

Łukasiewicz

Poznański

Instytut

Technologiczny

Zastosowanie sieci neuronowych w diagnostyce elementów systemu transportu szynowego

**mgr inż. Julia Milewicz, mgr inż. Krzysztof Kołodziejczak,
dr hab inż. Grzegorz Szymański, prof. PP**


XXV Konferencja Naukowa Pojazdy Szynowe 2023, Polanica-Zdrój, 10-13 września 2023 r.

Agenda prezentacji

- 1. Wprowadzenie**
- 2. Idea uczenia głębokiego i sieci neuronowych**
- 3. Przykłady zastosowania CNN w diagnostyce elementów systemu transportu szynowego**
 - i. Diagnostyka powierzchni izolatorów sieci jezdnej
 - ii. Diagnostyka powierzchni główki szyny
 - iii. Diagnostyka osi zestawu kołowego
 - iv. Diagnostyka łożysk tocznych
 - v. Diagnostyka luzów zaworowych silnika wysokoprężnego
- 4. Podsumowanie**



Wprowadzenie



Wprowadzenie

Wyzwania stawiane przed transportem szynowym:




Ekologia




Bezpieczeństwo



Rozwój sieci transportowych



Zwiększona eksploatacja pojazdów i infrastruktury



Optymalizacja procesów utrzymaniowo-naprawczych

“Transformacja cyfrowa stanie się niezbędnym czynnikiem napędowym modernizacji całego systemu, umożliwiając jego płynną i wydajną eksploatację”

Komunikat Komisji do Parlamentu Europejskiego, Rady, Europejskiego Komitetu Ekonomiczno-społecznego i Komitetu Regionów: *Strategia na rzecz zrównoważonej i inteligentnej mobilności – europejski transport na drodze ku przyszłości*

Bruksela, dnia 9.12.2020 r

Uczenie głębokie i sieci neuronowe

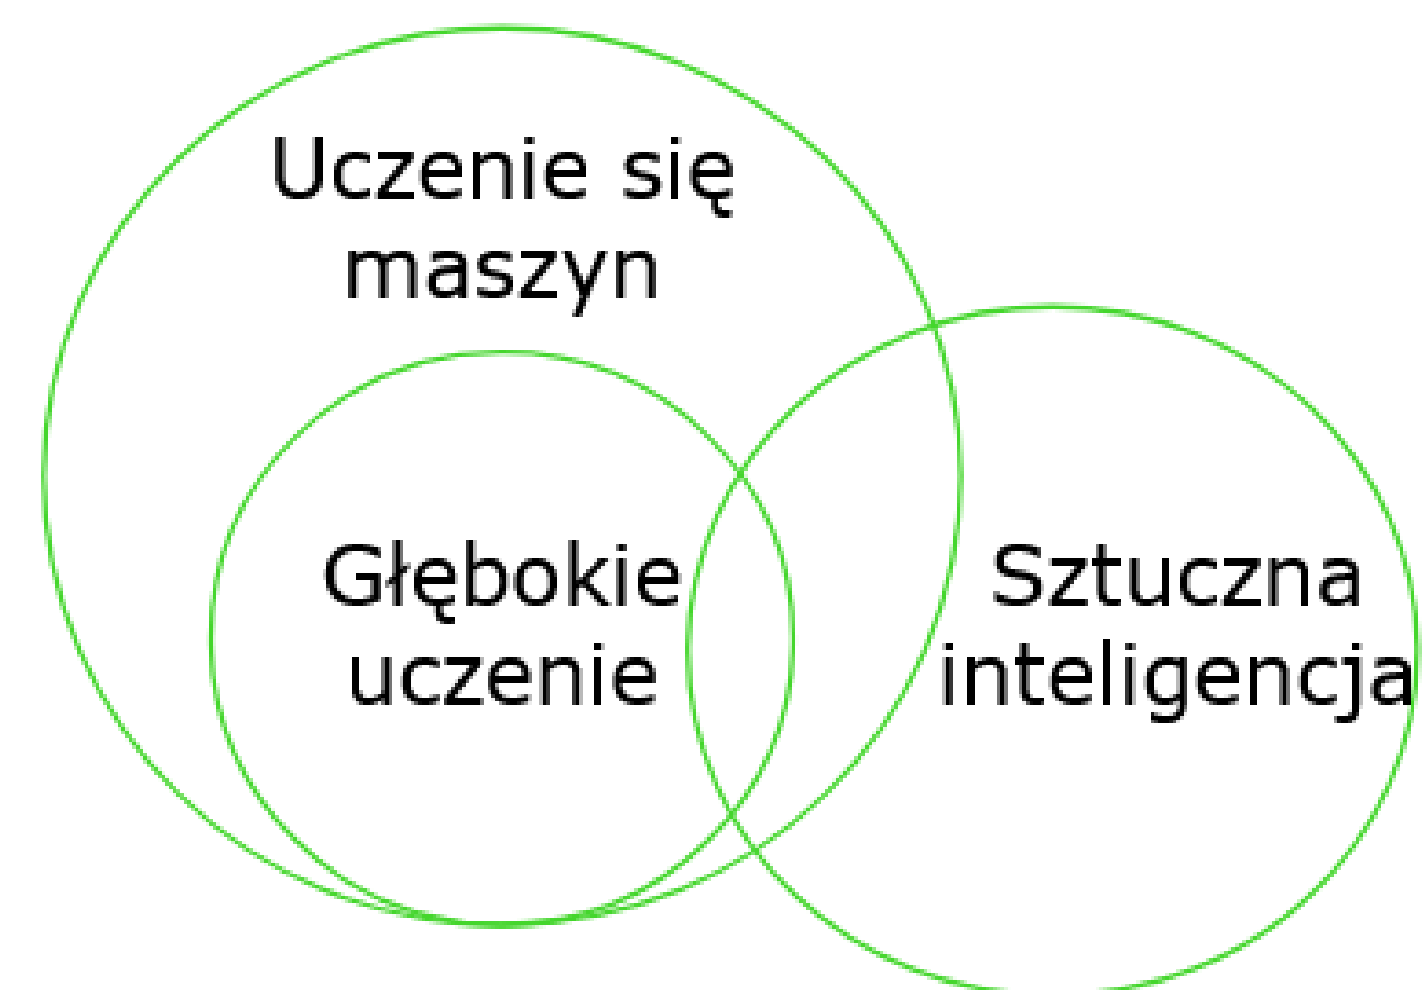


Idea uczenia głębokiego i sieci neuronowych

1. Głębokie uczenie (*deep learning, DL*) to podzbiór uczenia się maszyn (*machine learning, ML*), czyli dziedziny dedykowanej badaniom oraz rozwijaniu się maszyn, które mogą się uczyć (niekiedy z ostatecznym celem zbudowania ogólnej sztucznej inteligencji).

Szerokie spektrum zastosowań, w tym:

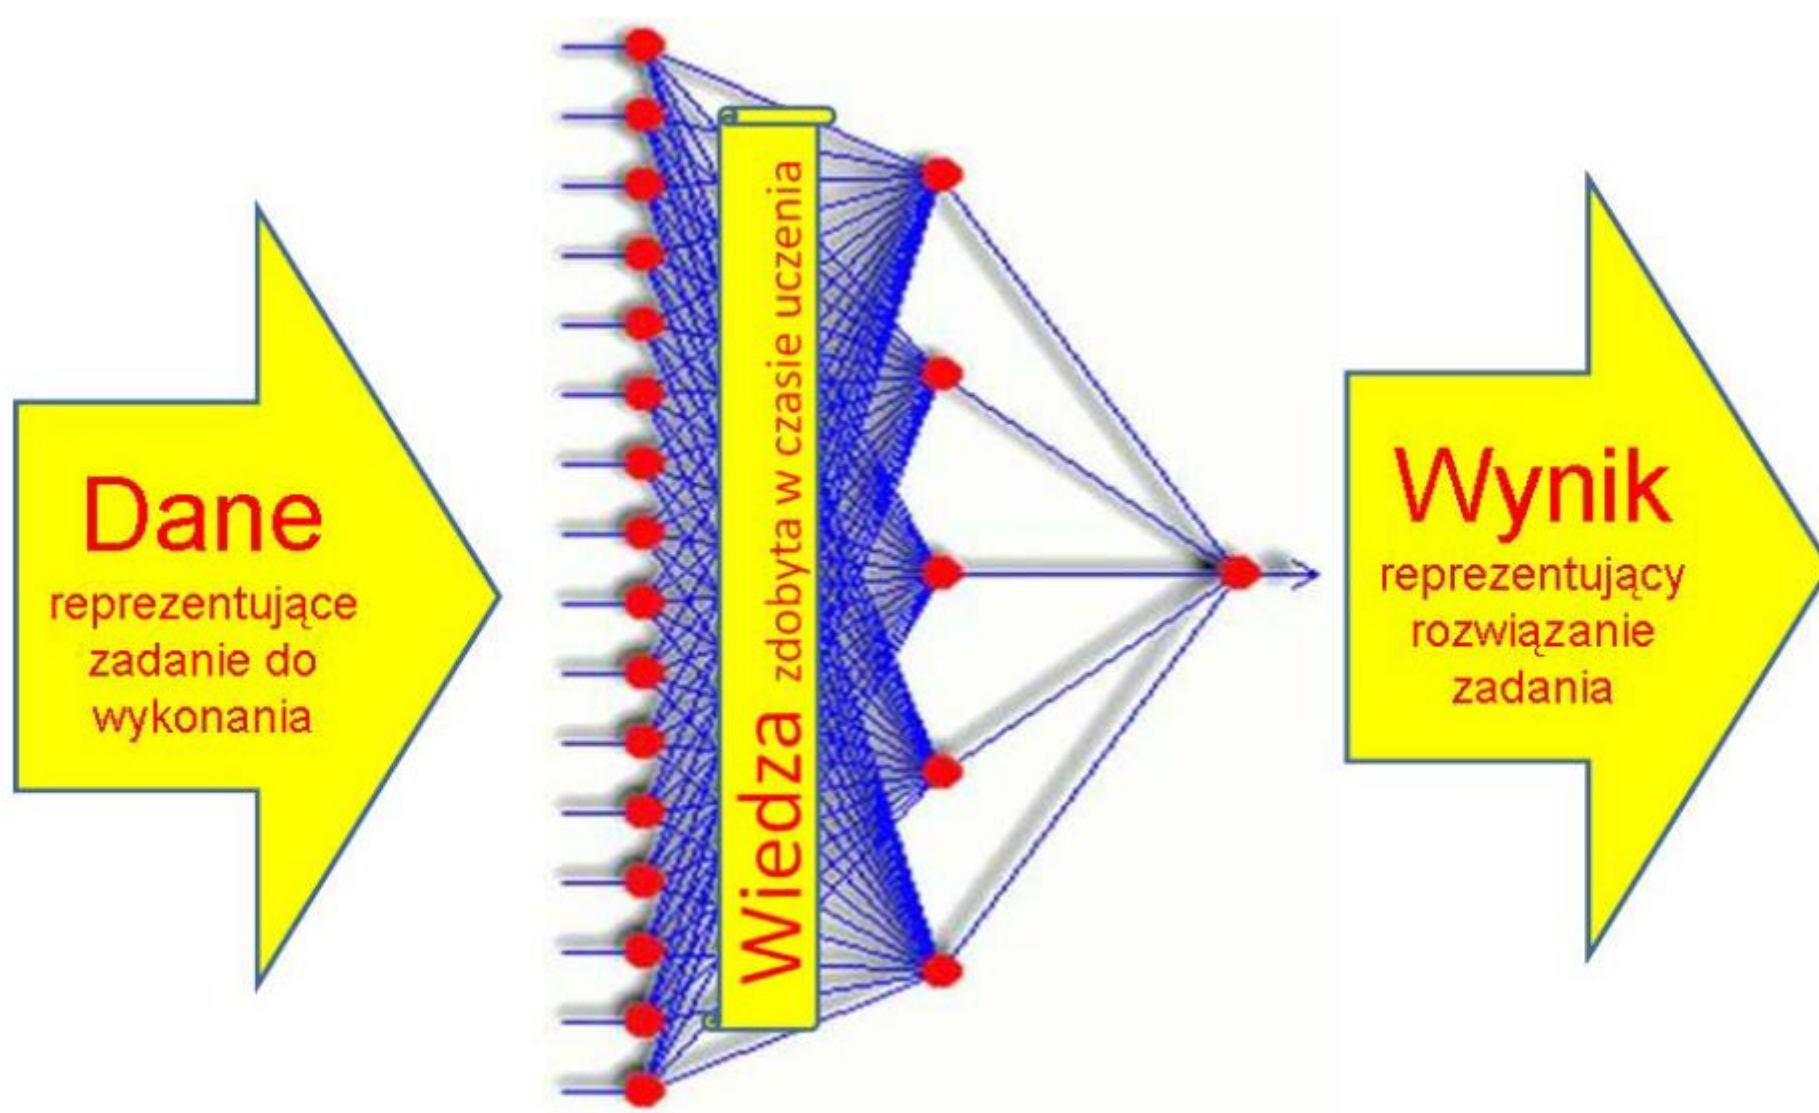
- **rozpoznawanie obrazów,**
- przetwarzanie języka naturalnego,
- rozpoznawanie mowy.



Rys. 1. Schemat zależności między uczeniem się maszyn, głębokim uczeniem i sztuczną inteligencją [1]

Idea uczenia głębokiego i sieci neuronowych

2. Sieci neuronowe (*neural networks, NN*) to modele obliczeniowe, które są inspirowane strukturą mózgu i próbują naśladować jego sposób działania.



Rys. 2. Zasada działania sieci neuronowej [2]


Cechy:

- umiejętność rozwiązywania problemów bez uprzedniej formalizacji matematycznej
- brak potrzeby odwoływania się do założeń teoretycznych problemu
- zdolność uczenia się na przykładach
- zdolność do generalizacji (uogólniania zdobytej wiedzy)

Idea uczenia głębokiego i sieci neuronowych

3. Przykłady modeli uczenia głębokiego i ich zastosowań:

- **konwolucyjne sieci neuronowe** – przetwarzanie obrazów
- rekurencyjne sieci neuronowe – przetwarzanie języka
- głębokie uczenie przez wzmocnienie – robotyka, gry, język, obrazy
- generatywne sieci przestawne – generowanie obrazów



Rys. 3. Uproszczona struktura sieci neuronowej [2]


Idea uczenia głębokiego i sieci neuronowych

4. Konwolucyjne sieci neuronowe (*convolutional neural network, CNN*)

głęboka sieć neuronowa do rozpoznawania obrazów, wykorzystująca filtry do wykrywania cech obrazu.

Naśladują działanie mózgu i oczu do przetwarzania bodźców wzrokowych: różne grupy neuronów wykrywają różne cechy obrazu (linie, kolory, krawędzie).

Pierwsze neurony zbierają proste bodźce, dalsze neurony zbierają je w skomplikowane kształty.



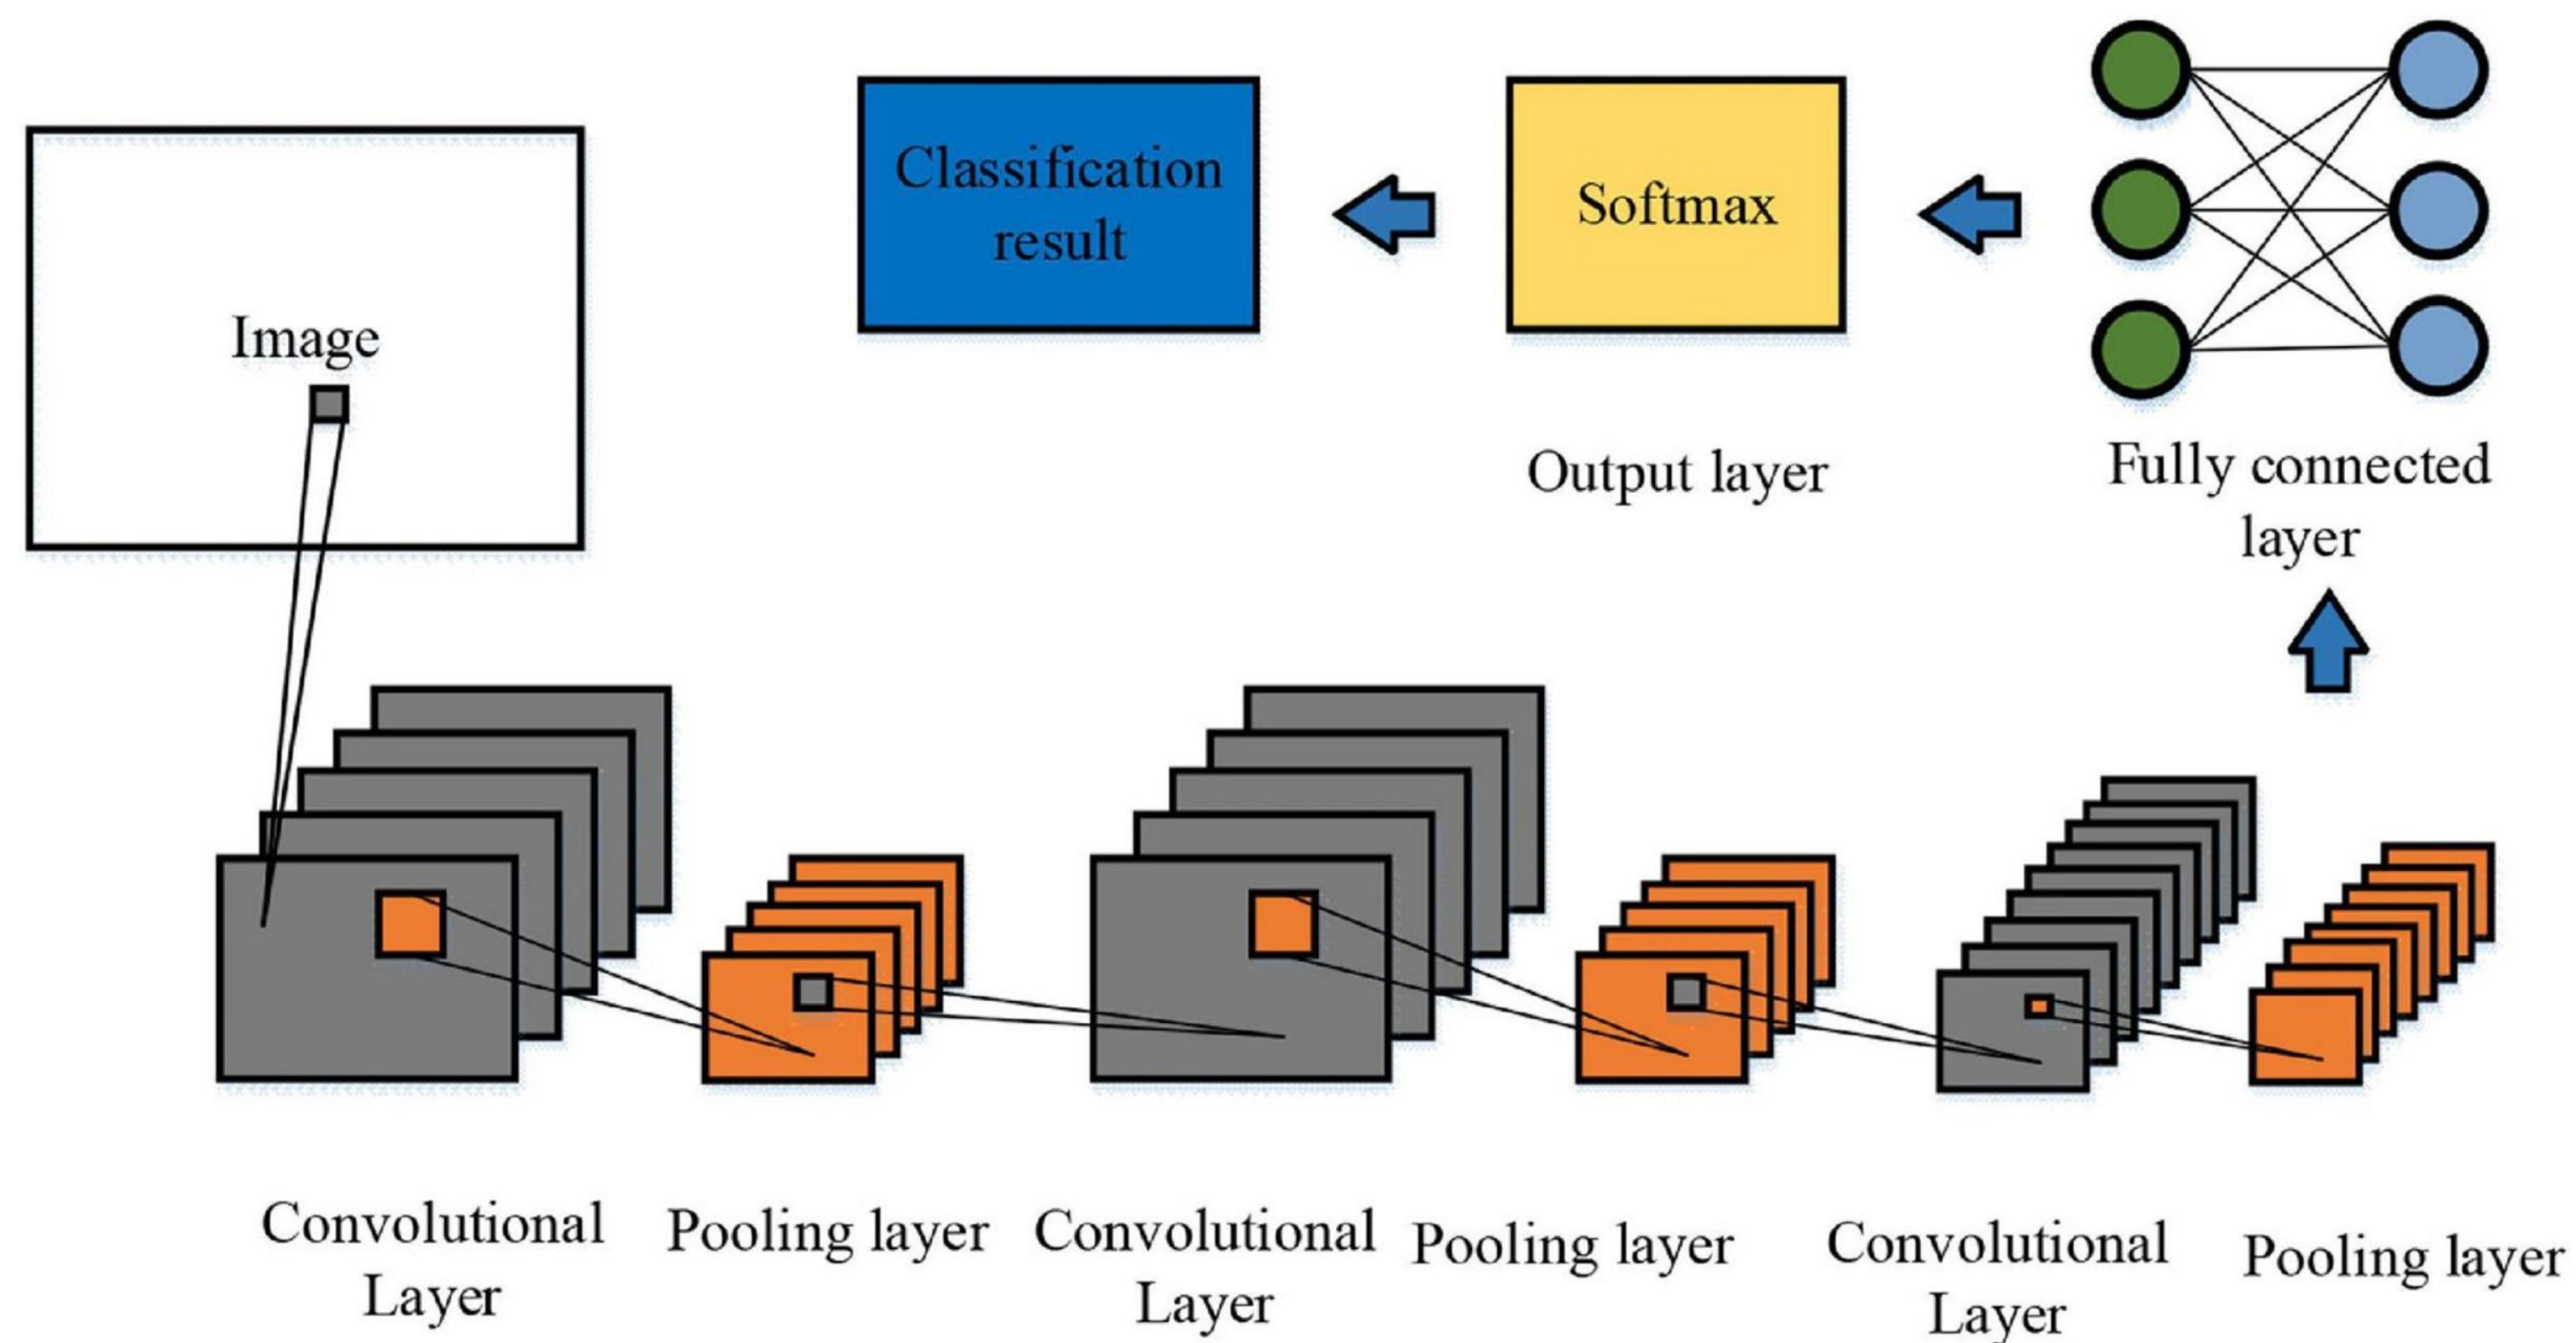
Idea uczenia głębokiego i sieci neuronowych

5. Typy warstw:

- ❑ warstwy w pełni połączone (*fully connected layers*) - warstwa o m neuronach połączona z warstwą o n neuronach $m \times n$ połączeniami (każde ma swoją wagę)
- ❑ warstwa splotowa (*convolutional layers*) - wykorzystuje specjalny filtr (zwany jądrem łączącym, kernelem) do zamiany jednej warstwy neuronów na drugą
- ❑ warstwa łącząca (*pooling layer*) - warstwa kompresująca dane do mniejszego rozmiaru


Idea uczenia głębokiego i sieci neuronowych

6. Architektura konwolucyjnej sieci neuronowej:



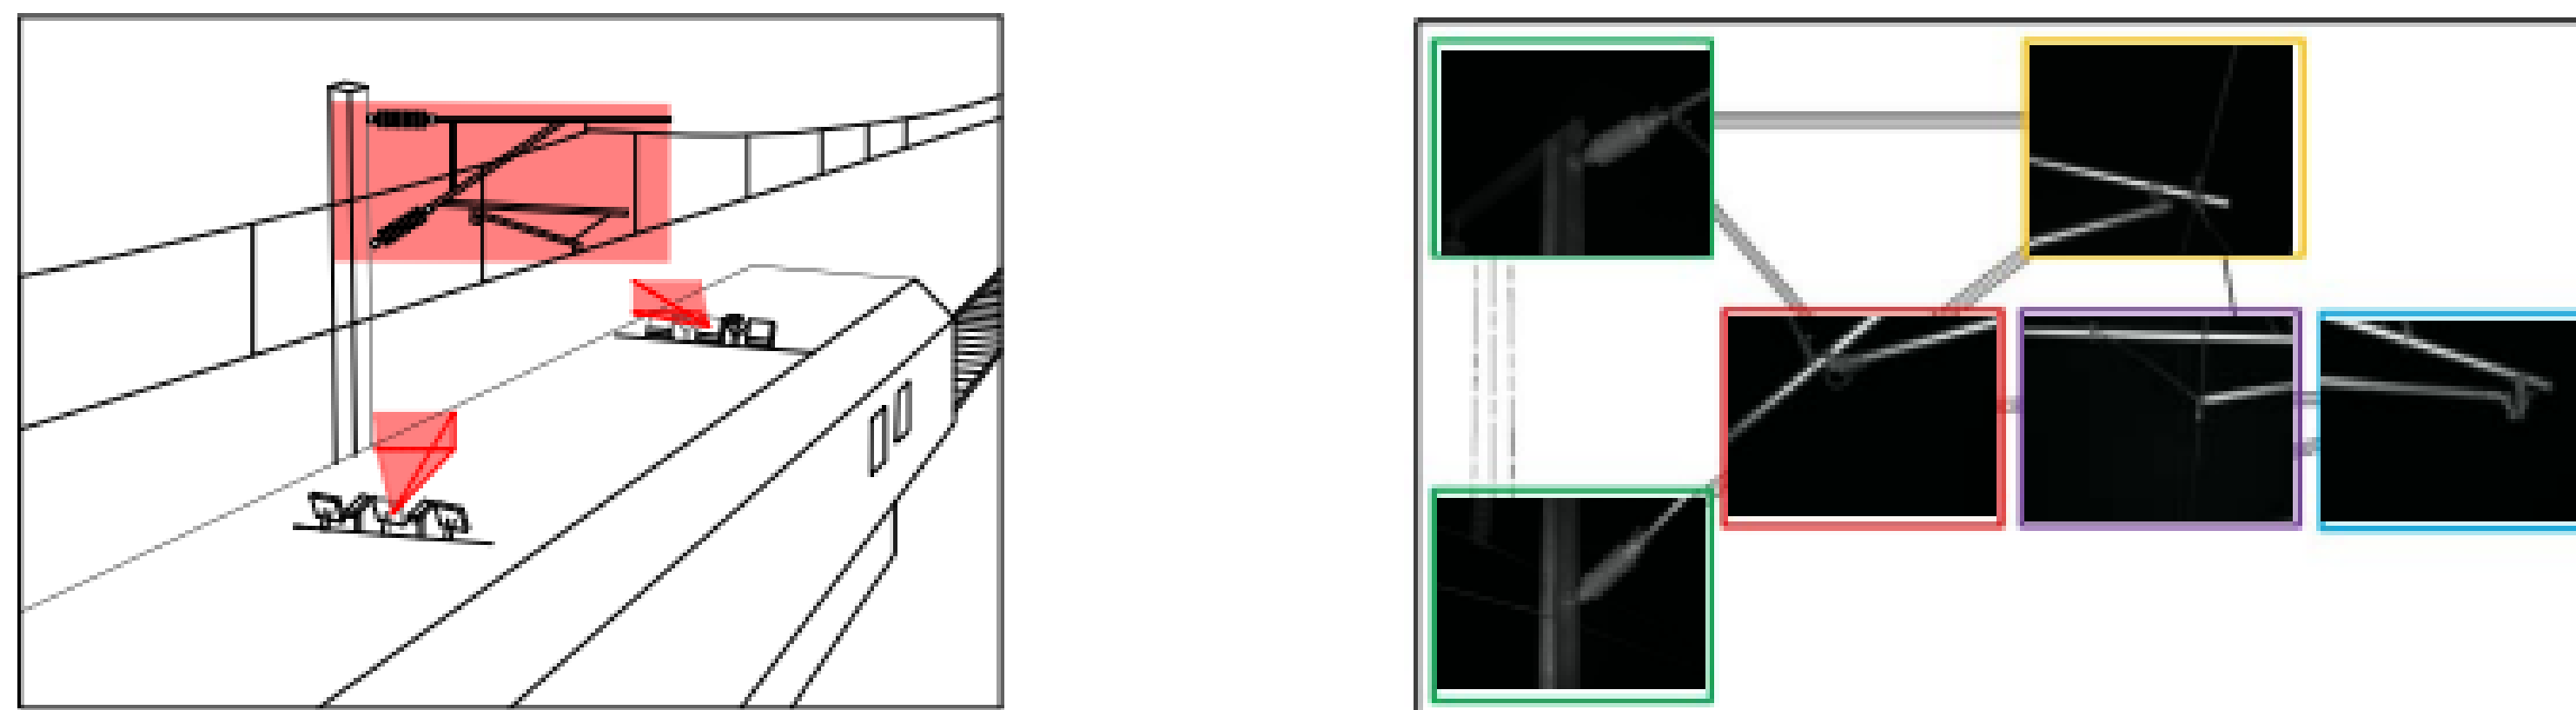
Rys. 4. Schemat przetwarzania obrazu przez konwolucyjną sieć neuronową [3]

**Przykłady zastosowania
CNN w diagnostyce
elementów systemu
transportu szynowego**



Przykłady zastosowania CNN w diagnostyce elementów systemu transportu szynowego

1. Diagnostyka powierzchni izolatorów sieci jezdnej



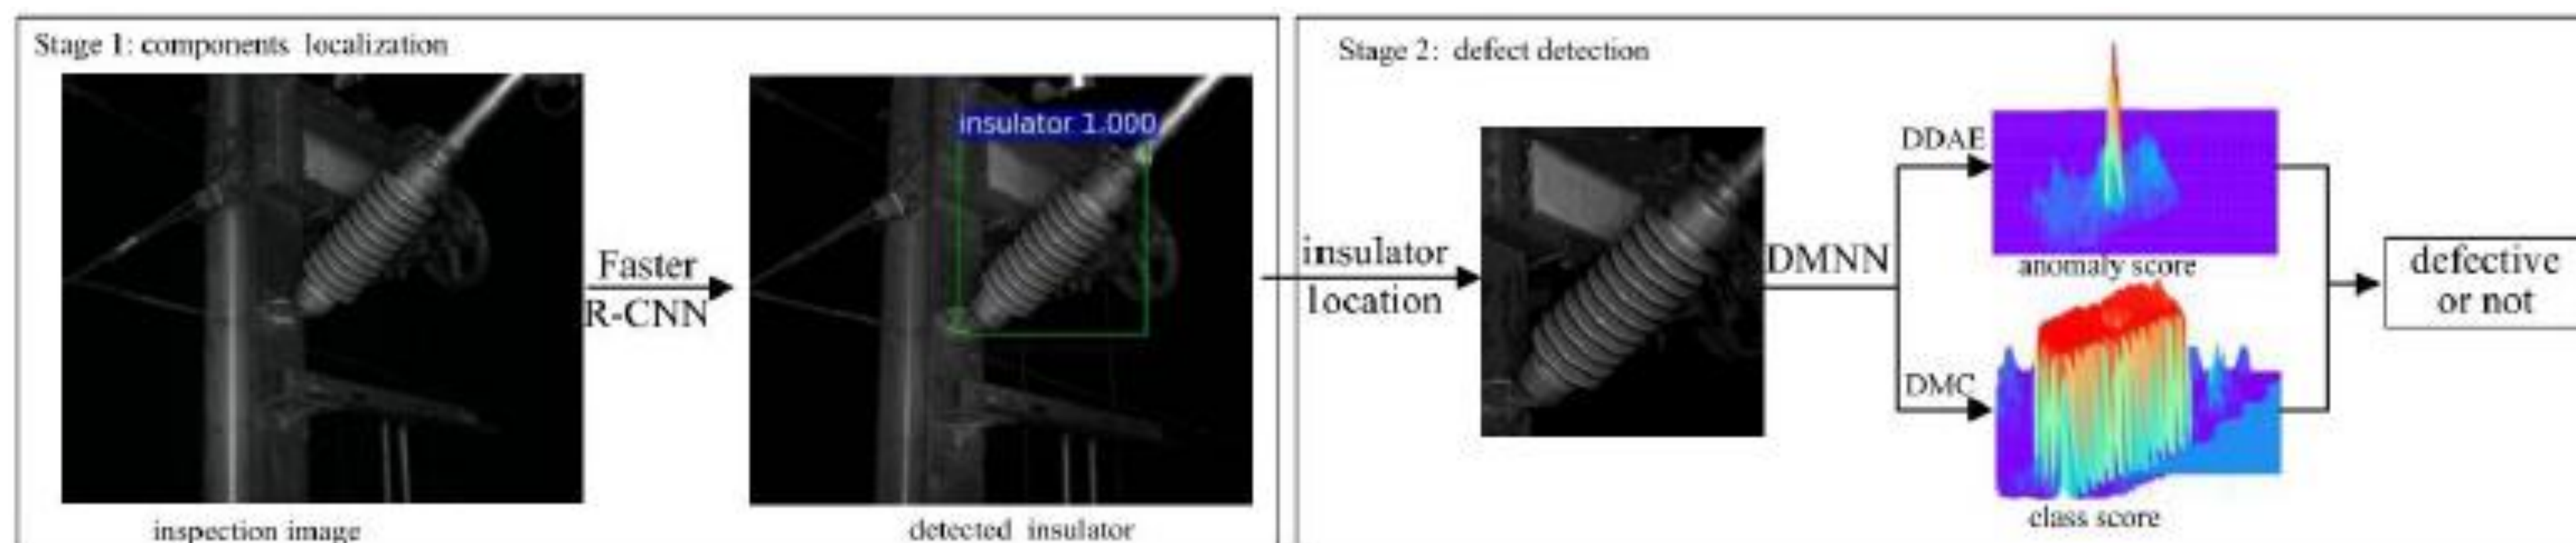
Rys. 5. Szkic działania systemu diagnostycznego oraz zestawienie zdjęć z różnych kamer systemu diagnostycznego [4]

System diagnostyczny składał się z dwóch grup kamer i dodatkowych lamp zamontowanych na pojeździe inspekcyjnym.

Zdjęcia elementów infrastruktury o rozdzielczości 4920x3280 były wykonywane z dwóch stron, dodatkowo rejestrowano dodatkowe informacje związane z położeniem elementu infrastruktury.

Przykłady zastosowania CNN w diagnostyce elementów systemu transportu szynowego

1. Diagnostyka powierzchni izolatorów sieci jezdnej




Rys. 6. Architektura systemu diagnostycznego lokalizująca oraz diagnozująca element infrastruktury [4]

Pierwszym etapem działania systemu diagnostycznego było wykrycie położenia badanego komponentu na fotografii za pomocą sieci Faster R-CNN (Faster Region-based Convolutional Neural Network).

Drugim etapem działania systemu diagnostycznego jest wykrycie uszkodzenia komponentu za pomocą MTL (Multitask Learning) składającego się z sieci: DDAE (Deep Denoising Autoencoder) oraz DMC (Deep Material Classifier).

Przykłady zastosowania CNN w diagnostyce elementów systemu transportu szynowego

2. Diagnostyka powierzchni główki szyny




System diagnostyczny, którego celem jest wyszukiwanie uszkodzeń główki szyny składa się z trzech etapów:

- skanowanie infrastruktury przez jednostkę latającą (np. drona),
- ekstrakcja (segmentacja) z wykonanych zdjęć powierzchni główki szyny
- wyszukiwanie uszkodzeń powierzchni główki szyny

Rys. 7. Struktura systemu diagnostycznego [5]

Przykłady zastosowania CNN w diagnostyce elementów systemu transportu szynowego

2. Diagnostyka powierzchni główki szyny



Moduł FCN-8 (Fully Convolutional Network) wraz z siecią VGGNet jest odpowiedzialny za segmentację obrazu tzn. przyporządkowanie każdemu punktowi obrazu etykiety.

Powstałe w ten sposób etykiety należą do dwóch klas:

- szyna (oznaczona na biało),
- tło (oznaczone na czarno).

Rys. 8. Przykłady działania sieci FCN-8 [5]

Przykłady zastosowania CNN w diagnostyce elementów systemu transportu szynowego

3. Diagnostyka osi zestawu kołowego wózka typu Y21



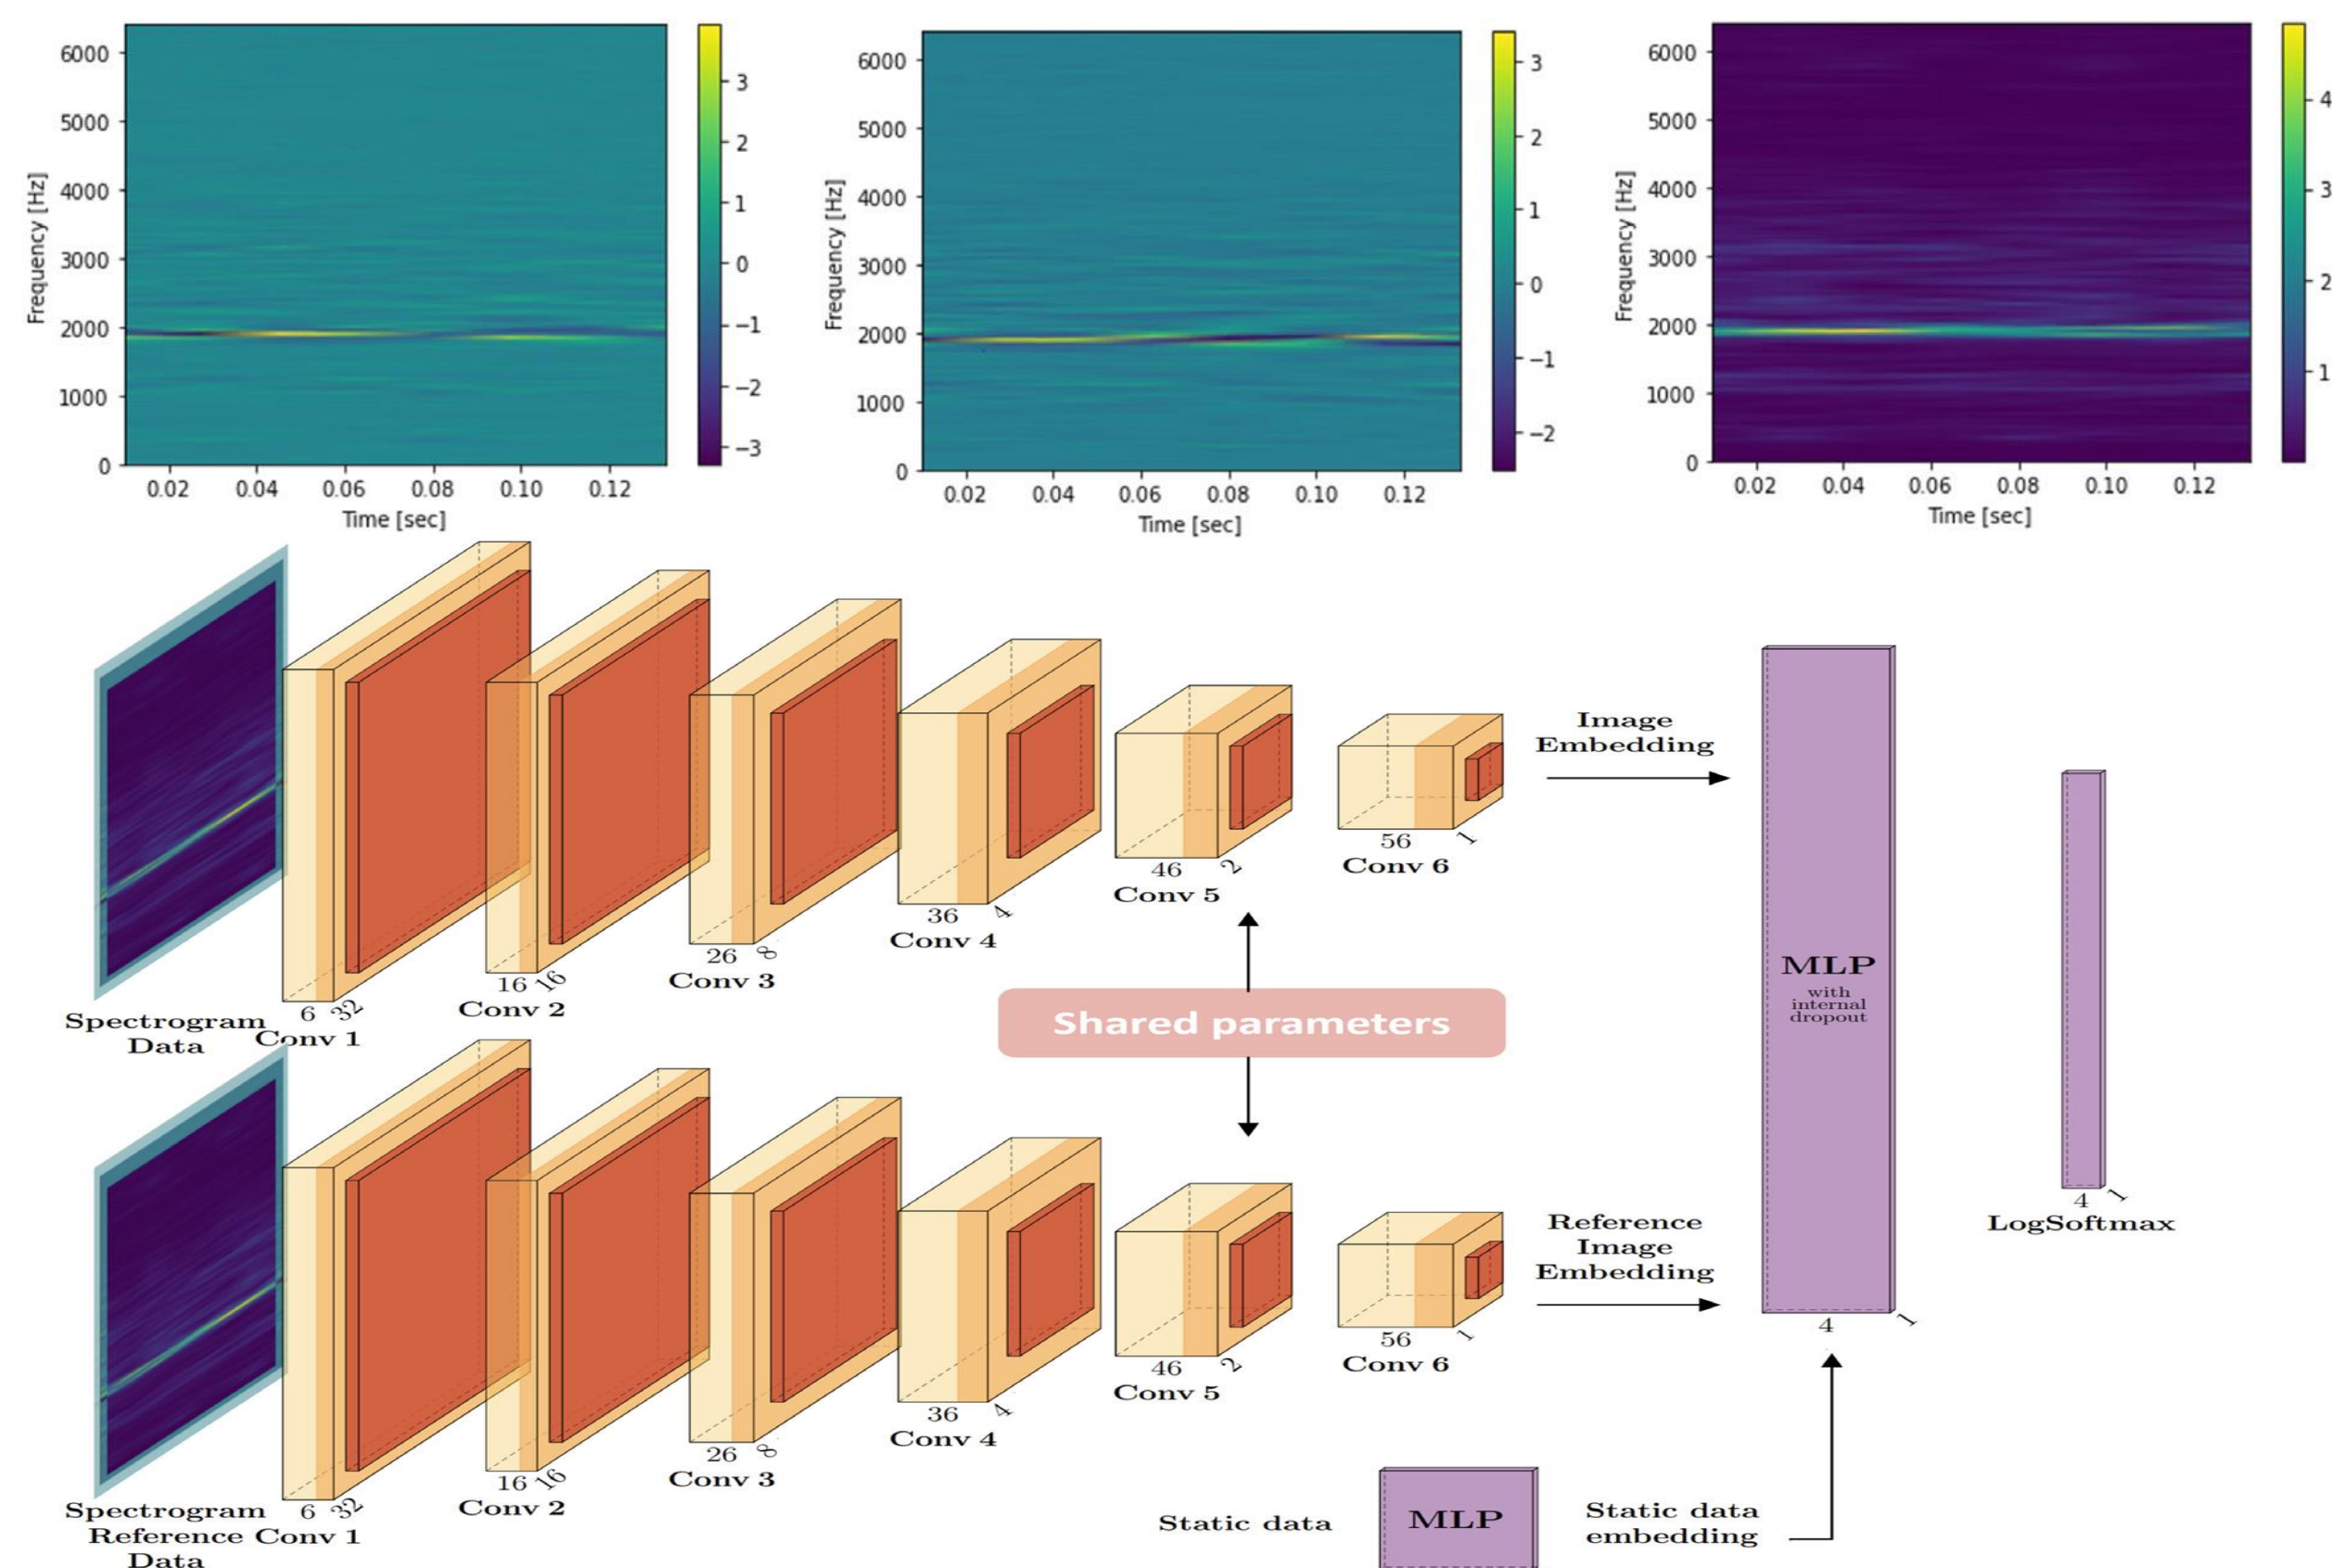
Wózki typu Y21, będące odmianą wózka Y25, wyposażone są w sprężyny śrubowe zamiast resorów piórowych, co pozwala na zastosowanie lżejszej i krótszej ramy wózka.

1. Badany zestaw kołowy 2. Unieruchomiony zestaw kołowy 3. Lewe łożysko osiowe 4. Prawe łożysko osiowe 5. Silnik oraz układ napędzający badany zestaw kołowy

Rys. 9. Stanowisko diagnostyczne [6]

Przykłady zastosowania CNN w diagnostyce elementów systemu transportu szynowego

3. Diagnostyka osi zestawu kołowego wózka typu Y21



Rys. 10. Architektura sieci neuronowej oraz dane wejściowe[6]

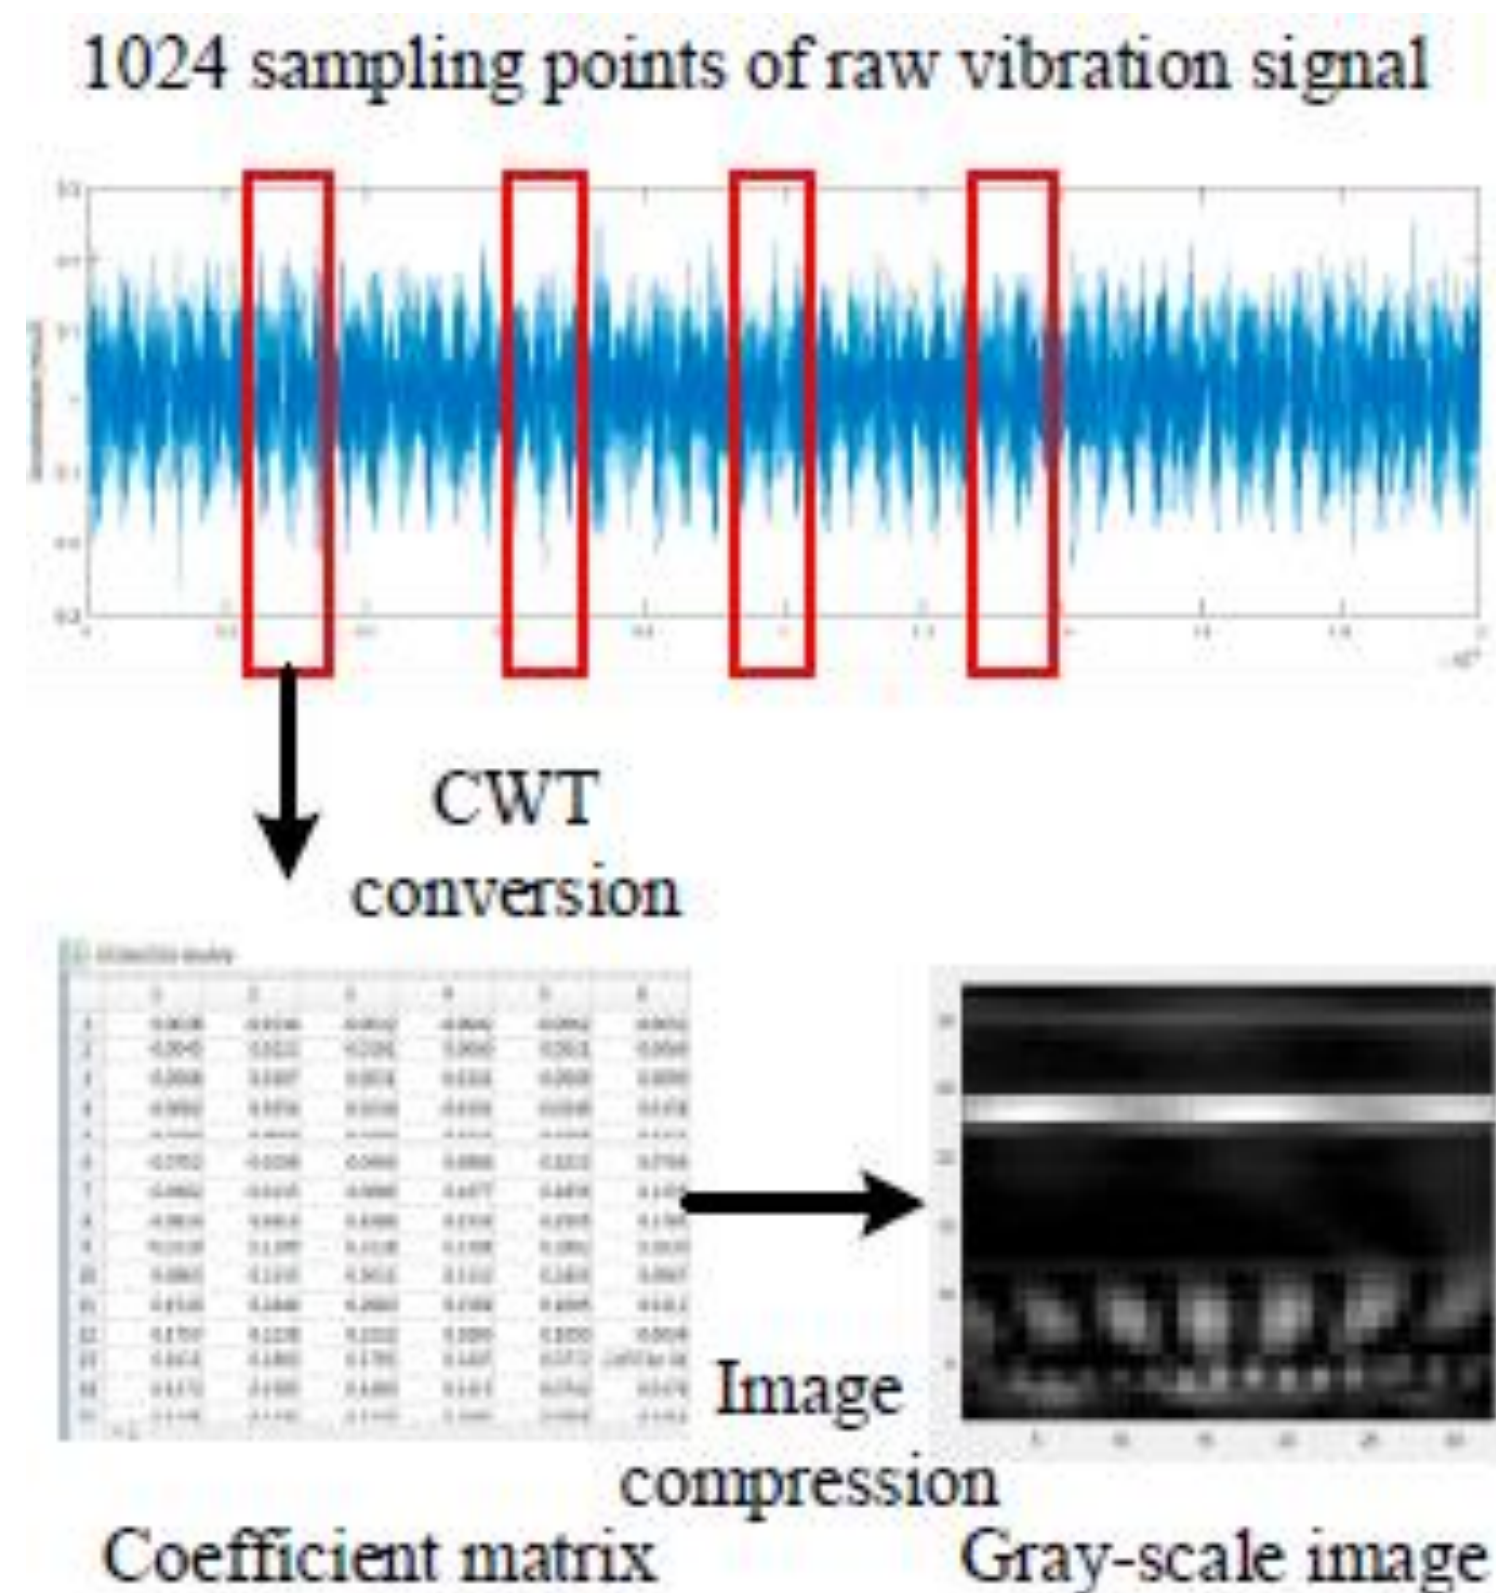
Dla sieci neuronowej zastosowano zestaw danych w postaci:

- spektrogramu uszkodzonej osi
- spektrogramu osi bez uszkodzeń
- dodatkowych danych związanych z eksperymentem.

Uzyskane dane z sieci CNN dostarczane są do sieci MLP (Multilayer Perceptron), która odpowiada za klasyfikację.

Przykłady zastosowania CNN w diagnostyce elementów systemu transportu szynowego

4. Diagnostyka łożysk tocznych




Pierwszym etapem przygotowania danych jest konwersja sygnału na obraz oparta o ciągłą transformatę falkową.

Funkcje falkowe skutecznie wychwytyją niestacjonarną charakterystykę sygnału. W tym przypadku zastosowano falkę Morleta.

Przykłady zastosowania CNN w diagnostyce elementów systemu transportu szynowego

4. Diagnostyka łożysk tocznych

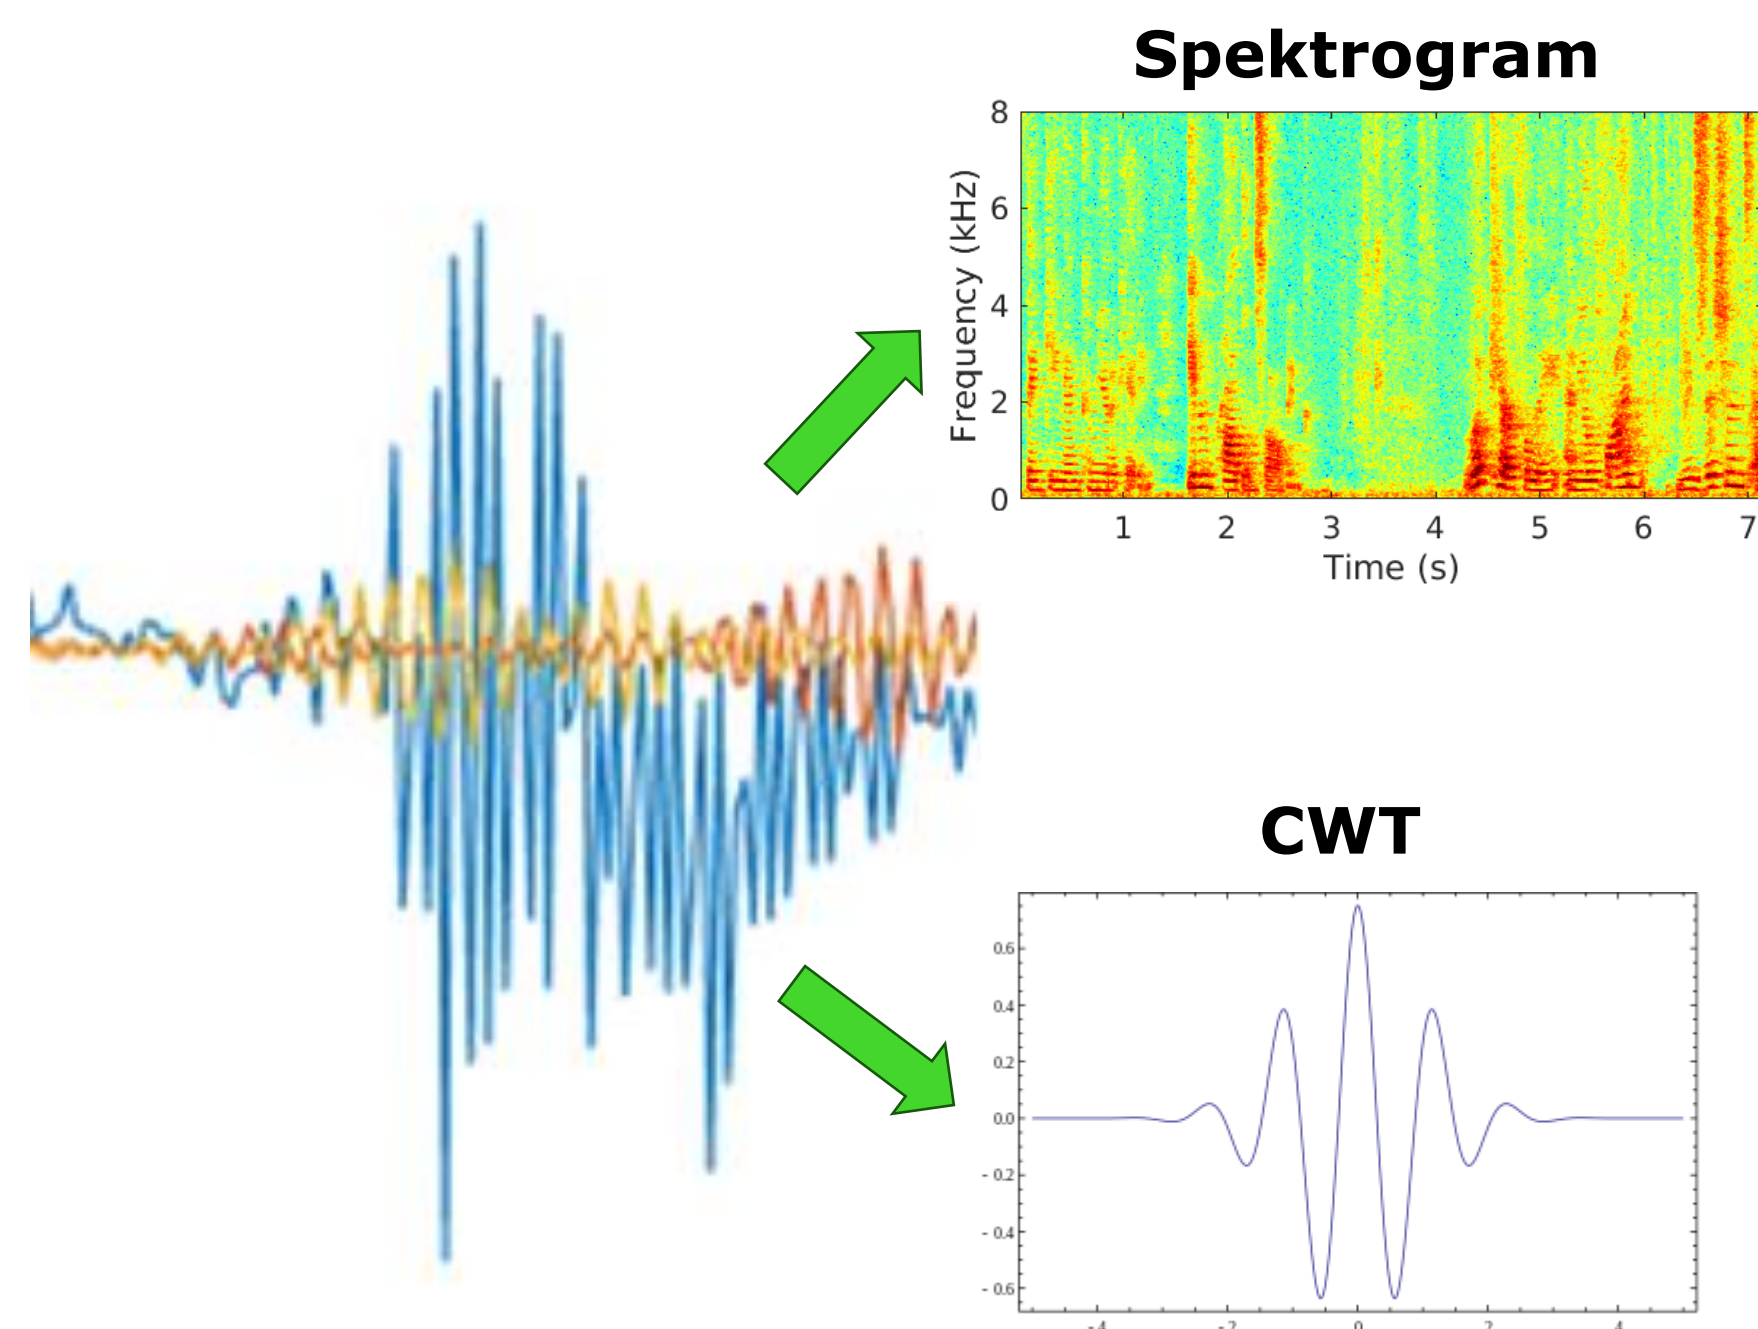


Rys. 12. Architektura zastosowanej sieci neuronowej [7]

Zaproponowana architektura sieci bazuje na ulepszonej sieci LeNet-5, która automatycznie wyodrębnia z obrazów reprezentatywne cechy i pozwala klasyfikatorom poprawnie rozpoznać rodzaj uszkodzeń.

Przykłady zastosowania CNN w diagnostyce elementów systemu transportu szynowego

5. Diagnostyka luzów zaworowych silnika wysokoprężnego



Rys. 13. Przykładowy sygnał wibroakustyczny oraz metody transformacji [praca własna]


Eksperyment polegał na rejestrowaniu sygnałów wibroakustycznych w zależności od prędkości obrotowej oraz obciążenia silnika przy danych nastawach luzu zaworowego.

W ramach wcześniejszych prac zastosowano wybrane sygnały, które były reprezentowane przez miary punktowe oraz sieć neuronową w postaci perceptronu wielowarstwowego (MLP).

Dalsze prace polegają na zamianie sygnałów na spektrogramy oraz obrazy powstałe w wyniku zastosowania ciągłej transformacji falkowej.

Następnie dla uzyskane obrazy zostaną dostarczone do konwolucyjnych sieci neuronowych.

Podsumowanie



Bibliografia

- [1] Trask, A. (2019). Zrozumieć głębokie uczenie, Wydawnictwo Naukowe PWN, Warszawa
- [2] Tadeusiewicz, R., Szaleniec, M. (2015). Leksykon sieci neuronowych, Wydawnictwo Fundacji „Projekt Nauka”, Wrocław.
- [3] <https://www.frontiersin.org/articles/10.3389/fpsyg.2021.663359/full> (dostęp 05-09-2023)
- [4] Kang G., Gao S., Yu L., Zhang D. (2019). Deep Architecture for High-Speed Railway Insulator Surface Defect Detection: Denoising Autoencoder With Multitask Learning. *IEEE Transactions on Instrumentation and Measurement*. 68. 2679-2690.
- [5] Bojarczak, P., Lesiak, P. (2021). UAVs in rail damage image diagnostics supported by deep-learning networks. *Open Engineering*, 11(1), 339-348.
- [6] Galdo A. L., Guerrero-López A., Olmos P. M., Gómez García M. J. Detecting train driveshaft damages using accelerometer signals and differential Convolutional Neural Networks, *Engineering Applications of Artificial Intelligence* 126 (2023)
- [7] Xu G., Min L., Jiang Z., Söffker D., Shen W. Bearing Fault Diagnosis Method Based on Deep Convolutional Neural Network and Random Forest Ensemble Learning, *Sensors* 2019, 19, 1088

Dziękujemy za uwagę.

Julia Milewicz

 julia.milewicz@pit.lukasiewicz.gov.pl

Krzysztof Kołodziejczak

 krzysztof.kolodziejczak@pit.lukasiewicz.gov.pl

