



Politechnika Łódzka



Katedra Automatyki, Biomechaniki i Mechatroniki (K11)

Wydział Mechaniczny



Sztuczna inteligencja w wybranych zastosowaniach inżynierskich

O możliwościach wdrożenia AI w katedrze, podstawowe definicje oraz praktyczne przykłady w klasyfikacji obrazów i analizie sygnałowej

dr inż. Michał Ludwicki



Plan

- *Definicje*
- *Zastosowanie „na co dzień”*
- *Rodzaje i budowa*
- *Przykłady*
 - rozpoznawanie liter
 - szukanie anomalii w danych pomiarowych
 - rozpoznawanie obrazów
- *Podsumowanie*

Definicja

Sztuczna inteligencja [ang. artificial intelligence]

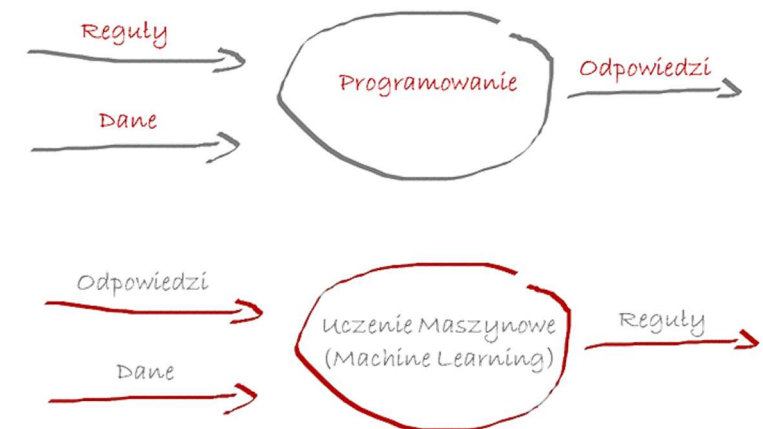
„Zdolność systemu do prawidłowego interpretowania danych pochodzących z zewnętrznych źródeł, nauki na ich podstawie

oraz wykorzystywania tej wiedzy, aby wykonywać określone zadania i osiągać cele poprzez elastyczne dostosowanie.”

Uczenie maszynowe [ang. machine learning]

„Algorytmy, które poprawiają się automatycznie poprzez doświadczenie.”

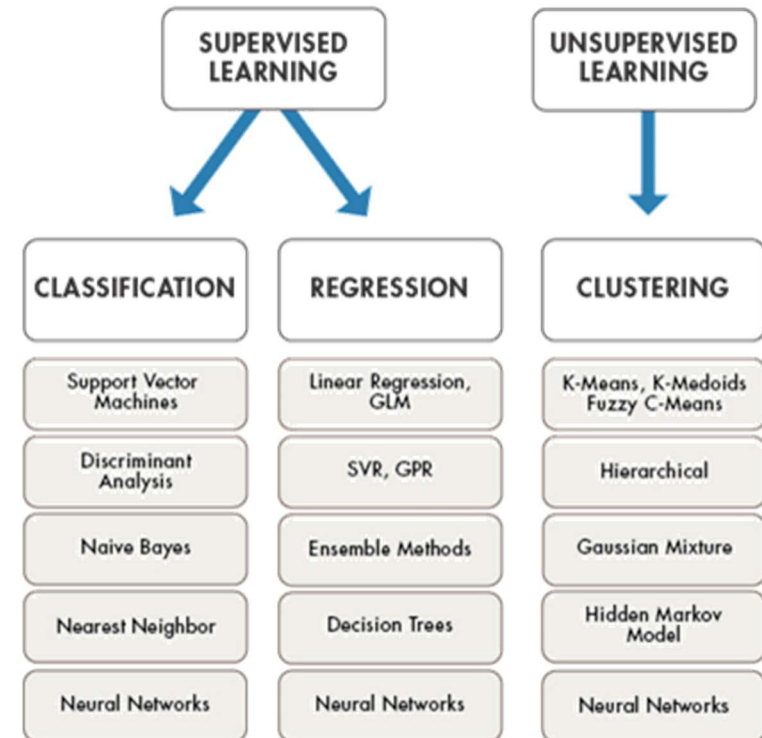
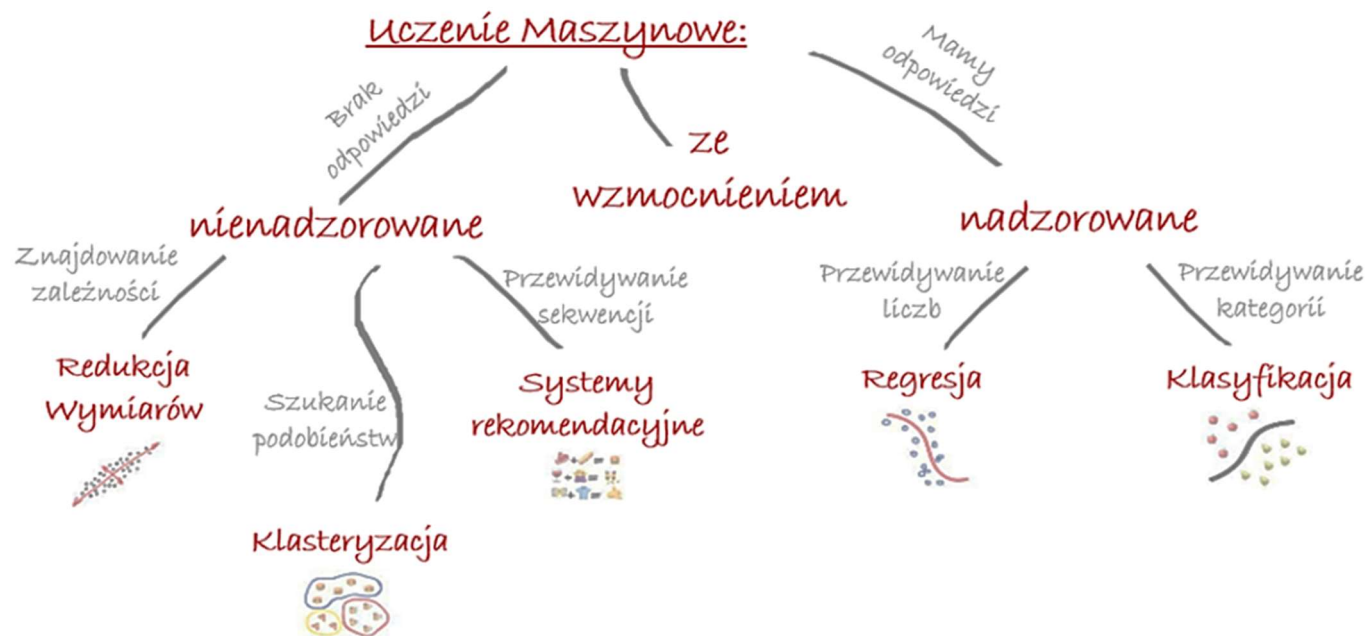
→ Budują model matematyczny do podejmowania decyzji, na podstawie przykładowych danych, bez zaprogramowania (wprost) przez człowieka.





Zastosowania „z życia”

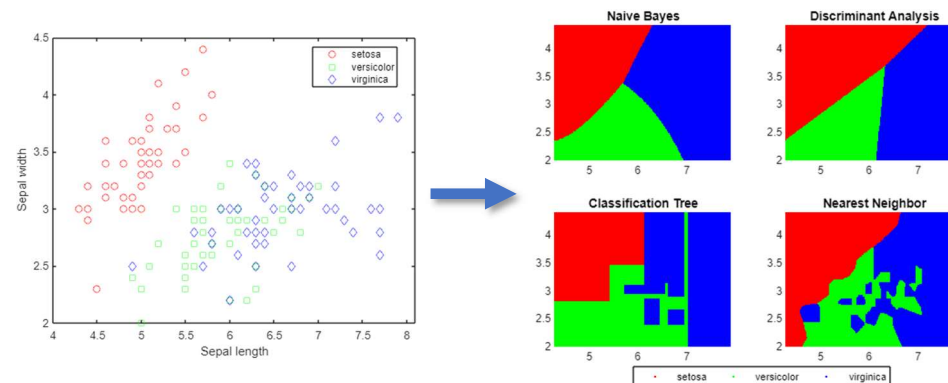
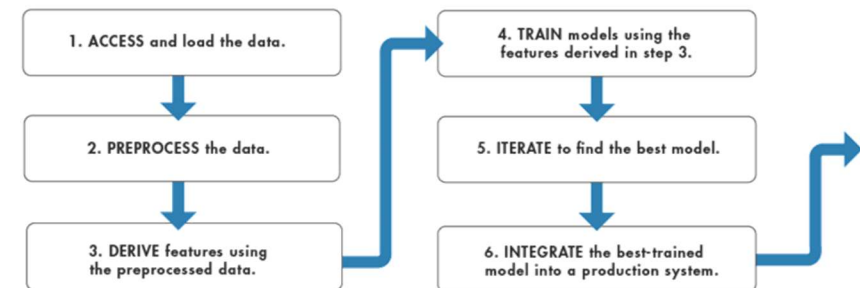
- Filtrowanie spamu e-mail
- Transkrypcja wypowiedzi
- Profilowanie reklam pod klientów
- Szacowanie ryzyka kredytowego
- Wykrywanie anomalii w przelewach bankowych
- Rozpoznawanie osób/obiektów
- ...



<https://www.mathworks.com/help/stats/machine-learning-in-matlab.html>

Zasady budowy modelu

- Duży zbiór danych uczących
+ 10-30% danych do walidacji
- Dobrze zorganizowany,
jednolity format danych
- Uczenie modelu bezpośrednio na danych
lub na podstawie wyekstrahowanych cech
charakterystycznych
- Dobór odpowiedniego (najdokładniejszego)
algorytmu
- „Czyszczenie” modelu z błędnych odpowiedzi,
np. dopasowanie ilościowe/jakościowe danych
wejściowych, nakładanie filtrów na wyjściu
modelu





Modele „wstępnie nauczone” [*pretrained*]

- Gotowe architektury sieci neuronowych, wstępnie nauczone
- Przykłady:
 - AlexNet – rozpoznawanie obrazu
 - WaveNet – odwzorowanie mowy w Google Assistant
 - OCR – rozpoznawanie tekstu na obrazie
 - AlphaFold – przewidywanie struktur białkowych
 - DALL-E, Midjourney – generowanie obrazów na podstawie opisu tekstowego



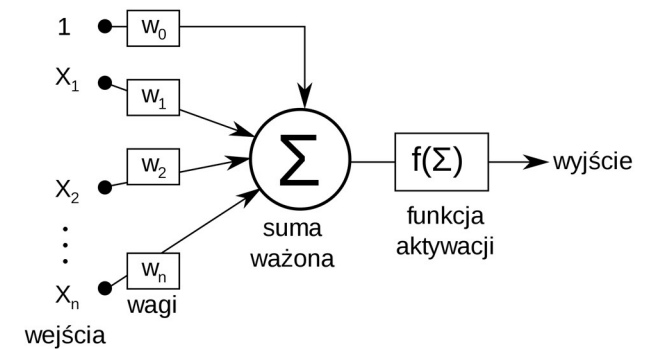
Typowa sieć neuronowa

Sztuczny neuron – **perceptron** (*neuron McCullocha-Pittsa*)

- Węzły – wejście, niekoniecznie binarna

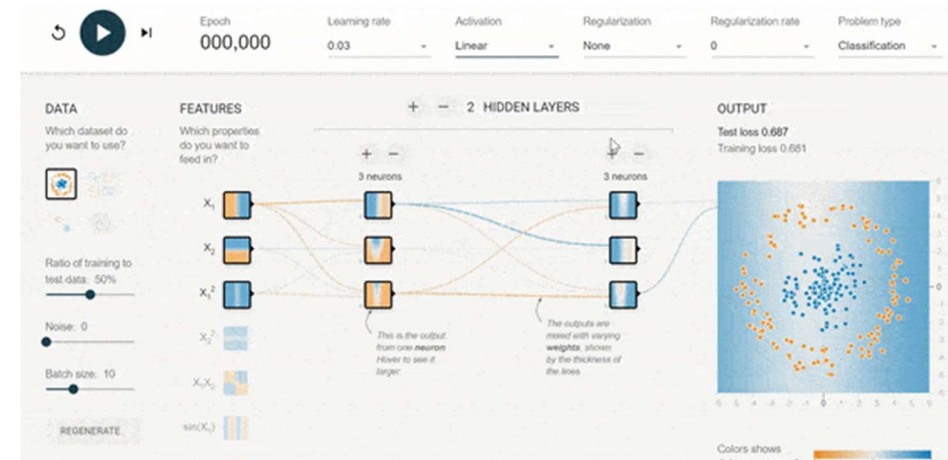

- Wagi – do wytrenowania

- Wyjście – funkcja aktywacji $f(s)$, gdzie $s = w_0 + \sum_{i=1}^n x_i w_i$
(nieliniowość)



warstwy:

- wejściowa
- warstwy ukryte
- wyjściowa



<https://playground.tensorflow.org/>



Przykład 1 – rozpoznawanie liter

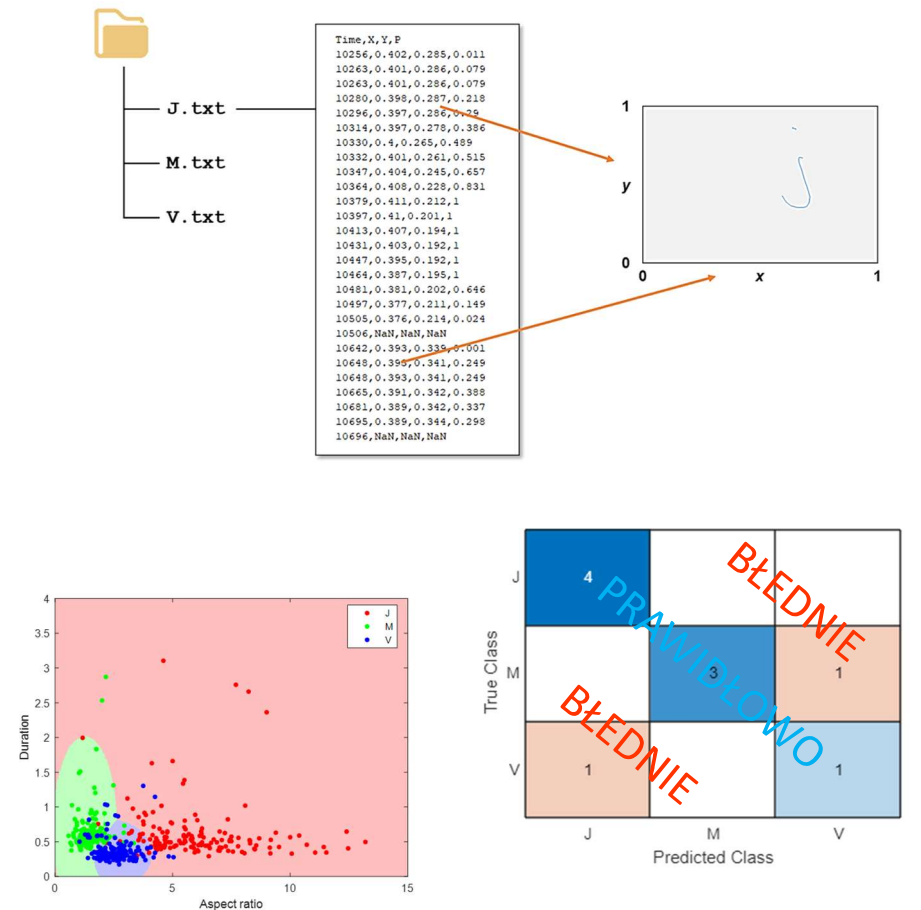
klasyfikacja

Przykład 1 – rozpoznawanie liter

- Dane uczące:**
trajektorie pisanych liter $x(t)$ i $y(t)$, po 150 próbek każdej litery
- Przygotowanie danych:**
ujednoczenie czasu startu, formatu danych i nazw plików
- Wyciągnięcie cech:**
proporcje (szerokość/wysokość), czas trwania pisania
- Algorytm klasyfikacji:**
k najbliższych sąsiadów [k-nearest neighbor]
- Weryfikacja:**
Tablica pomyłek [confusion matrix]

	AspectRatio	Duration	Character
1	5.7308	0.4010	J
2	1.6596	0.4550	M
3	2.4063	0.2750	V
4	3.7568	0.8560	J
5	2.3200	1.3600	M
6	3.6774	0.7060	V

```
load featuredata.mat
knnmodel = fitcknn(features, "Character", ...
    "NumNeighbors", 5);
```



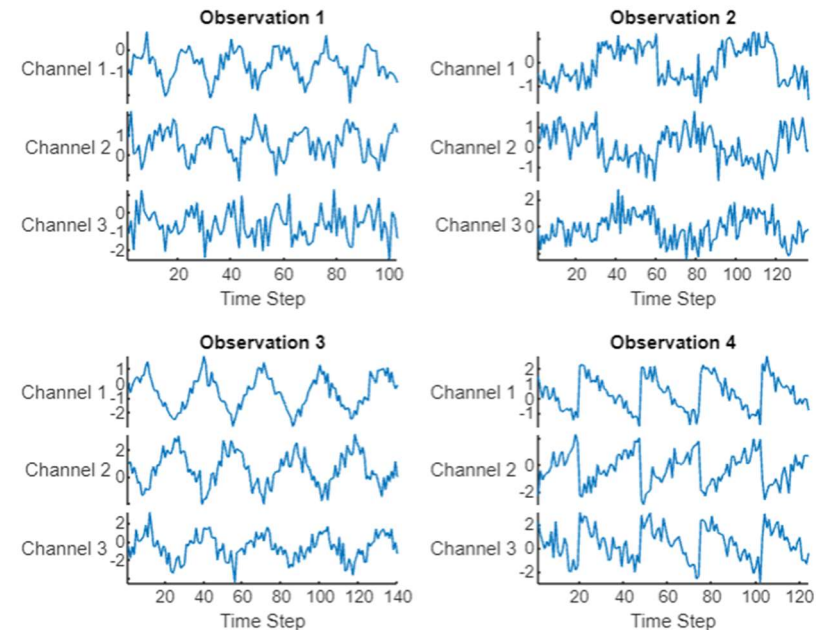


Przykład 2 – szukanie anomalii w danych pomiarowych

autoencoder, trenowanie nienadzorowane

Przykład 2 – szukanie anomalii w danych pomiarowych

- Dane uczące:**
2000 3-kanalowych przebiegów, nieopisanych
90% do treningu, 10% do walidacji
- Przygotowanie danych:**
jednakowa liczba próbek
we wszystkich kanałach i przebiegach



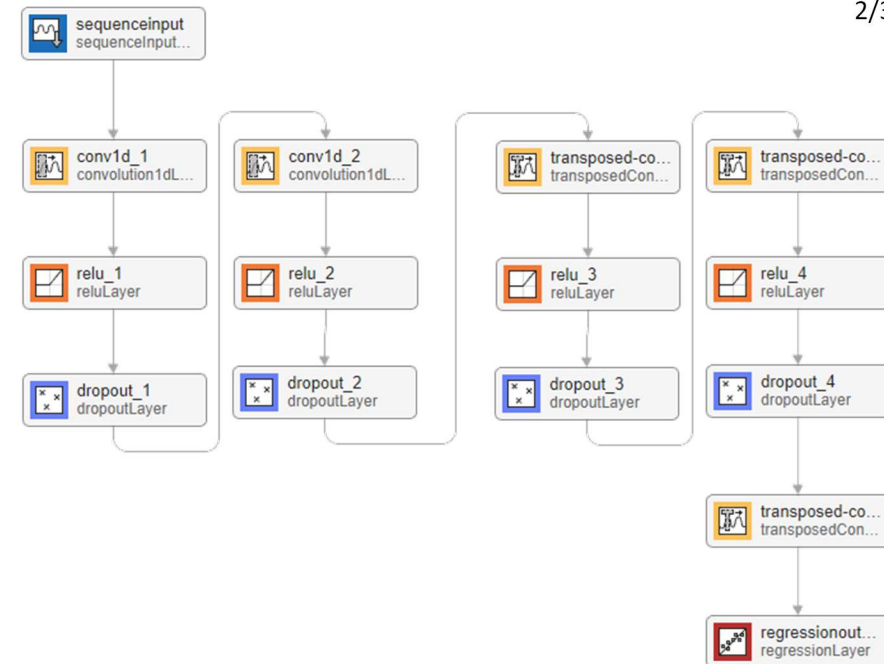
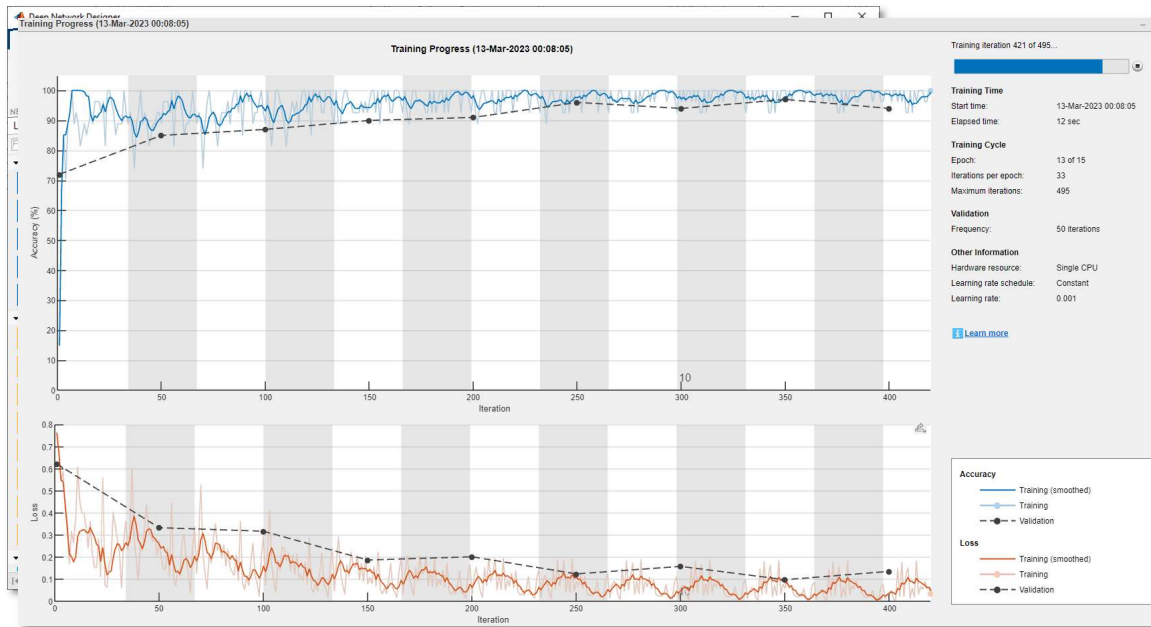
<https://matlab.mathworks.com/>

`openExample('nnet/TimeSeriesAnomalyDetectionUsingDeepLearningExample')`

3. Budowa architektury sieci

- kilka warstw konwolucyjnych (splotowych)
- kilka funkcji aktywacji
- kilka funkcji kasujących nadmiar danych, żeby sieć się nie przeczyła

4. Uczenie sieci





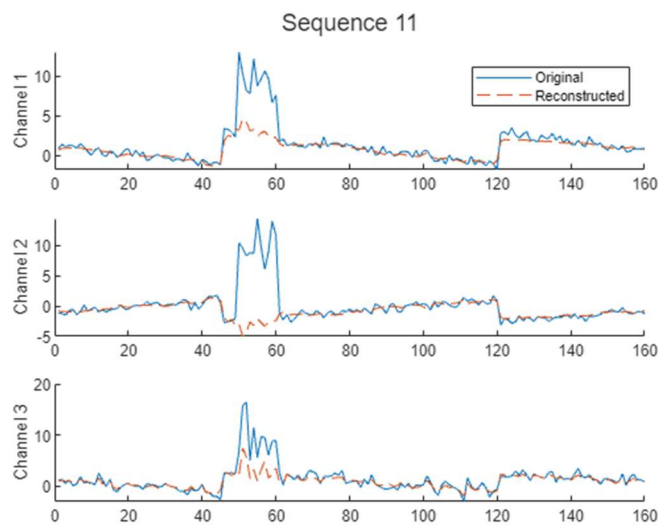
3 ₀	3 ₁	2 ₂	1	0	
0 ₂	0 ₂	1	0	3	1
3 ₀	1 ₁	2 ₂	2	3	
2	0	0	2	2	
2	0	0	0	1	

12.0	12.0	17.0
10.0	17.0	19.0
9.0	6.0	14.0

Warstwy sieci głębokich
<https://www.mathworks.com/help/deeplearning/ug/list-of-deep-learning-layers.html>

5. Szukanie anomalii w danych:

- porównanie wejściowych danych testowych z danymi przewidywanymi
- policzenie średniego błędu bezwzględnego





Przykład 3 – rozpoznawanie obrazów

sieć wstępnie wytrenowana

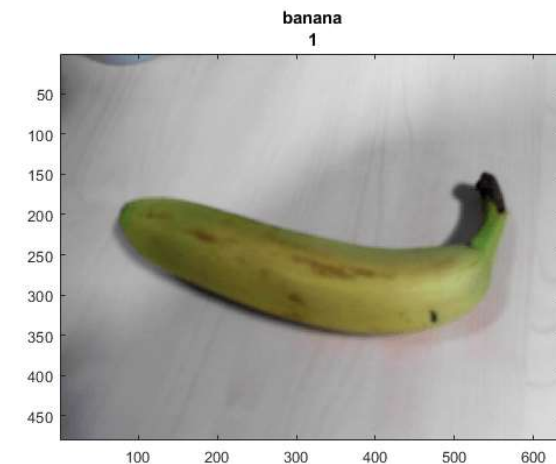
Przykład 3 – rozpoznawanie obrazów

- **sieć AlexNet** – sieć konwolucyjna, 8-warstwowa, nauczona na ponad 1 mln zdjęć z bazy <http://www.image-net.org>
- klasyfikuje zdjęcia na 1000 kategorii
- dane wejściowe: zdjęcie o rozdzielczości 227x227 px

```
camera = webcam; % Connect to the camera
net = alexnet; % Load the neural network

while true
    im = snapshot(camera); % Take a picture
    image(im); % Show the picture
    im = imresize(im,[227 227]); % Resize the picture for alexnet
    label = classify(net,im); % Classify the picture
    title(char(label)); % Show the class label
    drawnow
end
```

<https://matlab.mathworks.com/>

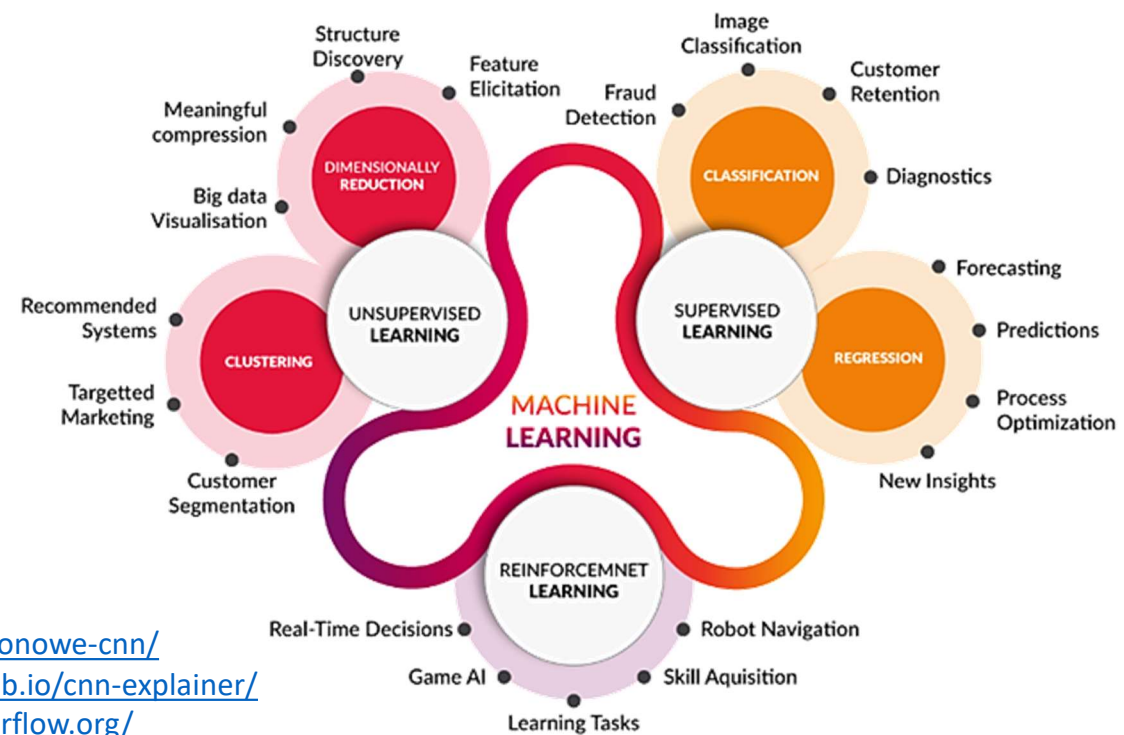




Podsumowanie

- Istnieje wiele modeli uczenia maszynowego, a wybór właściwego zależy od konkretnego przypadku i potrzeb.
- Aplikacje pomocnicze w MATLAB-ie pomagają w doborze tego „najlepszego”, np. *Classification Learner*, *Deep Network Designer*, *Regression Learner*.
- Biblioteki Uczenia maszynowego posiada również Mathematica, LabVIEW oraz wiele języków programowania, np. Python.

Dziękuję za uwagę



Dodatkowe źródła:

Blog o AI: <https://mirosławmamczur.pl/jak-działają-konwolucyjne-sieci-neuronowe-cnn/>

Demonstracja sieci konwolucyjnej dla obrazu (online): <https://poloclub.github.io/cnn-explainer/>

Demonstracja sieci do klasyfikacji/regresji (online): <https://playground.tensorflow.org/>

Generator obrazów AI (online): <https://huggingface.co/spaces/dalle-mini/dalle-mini>

Wywiad o AI: https://www.youtube.com/live/2_yQlynKo48