



Politechnika Łódzka



Katedra Automatyki, Biomechaniki i Mechatroniki (K11)

Wydział Mechaniczny



Sztuczna inteligencja w biomechanice

dr inż. Michał Ludwicki



AI w biomechanice

Wstęp

Wybrane przykłady

- identyfikacja wzorców,
- wsparcie *motion capture* (bezmarkerowa rejestracja ruchu),
- przewidywanie sygnałów,
- prognozowaniu urazów,
- analiza wyników badań.

Praca własna

Typowa sieć neuronowa

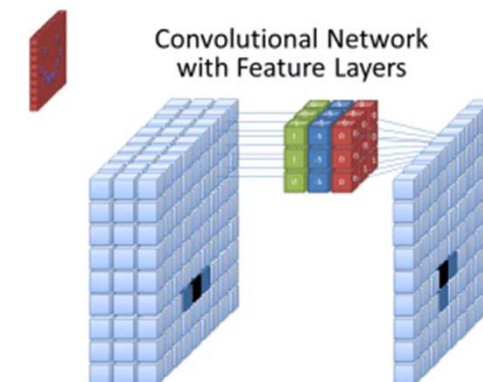
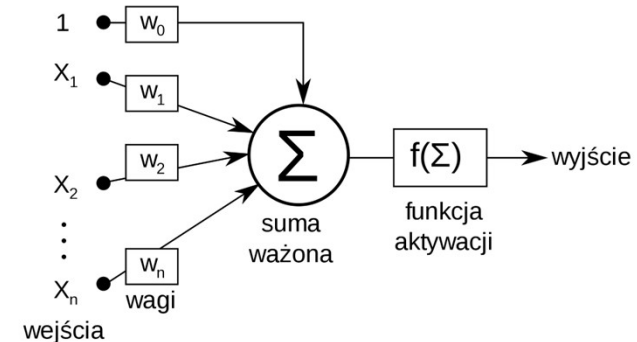

Sztuczny neuron – **perceptron** (*neuron McCullocha-Pittsa*)

- Węzły – wejście, niekoniecznie binarna
- Wagi – do wytrenowania (np. przez propagację wsteczną)

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

warstwy:

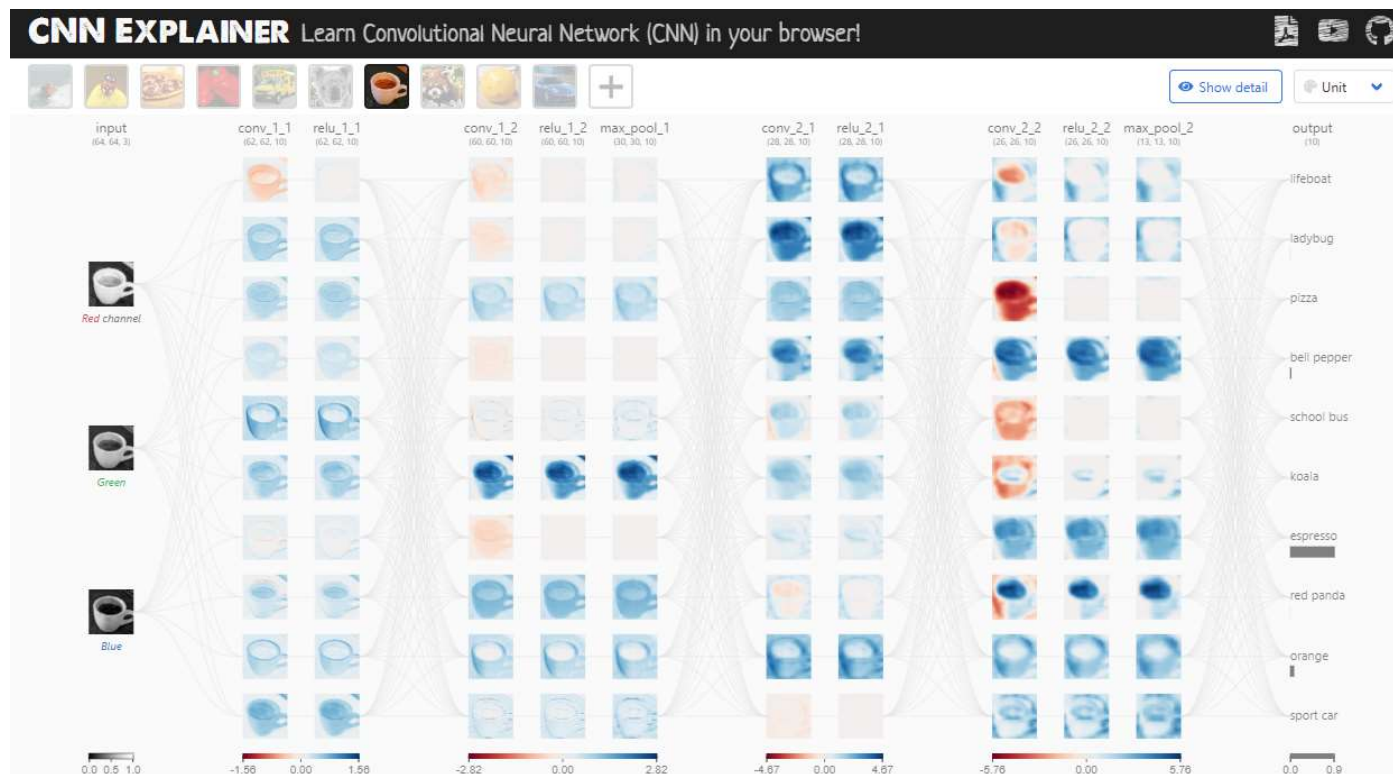
- wejściowa
- warstwy ukryte
- wyjściowa



cecebur - Wikimedia Commons, CC BY SA 4.0

Sieć konwolucyjna

Wykrywanie lokalnych cech w obrazach itp.





Parametry uczenia algorytmu

- **liczba epok**
Epoka to pojedyncza iteracja przez cały zbiór danych treningowych.
- **rozmiar paczki (mini-batch)**
Określa liczbę przykładów danych treningowych, które są używane do aktualizacji wag modelu w jednej iteracji.
- **prędkość uczenia (learn rate)**
Współczynnik określający, jak szybko model ma się dostosować do zmian w danych treningowych.
- **sposób losowania danych**
Jak często zmieniać kolejność danych (np. co epoka)



Politechnika Łódzka



Katedra Automatyki, Biomechaniki
i Mechatroniki (K11)

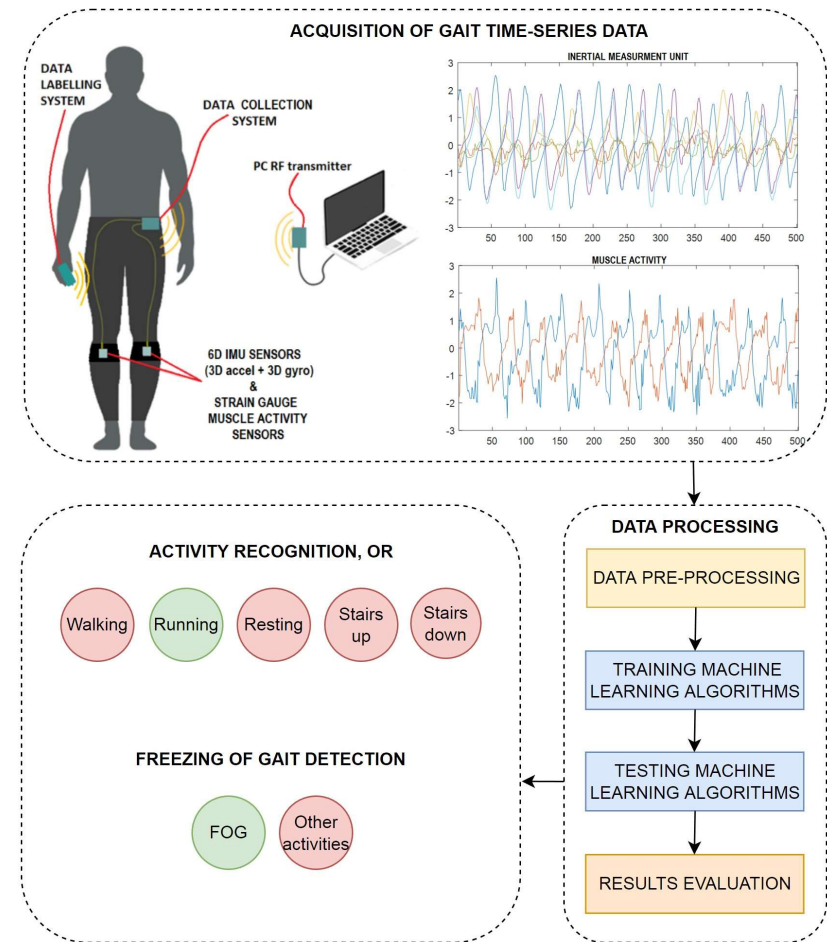
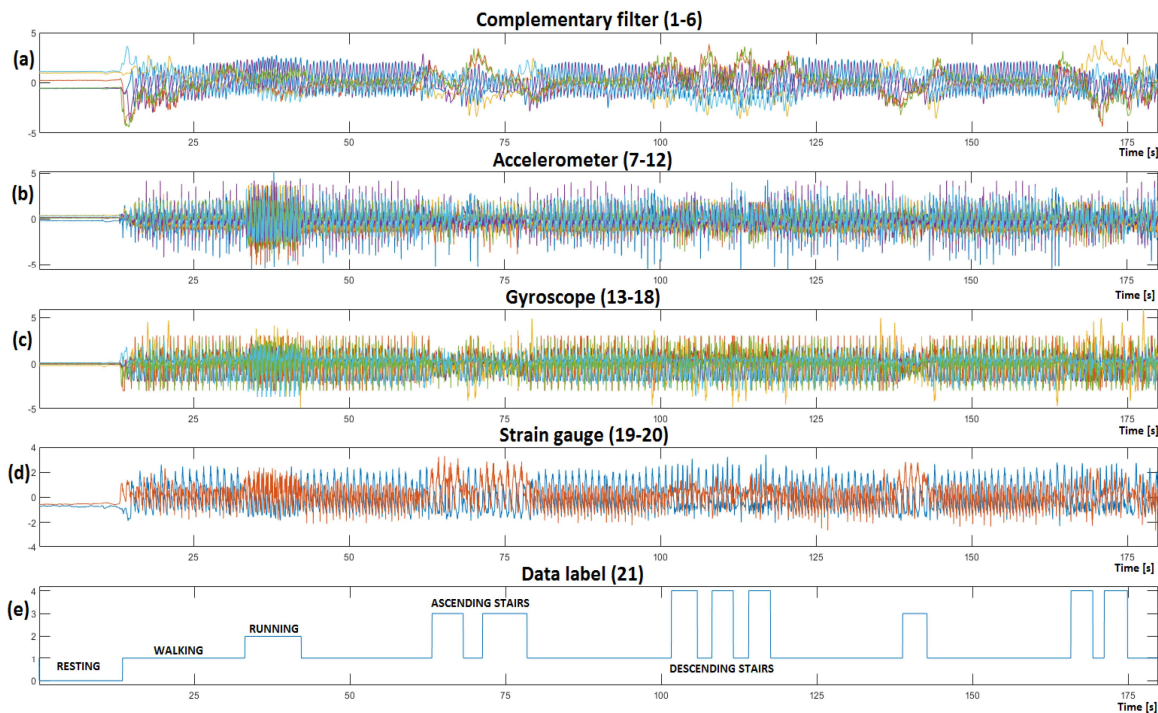
Wydział Mechaniczny



Przykłady

Identyfikacja wzorców

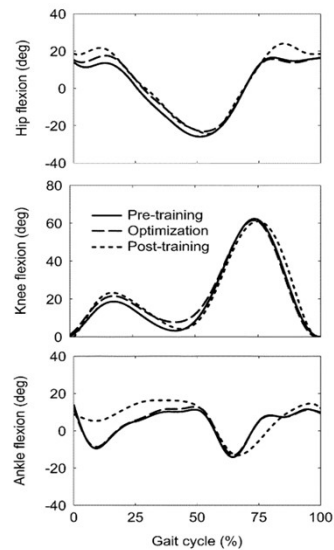
Przykład: IMU + tensometr (naprężenie w stawie)





Slemenšek, Jan, et al. "Human Gait Activity Recognition Machine Learning Methods." *Sensors*, vol. 23, no. 2, Jan. 2023, p. 745, <https://doi.org/10.3390/s23020745>

Identyfikacja faz chodu na bieżni automatycznej


- w ramach projektu z przedmiotu Podstawy Biomechaniki próba zastosowania algorytmów sztucznej inteligencji do automatycznego rozpoznawania faz chodu człowieka na podstawie danych z systemu motion capture / IMU



<https://doi.org/10.1109/TBME.2007.891934>



<http://doi.org/10.7717/peerj.8820/fig-2>



<https://doi.org/10.3390/biomimetics602022>

Motion Capture wspierane przez AI

Rozpoznaje ruch już na pojedynczym nagraniu wideo 2D (*DARMOWA WERSJA Rokoko*)



Płatna wersja dla 2 kamer i kostiumów z pętlą indukcyjną i IMU

Rokoko

- <https://www.rokoko.com/products/vision>
- <https://www.rokoko.com/products/full-performance-capture>

OpenCap

- <https://www.opencap.ai/>






Politechnika Łódzka



Katedra Automatyki, Biomechaniki
i Mechatroniki (K11)

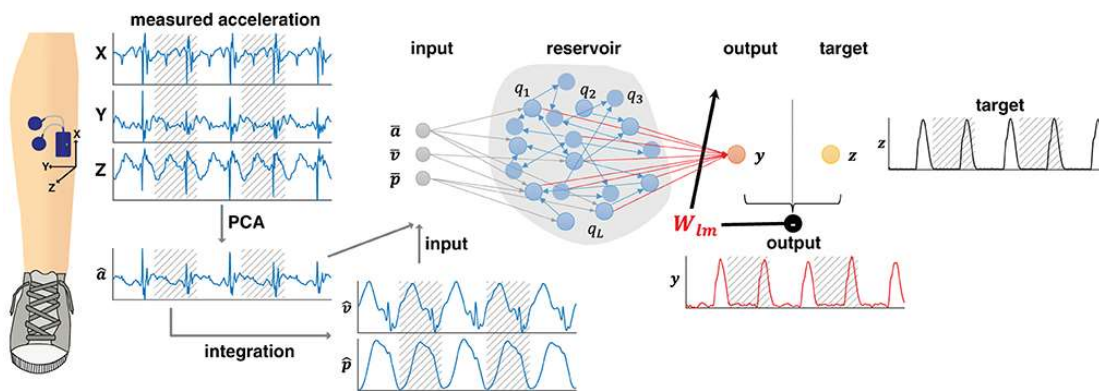
Wydział Mechaniczny



dr inż. Michał Ludwicki

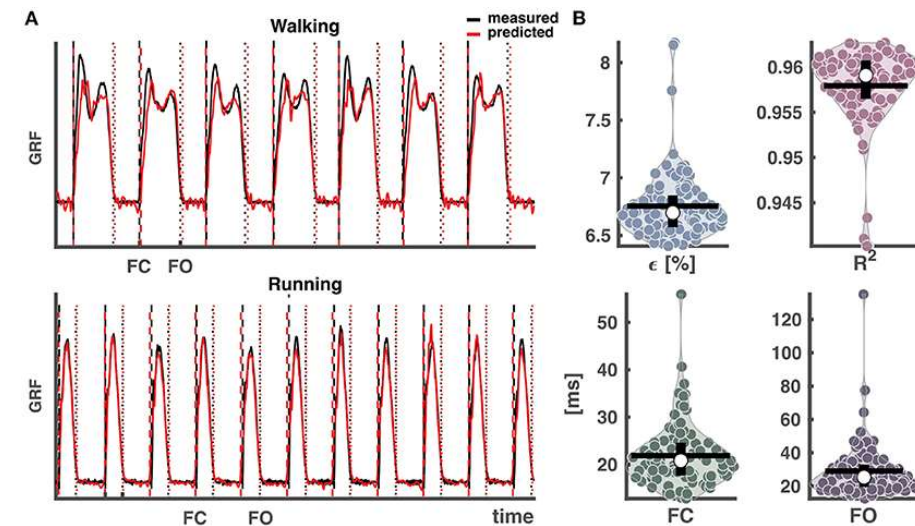
Przewidywanie

Przykład: Przewidywanie siły reakcji podłoża na podstawie sygnału z akcelerometru



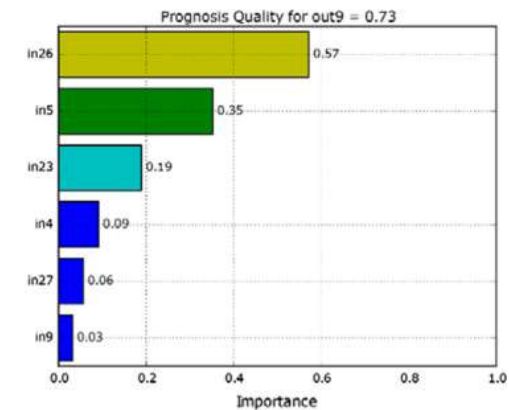
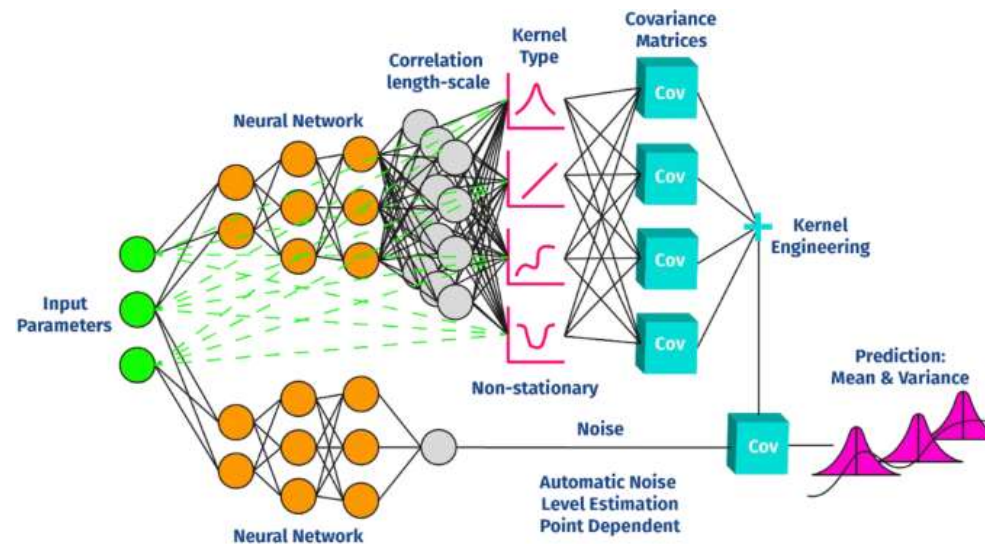
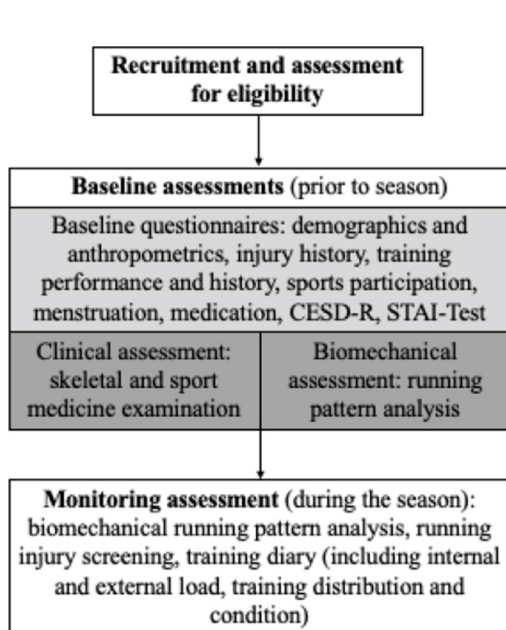
Reservoir computer

Wejście połączone z częścią lub wszystkimi neuronami.
 Wyjście połączone z wszystkimi neuronami.
 Tylko wagi połączeń z wyjściem są trenowane.



Bach, Margit M., et al. "Predicting Vertical Ground Reaction Forces from 3D Accelerometry Using Reservoir Computers Leads to Accurate Gait Event Detection." *Frontiers in Sports and Active Living*, vol. 4, Oct. 2022, <https://doi.org/10.3389/fspor.2022.1037438>

Prognozowanie urazów u sportowców

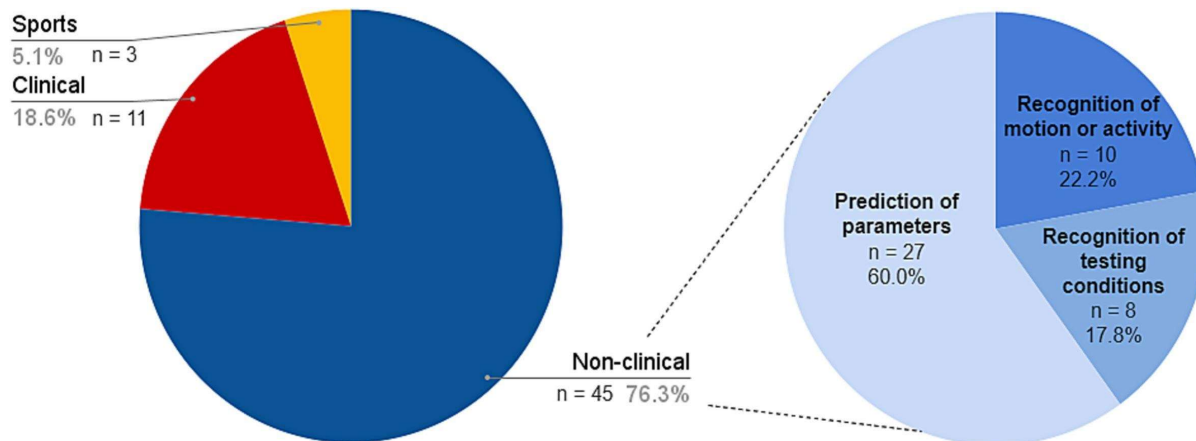


Deep Gaussian Covariance Network

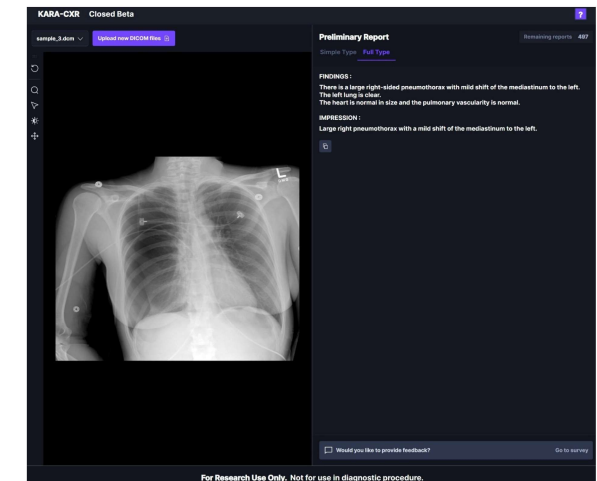

(założenie dystrybucji Gaussa danych wyjściowych)

Rahlf, A. L., et al. "A Machine Learning Approach to Identify Risk Factors for Running-Related Injuries: Study Protocol for a Prospective Longitudinal Cohort Trial." *BMC Sports Science, Medicine and Rehabilitation*, vol. 14, no. 1, Apr. 2022, p. 75, <https://doi.org/10.1186/s13102-022-00426-0>.

Analiza wyników badań



Teoh, Yun Xin, et al. "A Scoping Review of Applications of Artificial Intelligence in Kinematics and Kinetics of Ankle Sprains - Current State-of-the-Art and Future Prospects." *Clinical Biomechanics*, vol. 113, Mar. 2024, p. 106188, <https://doi.org/10.1016/j.clinbiomech.2024.106188>.
2010...2023: 59 artykułów



<https://karacxr.ai/>

Lee, Kyu Hong, et al. "Validation of a Deep Learning Chest X-Ray Interpretation Model: Integrating Large-Scale AI and Large Language Models for Comparative Analysis with ChatGPT." *Diagnostics*, vol. 14, no. 1, Jan. 2024, p. 90, <https://doi.org/10.3390/diagnostics14010090>.




Praca własna

- **Wykorzystanie danych z OPUS 9**

- Motion capture
- sEMG
- Platforma dynamometryczna

- **Cele**

- Dokładniejsza (niż producenta) interpolacja/ekstrapolacja brakujących danych pomiarowych
- Rozpoznawanie konkretnych cech (schorzeń, urazów)
- Automatyzacja synchronizacji danych pomiarowych





MATLAB

Możliwości skryptu:

- rozpoznaje rodzaje danych pomiarowych
- ładuje i odrzuca te uszkodzone (np. zbyt krótkie)
- uczy sieć na dowolnie wybranych zestawach sygnałów (na razie jednego rodzaju)
- archiwizuje parametry obliczeń i wyniki
- wizualizuje dane wejściowe i wyniki

Parametry:

- 90% danych do treningu, 10% do walidacji
- Sieć rekurencyjna typu Long short-term memory (LSTM)

```

classdef MoCapDataStructure
    % Tworzy ustrukturyzowane dane w pamięci programu, []
    properties
        nFrames (1,1) int32 % Liczba klatek
        Params (1,1) string % nagłówek z parametrami pomiaru
        Header (,:) string % nagłówek pliku z parametrami nagrania
        SkeletonName (1,1) string % nazwa szkieletu
        Data (,:) double % dane liczbowe
        Time (,:) int32
        Frames (,:) int32
    end
    % zestaw danych dla AI z pojedynczego pliku
    DataRows (,:) cell % ustrukturyzowane dane XYZ z pojedynczego pliku
    Labels (1,1) categorical % nazwy wszystkich markerów nagrania
    SkeletonLabels (1,1) categorical % nazwy markerów szkieletu
    marginsKonca (1,1) double = 6*3 % 6 markerów w lewo od końca (czasami zostają resztki
    marginsStartStop (1,1) double = 3.0
    wybraneMarkery (1,1) categorical
    czyFiltrowac (1,1) logical
    loguj (1,1) logical
    wszystkieMarkery (1,1) categorical
end
methods(Static)
    methods
        function o = MoCapDataStructure(head, ddata, trini, wybraneMarkery, iliaLinii, czyFiltrowac)
        function head=getHead(o, n)
        function rot=getRotationType(o)
        function u=getLengthInUnits(o)
        function nrKolumny=findColumn(o, markerType, markerName, axis)
    end
end

```


Wybrane źródło:
MoCap

Wybrane markery [10]:
WaistLBack WaistLFront BackLeft LShoulderBack LShoulderTop
WaistRBack WaistRFront BackRight RShoulderBack RShoulderTop

sequenceInputLayer:
' Sequence Input Sequence input with 3 dimensions
' BiLSTM BiLSTM with 10 hidden units
' Fully Connected 2 fully connected layer
' Softmax softmax 5 " Classification Output crossentropyx


Solver:
• nnet.cnn.TrainingOptionsADAM
• InitialLearnRate: 0.005
• MaxEpochs: 5000
• MiniBatchSize: 65
• ExecutionEnvironment: gpu

losowanie co epoka!







Wyniki – rozpoznawanie kifozy piersiowej



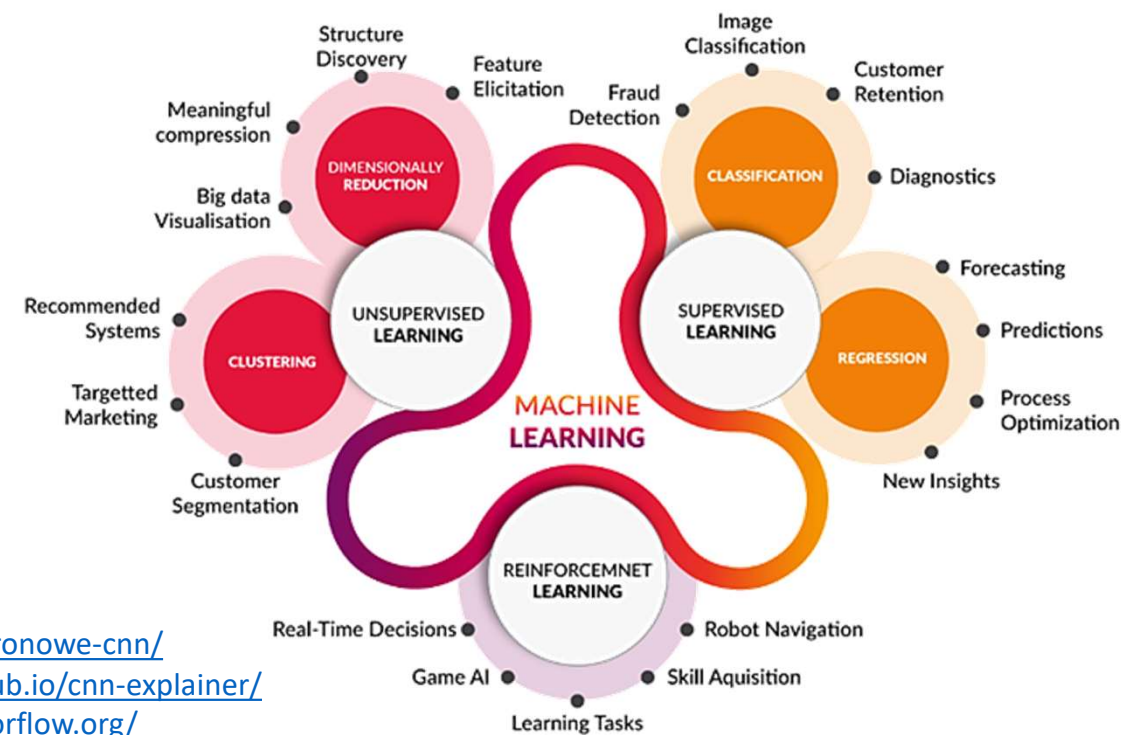
Confusion Matrix for 2 features



dokładność klasyfikacji: 78%



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