learn and TensorFlow* 2017

# Granica decyzyjna (ang. decision boundary)



A. Géron, *Hands-On Machine Learning with Scikit-Learn and TensorFlow* 2017

# Funkcja logistyczna



A. Géron, *Hands-On Machine Learning with Scikit-Learn and TensorFlow* 2017



## Pochodna funkcji logisytycznej

$$\sigma(t) = \frac{1}{1 + e^{-t}}$$

### Zadanie

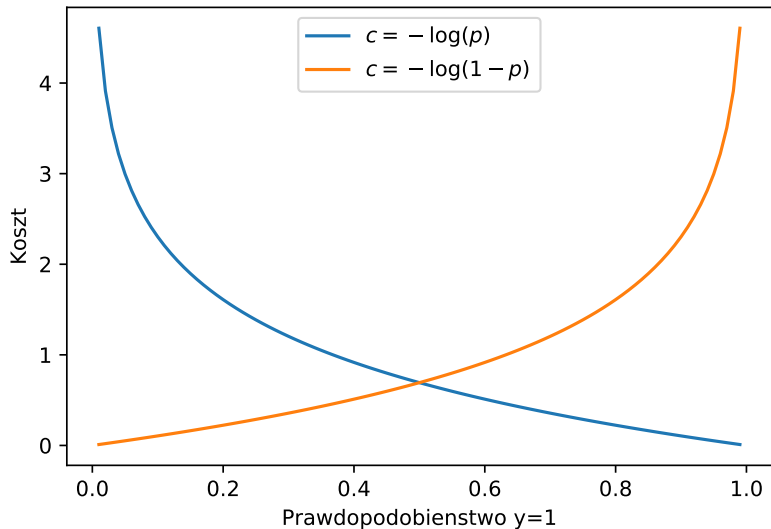
Wiadomo, że  $\sigma(t_0) = .1$ . Czy da się na tej podstawie prosto obliczyć wartość pochodnej  $\sigma'(t)$  w punkcie  $t_0$ ?

# Regresja logistyczna

$$\hat{p} = \sigma(\mathbf{xw})$$

$$\hat{y} = \begin{cases} 1 & \hat{p} \geq 0,5 \\ 0 & \hat{p} < 0,5 \end{cases}$$

## Funkcja kosztu dla pojedynczego przykładu



## Funkcja kosztu dla pojedynczego przykładu

### Zadanie

Zapisać poniższą funkcję jako pojedyncze wyrażenie (używając dodawania, mnożenia itp.):

$$c(y, p) = \begin{cases} -\log(p) & y = 1 \\ -\log(1 - p) & y = 0 \end{cases}$$

## Funkcja kosztu dla całego problemu

$$\mathbf{p} = \sigma(\mathbf{X}\mathbf{w})$$

$$J(\mathbf{w}) = \frac{1}{n} \sum_{i=1}^n c(y_i, p_i) =$$

$$-\frac{1}{n} \sum_{i=1}^n [y_i \log p_i + (1 - y_i) \log(1 - p_i)]$$

## Funkcja kosztu dla całego problemu

$$\mathbf{p} = \sigma(\mathbf{X}\mathbf{w})$$

$$J(\mathbf{w}) = \frac{1}{n} \sum_{i=1}^n c(y_i, p_i) =$$

$$-\frac{1}{n} \sum_{i=1}^n [y_i \log p_i + (1 - y_i) \log(1 - p_i)]$$

$$\frac{\partial J}{\partial w_j} = \frac{1}{n} \sum_{i=1}^n (\sigma(\mathbf{X}_i \mathbf{w}) - y_i) X_{i,j}$$

## Softmax regression/Multinomial logistic regression

### Zadanie klasyfikacji

Dla danego wektora cech  $\mathbf{x}$  opisującego obiekt przewidzieć, do której z  $K$  predefiniowanych klas należy obiekt:  $y \in \{1, 2, \dots, K\}$

$\mathbf{W}$  macierz wag typu  $p \times k$

$\mathbf{P}$  macierz prawdopodobieństw typu  $n \times k$

$$\hat{\mathbf{P}} = \sigma(\mathbf{XW}) = \left[ \frac{\sigma(\mathbf{X}_{i,\cdot} \mathbf{W}_{\cdot,k})}{\sum_{l=1}^K \sigma(\mathbf{X}_{i,\cdot} \mathbf{W}_{\cdot,l})} \right]_{i,k}$$

$$\hat{y}_i = \arg \max_k P_{i,k} = \arg \max_k \mathbf{X}_{i,\cdot} \mathbf{W}_{\cdot,k}$$

## Uczenie regresji softmax

$$Y_{i,k} = \begin{cases} 1 & y_i = k \\ 0 & \text{w przeciwnym przypadku} \end{cases}$$

$$J(\mathbf{W}) = -\frac{1}{n} \sum_{i=1}^n \sum_{k=1}^K Y_{i,k} \log \hat{P}_{i,k}$$

$$\nabla_{\mathbf{W}_{\cdot,k}} J(\mathbf{W}) = \frac{1}{n} \sum_{i=1}^n (\hat{P}_{i,k} - Y_{i,k}) \mathbf{x}_i$$