

POLITECHNIKA POZNAŃSKA

WYDZIAŁ AUTOMATYKI, ROBOTYKI
I ELEKTROTECHNIKI

INSTYTUT ELEKTROTECHNIKI
I ELEKTRONIKI PRZEMYSŁOWEJ

ZAKŁAD MECHATRONIKI
I MASZYN ELEKTRYCZNYCH



mgr inż. Konrad Górny

Rozprawa doktorska

Metody uczenia maszynowego w diagnostyce uzwojenia stojana silnika indukcyjnego z wykorzystaniem polowego modelu zjawisk elektromagnetycznych

Promotor: *dr hab. inż. Wojciech Pietrowski*

Promotor pomocniczy: *dr hab. inż. Mariusz Barański*

Poznań 2024

Pragnę wyrazić głęboką wdzięczność moim Promotorom, dr hab. inż. Wojciechowi Pietrowskiemu oraz dr hab. inż. Mariuszowi Barańskiemu, za nieocenione wsparcie oraz cenny czas poświęcony na pomoc w realizacji niniejszej pracy.

Szczególne podziękowania kieruję do mojej żony Alicji oraz Rodziców za ich bezwarunkowe wsparcie, motywujące słowa oraz nieskończone pokłady cierpliwości.

Streszczenie

W niniejszej rozprawie noszącej tytuł „**Metody uczenia maszynowego w diagnostyce uzwojenia stojana silnika indukcyjnego z wykorzystaniem polowego modelu zjawisk elektromagnetycznych**„, zbadano możliwość zastosowania polowego modelu zjawisk elektromagnetycznych oraz metod uczenia maszynowego w diagnostyce uzwojenia stojana maszyny indukcyjnej. Celem zrealizowanych badań była poprawa niezawodności pracy trójfazowych silników indukcyjnych poprzez wdrożenie do procesu diagnostycznego modelu polowego trójfazowego silnika indukcyjnego oraz konwolucyjnej sieci neuronowej. Na podstawie kompleksowej analizy literatury, autor szczegółowo omówił aktualne metody diagnostyczne, metody przetwarzania sygnału, a także modele matematyczne trójfazowych silników indukcyjnych w ujęciu obwodowym i polowym, z uwzględnieniem uszkodzeń uzwojenia stojana.

W ramach badań opracowano i zweryfikowano polowo-obwodowe modele trójfazowych silników indukcyjnych. Ponadto autor zestawiał metody i równania opisujące rozkład pola elektromagnetycznego za pomocą potencjałów skalarnych i wektorowych. Opracowane modele umożliwiły wyznaczenie oraz analizę przebiegów prądów fazowych trójfazowego silnika indukcyjnego, bez oraz z uwzględnieniem zwarć międzyzwojowych we wszystkich fazach rozpatrywanej maszyny. Przeprowadzono analizę wyników badań symulacyjnych, tworząc na ich podstawie bazę danych zawierającą przebiegi prądów fazowych. Dokonano eksperymentalnej weryfikacji utworzonego modelu polowego silnika indukcyjnego. Dodatkowo, w ramach pracy omówiono metody uczenia maszynowego stosowane w diagnostyce silników elektrycznych, ze szczególnym uwzględnieniem głębokich sieci neuronowych. W ramach badań opracowano autorskie oprogramowanie do wizualizacji struktury, treningu, strojenia hiperparametrów i analizy wyników konwolucyjnych sieci neuronowych. Przeanalizowano wpływ rodzaju danych treningowych i strojenia hiperparametrów na wyniki detekcji i klasyfikacji zwarć międzyzwojowych uzwojenia stojana silnika indukcyjnego. Dokonano szczegółowej analizy otrzymanych wyników oraz omówiono ich wpływ na efektywności klasyfikacji utworzonych modeli konwolucyjnych sieci neuronowych. Osiągnięcia zaprezentowane w rozprawie stanowią podstawę dla dalszych prac nad zagadnieniem zastosowania głębokich sieci neuronowych do wczesnej diagnostyki trójfazowych silników indukcyjnych.

Abstract

In this doctoral dissertation titled "Machine learning methods in the diagnostics of induction motor stator windings using a field model of electromagnetic phenomena" the possibility of applying a field model of electromagnetic phenomena and machine learning methods in the diagnostics of induction motor stator windings was investigated. The aim of the conducted research was to improve the reliability of three-phase induction motors by implementing a field model of a three-phase induction motor and a convolutional neural network into the diagnostic process. Based on a comprehensive literature review, the author thoroughly discussed current diagnostic methods, signal processing methods, as well as mathematical models of three-phase induction motors in circuit and field approaches, taking into account stator winding faults.

As part of the research, field-circuit models of three-phase induction motors were developed and verified. Additionally, the author compiled methods and equations describing the distribution of the electromagnetic field using scalar and vector potentials. The developed models enabled the determination and analysis of the phase currents of a three-phase induction motor, both with and without considering inter-turn short circuits in all phases of the considered machine. A simulation analysis of the research results was conducted, creating a database containing phase current waveforms based on the findings. An experimental verification of the developed field model of the induction motor was also carried out.

Furthermore, the dissertation discussed machine learning methods used in the diagnostics of electric motors, with a particular emphasis on deep neural networks. Proprietary software was developed within the research for visualizing the structure, training, hyperparameter tuning, and analyzing the results of convolutional neural networks. The impact of the type of training data and hyperparameter tuning on the results of inter-turn short circuit detection and classification of the induction motor stator winding was analyzed. A detailed analysis of the obtained results was conducted, and their impact on the classification efficiency of the developed convolutional neural network models was discussed. The achievements presented in the dissertation form the basis for further work on the application of deep neural networks for the early diagnostics of three-phase induction motors.

Spis treści

1	Wprowadzenie. Cel, teza i zakres pracy	13
2	Diagnostyka silnika indukcyjnego klatkowego	20
2.1	Klasyfikacja sygnałów diagnostycznych	26
2.2	Wybrane metody przetwarzania sygnału	28
2.3	Pozyskiwanie sygnału diagnostycznego	30
3	Modele matematyczne silników indukcyjnych.....	32
3.1	Wprowadzenie	32
3.2	Opis modelu silnika indukcyjnego o parametrach skupionych	32
3.3	Opis matematyczny uzwojenia stojana z uwzględnieniem zwarcia międzyzwojowego.....	45
3.4	Opis matematyczny silnika indukcyjnego w ujęciu polowym.....	50
4	Metody uczenia maszynowego w diagnostyce silników elektrycznych.....	58
4.1	Wprowadzenie	58
4.2	Klasyczne struktury sztucznych sieci neuronowych.....	59
4.2.1	Wielowarstwowa sieć perceptronowa	62
4.2.2	Sieci samoorganizujące.....	71
4.3	Głębokie sieci neuronowe	75
4.3.1	Splotowe sieci neuronowe	80
4.4	Metody oceny klasyfikatora.....	88
5	Głębokie sieci neuronowe w diagnostyce uzwojenia stojana silnika indukcyjnego	93
5.1	Wprowadzenie	93
5.2	Modelowanie uzwojenia stojana silnika bez uwzględnienia zwarcí międzyzwojowych – wyznaczanie sygnału diagnostycznego.....	95
5.3	Modelowanie silnika z uwzględnieniem zwarcí międzyzwojowych w obwodzie stojana – wyznaczanie sygnału diagnostycznego	102
5.4	Badania eksperymentalne	111

5.5 Konwolucyjne sieci neuronowe w diagnostyce uzwojenia stojana silnika indukcyjnego	118
5.5.1 Wprowadzenie	119
5.5.2 Bazowa struktura konwolucyjnej sieci neuronowej do klasyfikacji zwarć międzyzwojowych uzwojenia stojana silnika indukcyjnego.....	119
5.5.3 Strojenie hiperparametrów konwolucyjnej sieci neuronowej do klasyfikacji zwarć międzyzwojowych uzwojenia stojana silnika indukcyjnego	148
6 Wnioski i uwagi końcowe.....	168
Literatura	171
ZAŁĄCZNIKI.....	187
Wykaz rysunków:.....	187
Wykaz tabel:.....	190

Wykaz wybranych oznaczeń:

Oznaczenia parametrów modelowania matematycznego:

U - napięcie,

U_A^S - napięcie fazy A uzwojenia stojana,

U_{AF}^S - napięcie na niezwartych zwojach cewki fazy A uzwojenia stojana,

U_{AS}^S - napięcie na zwartych zwojach cewki fazy A uzwojenia stojana,

U_B^S - napięcie fazy B uzwojenia stojana,

U_C^S - napięcie fazy C uzwojenia stojana,

$U_A'^R$ - napięcie fazy A uzwojenia wirnika sprowadzone na stronę stojana,

$U_B'^R$ - napięcie fazy B uzwojenia wirnika sprowadzone na stronę stojana,

$U_C'^R$ - napięcie fazy C uzwojenia wirnika sprowadzone na stronę stojana,

i, I - prąd,

i_A^S - prąd fazy A uzwojenia stojana,

i_{AF}^S - prąd w niezwartych zwojach cewki fazy A uzwojenia stojana,

i_{AS}^S - prąd w zwartych zwojach cewki fazy A uzwojenia stojana,

i_B^S - prąd fazy B uzwojenia stojana,

i_C^S - prąd fazy C uzwojenia stojana,

$i_A'^R$ - prąd fazy A uzwojenia wirnika sprowadzony na stronę stojana,

$i_B'^R$ - prąd fazy B uzwojenia wirnika sprowadzony na stronę stojana,

$i_C'^R$ - prąd fazy C uzwojenia wirnika sprowadzony na stronę stojana,

R - rezystancja,

R_A^S - rezystancja fazy A uzwojenia stojana,

R_{AF}^S - rezystancja niezwartych zwojów cewki fazy A uzwojenia stojana,

R_{AS}^S - rezystancja zwartych zwojów cewki fazy A uzwojenia stojana,

R_B^S - rezystancja fazy B uzwojenia stojana,

R_C^S - rezystancja fazy C uzwojenia stojana,

$R_A'^R$ - rezystancja fazy A uzwojenia wirnika sprowadzona na stronę stojana,

$R_B'^R$ - rezystancja fazy B uzwojenia wirnika sprowadzona na stronę stojana,

$R_C'^R$ - rezystancja fazy C uzwojenia wirnika sprowadzona na stronę stojana,

L - indukcyjność,

$L_{A\alpha}^S$ - indukcyjność rozproszenia fazy A uzwojenia stojana,

$L_{AF\alpha}^S$ - indukcyjność rozproszenia niezwartych zwojów cewki fazy A uzwojenia stojana,

$L_{AS\alpha}^S$ - indukcyjność rozproszenia zwartych zwojów cewki fazy A uzwojenia stojana,

$L_{B\alpha}^S$ - indukcyjność rozproszenia fazy B uzwojenia stojana,

$L_{C\alpha}^S$ - indukcyjność rozproszenia fazy C uzwojenia stojana,

$L_{A\alpha}'^R$ - indukcyjność rozproszenia fazy A uzwojenia wirnika sprowadzona na stronę stojana,

$L_{B\alpha}'^R$ - indukcyjność rozproszenia fazy B uzwojenia wirnika sprowadzona na stronę stojana,

$L_{C\alpha}'^R$ - indukcyjność rozproszenia fazy C uzwojenia wirnika sprowadzona na stronę stojana,

L_{AB}^S - indukcyjność własna fazy A uzwojenia stojana,

L_{AFB}^S - indukcyjność własna niezwartych zwojów cewki fazy A uzwojenia stojana,

L_{ASB}^S - indukcyjność własna zwartych zwojów cewki fazy A uzwojenia stojana,

L_{BB}^S - indukcyjność własna fazy B uzwojenia stojana,

L_{CB}^S - indukcyjność własna fazy C uzwojenia stojana,

$L_{AB}'^R$ - indukcyjność własna fazy A uzwojenia wirnika sprowadzona na stronę stojana,

$L'_{B\beta}{}^R$ - indukcyjność własna fazy B uzwojenia wirnika sprowadzona na stronę stojana,

$L'_{C\beta}{}^R$ - indukcyjność własna fazy C uzwojenia wirnika sprowadzona na stronę stojana,

M - indukcyjność wzajemna,

$M_{AB\beta}^S$ - indukcyjność wzajemna między fazą A uzwojenia stojana, a fazą B uzwojenia stojana,

$M_{AFAS\beta}^S$ - indukcyjność wzajemna między niezwartymi zwojami cewki fazy A uzwojenia stojana, a zwartymi zwojami cewki fazy A uzwojenia stojana,

$M_{AFB\beta}^S$ - indukcyjność wzajemna między niezwartymi zwojami cewki fazy A uzwojenia stojana, a fazą B uzwojenia stojana,

$M_{ASB\beta}^S$ - indukcyjność wzajemna między zwartymi zwojami cewki fazy A uzwojenia stojana, a fazą B uzwojenia stojana,

$M_{AFC\beta}^S$ - indukcyjność wzajemna między niezwartymi zwojami cewki fazy A uzwojenia stojana, a fazą C uzwojenia stojana,

$M_{ASC\beta}^S$ - indukcyjność wzajemna między zwartymi zwojami cewki fazy A uzwojenia stojana, a fazą C uzwojenia stojana,

$M_{AC\beta}^S$ - indukcyjność wzajemna między fazą A uzwojenia stojana, a fazą C uzwojenia stojana,

$M_{BC\beta}^S$ - indukcyjność wzajemna między fazą B uzwojenia stojana, a fazą C uzwojenia stojana,

$M'_{AB\beta}{}^R$ - indukcyjność wzajemna między fazą A uzwojenia wirnika, a fazą B uzwojenia wirnika sprowadzona na stronę stojana,

$M'_{AC\beta}{}^R$ - indukcyjność wzajemna między fazą A uzwojenia wirnika, a fazą C uzwojenia wirnika sprowadzona na stronę stojana,

$M'_{BC\beta}{}^R$ - indukcyjność wzajemna między fazą B uzwojenia wirnika, a fazą C uzwojenia wirnika sprowadzona na stronę stojana,

$M'_A{}^{SR}$ - indukcyjność wzajemna między fazą A uzwojenia stojana a uzwojeniem wirnika sprowadzona na stronę stojana,

$M'_{AF}{}^{SR}$ - indukcyjność wzajemna między niezwartymi zwojami cewki fazy A uzwojenia stojana a uzwojeniem wirnika sprowadzona na stronę stojana,

$M'_{AS}{}^{SR}$ - indukcyjność wzajemna między zwartymi zwojami cewki fazy A uzwojenia stojana a uzwojeniem wirnikiem sprowadzona na stronę stojana,

$M'_{B}{}^{SR}$ - indukcyjność wzajemna między fazą B uzwojenia stojana a uzwojeniem wirnika sprowadzona na stronę stojana,

$M'_{C}{}^{SR}$ - indukcyjność wzajemna między fazą C uzwojenia stojana a uzwojeniem wirnikiem sprowadzona na stronę stojana,

p - liczba par biegunów uzwojenia stojana/wirnika,

T_e - moment elektromagnetyczny,

T_L - moment obciążenia,

J - moment bezwładności,

ω - pulsacja,

φ - przesunięcie fazowe,

μ - przenikalność magnetyczna środowiska,

\mathbf{E} - wektor natężenia pola elektrycznego,

\mathbf{H} - wektor natężenia pola magnetycznego,

\mathbf{B} - wektor indukcji magnetycznej,

\mathbf{J} - wektor gęstości prądu,

V - skalarny potencjał elektryczny,

Ω - skalarny potencjał magnetyczny,

\mathbf{T} - wektorowy potencjał elektryczny,

\mathbf{A} - wektorowy potencjał magnetyczny.

Oznaczenia parametrów przetwarzania sygnałów:

T - okres sygnału,

A - amplituda sygnału,

f - częstotliwość sygnału,

Oznaczenia parametrów uczenia maszynowego:

φ - funkcja aktywacji neuronu,

$x(m)$ - dyskretny sygnał wyjściowy,

$x(n)$ - analizowany sygnał dyskretny,

n - numer przetwarzanej próbki,

m - indeks próbki wyjściowej,

N - liczba próbek analizowanego sygnału dyskretnego,

L - liczba warstw w sieci neuronowej,

$x_1, x_2, x_3, \dots, x_n$ - sygnały wejściowe neuronu,

$w_1, w_2, w_3, \dots, w_n$ - wagi sygnałów wejściowych,

e - suma ważona sygnałów wejściowych,

$y(e)$ - sygnał wyjściowy neuronu,

e_i - suma ważona sygnału wyjściowego i -tego neuronu,

w_{ij} - waga j -tego wejścia i -tego neuronu,

\mathbf{x} - wektor wejściowy,

x_i - sygnał wejściowy i -tego neuronu,

\mathbf{w} - wektor współczynników wagowych,

w_{i0} - bias i -tego wejścia,

y_i - sygnał wyjściowy i -tego neuronu,

$Q(n)$ - błąd średniokwadratowy n -tej iteracji,

$x_j^{(k)}$ - i -ty sygnał na wejściu k -tej warstwy,

μ - współczynnik uczenia,

$p(w(n))$ - kierunek minimalizacji funkcji błędu,

$\nabla \mathcal{E}$ - gradient funkcji błędu,

$\nabla^2 \mathcal{E}$ - hesjan funkcji błędu,

$d_i^{(L)}(n)$ - wartość wzorcowa/spodziewana,

$y_i^{(L)}(n)$ - wartość wyjściową neuronu,

I - macierz jednostkowa,

J - jacobian funkcji błędu,

$\mathcal{E}(w(n))$ - wartość błędu w ostatniej warstwie sieci neuronowej,

h_{ci} - funkcja sąsiedztwa sieci Kohonena.

1 Wprowadzenie. Cel, teza i zakres pracy

Dynamicznie rozwijający się światowy przemysł przyczynia się do coraz większego zapotrzebowania na wykorzystanie układów napędowych w procesach technologicznych [1, 2]. Wiąże się to z stosowaniem większej liczby silników elektrycznych, zużywających blisko 50% światowej produkcji energii elektrycznej. W zastosowaniach przemysłowych wciąż pierwszym wyborem dla napędu elektrycznego są maszyny indukcyjne (IM). Wpływa na to ich prosta konstrukcja, duża niezawodność, małe koszty eksploatacji i niska cena. Silniki IM dobrze sprawdzają się w układach bezpośredniego rozruchu z sieci. Z drugiej strony większe zużycie energii biernej, oraz straty w klatce wirnika wpływają na stosunkowo niską sprawność oraz współczynnik mocy, w porównaniu np. z silnikami synchronicznymi z magnesami trwałymi (PMSM) [3]. Niestety, wadą PMSM jest konieczność stosowania układów przekształtnikowych, co m.in. zwiększa cenę tego typu napędu elektrycznego. W napędach pracujących przy stałej prędkości obrotowej, koszt ten można zminimalizować wykorzystując silniki synchroniczne przystosowane do rozruchu bezpośredniego (LSPMSM), w których do generowania pola magnetycznego w wirniku z klatką rozruchową wykorzystuje się magnesy trwale umieszczone powierzchniowo lub zatopione w wirniku. Silniki takie znajdują szerokie zastosowanie w przemyśle jako napędy do pomp czy wentylatorów [4, 5].

Aby sprostać problemom wynikającym ze zwiększonego zapotrzebowania na silniki elektryczne, w wielu ośrodkach naukowo-badawczych realizowane są prace mające na celu opracowanie metod zwiększających niezawodność i efektywność pracy elektrycznych układów napędowych [6–8].

Prace te ukierunkowane są na opracowywanie nowych konstrukcji maszyn elektrycznych mających na celu, m.in. poprawienie ich parametrów rozruchowych czy znamionowych. Realizowane są również badania nad opracowaniem nowych metod diagnostycznych, umożliwiających szybką i precyzyjną ocenę stanu technicznego elektrycznych układów napędowych.

Istnieje kilka metod na poprawę niezawodności pracy układów napędowych, wśród których można wyróżnić m.in.:

- wprowadzenie układów redundantnych, które w przypadku awarii pracującego napędu przejmą jego funkcję zapewniając dalszą funkcjonalność systemu,
- zapewnienie optymalnych warunków pracy układu napędowego, zmniejszając tym samym prawdopodobieństwo wcześniejszej degradacji stanu technicznego np. elektroizolacji układu,
- zastosowanie maszyn wielofazowych, które przy odpowiednio przygotowanym układzie sterowania mogą zapewnić ciągłość pracy systemu podczas awarii np. jednej z faz uzwojenia stojana,
- wczesna i nieinwazyjna diagnostyka napędu, która poprzez wykorzystanie wyników analizy sygnałów diagnostycznych pozwala na przygotowanie procesu diagnostycznego, umożliwiającego możliwie jak najwcześniejsze wykrycie awarii, a tym samym przygotowanie procedur konserwacyjnych z odpowiednim wyprzedzeniem.

Wszystkie wymienione wyżej metody zwiększania niezawodności pracy układu napędowego mogą być stosowane niezależnie, ale mogą być one również wykorzystywane w jednym systemie uzupełniając się wzajemnie. Niestety, wykorzystanie układów redundantnych czy zastosowanie maszyn wielofazowych wiąże się z podwyższonymi kosztami inwestycji oraz samej eksploatacji układu, a zapewnienie optymalnych warunków jego pracy nie zawsze jest możliwe ze względu na liczne obszary zastosowań układów napędowych.

W przedłożonej rozprawie skupiono się na wczesnej i nieinwazyjnej diagnostyce silników indukcyjnych, która może stanowić samodzielną metodę diagnostyczną, jak również może być uzupełnieniem innych metod poprawy niezawodności pracy elektrycznych układów napędowych.

W wyniku dynamicznego rozwoju elektroniki, a tym samym większej dostępności układów przekształtnikowych takich jak np. przetworniki częstotliwości, również silniki indukcyjne znajdują szerokie zastosowanie w układach napędowych stosowanych w różnych gałęziach przemysłu [9–18]. Silniki indukcyjne z powodzeniem stosowane są np. jako napędy coraz popularniejszych pojazdów elektrycznych [19, 20]. Popularność silników asynchronicznych w rozwiązaniach napędowych zostaje zapewniona dzięki prostocie konstrukcji, niskim kosztom produkcji, możliwości regulacji prędkości obrotowej w szerokim zakresie, jak również dużemu momentowi

rozruchowemu. Możliwość regulacji prędkości obrotowej w szerokim zakresie, a także duży moment rozruchowy, mają istotny wpływ na dynamikę układu np. pojazdów elektrycznych, i w ich przypadku przekłada się bezpośrednio na wartość przyspieszenia, a pośrednio na bezpieczeństwo w ruchu drogowym. Dodatkowo, dzięki coraz lepszym właściwościom elektrycznym i magnetycznym materiałów, z których produkowane są silniki asynchroniczne, możliwe jest zwiększenie gęstości mocy i korzystniejszego wyzyskania zastosowanych materiałów, a w konsekwencji miniaturyzacja tych maszyn. Innowacyjne podejście w projektowaniu sprawia, że silniki asynchroniczne znajdują zastosowanie nie tylko jako napędy przemysłowe czy napędy w dużych pojazdach trakcyjnych, ale także coraz częściej można spotkać ich zastosowanie w samochodach ciężarowych, osobowych, a nawet motocyklach elektrycznych. Pomimo wysiłków projektowych mających na celu zwiększenie ich niezawodności, to w praktycznych zastosowaniach awarie silników elektrycznych nadal występują. Początkowe etapy awarii mogą nie mieć znaczącego wpływu na poprawne działanie maszyny, a ich wykrycie na wczesnym etapie występowania jest znacznie utrudnione [21–23]. Niewielkie uszkodzenia mogą jednak propagować wewnątrz silnika, co może doprowadzić do jego uszkodzenia. Konsekwencją awarii silnika może być zatrzymanie całego układu napędowego w procesie technologicznym [15, 24–26], a nawet stanowić zagrożenie dla zdrowia i życia. Rosnące zainteresowanie napędami z silnikami indukcyjnymi, a także szerokie spektrum ich zastosowania sprawia, że coraz większą rolę w ich eksploatacji odgrywa diagnostyka, a zapewnienie bezawaryjnej pracy staje się priorytetem nie tylko z ekonomicznego punktu widzenia firm i przedsiębiorstw [9, 27–31], ale również z punktu widzenia bezpieczeństwa.

Z przedstawionych w literaturze wyników badań eksploatacyjnych można wywnioskować, że procentowy udział uszkodzeń poszczególnych podzespołów silników indukcyjnych, zależy między innymi od mocy znamionowej maszyny. Zauważono, że w przypadku silników małej mocy, tj. silników o znamionowej mocy do 10 kW najczęściej występują awarie mechaniczne łożysk. Stanowią one niespełna 41% wszystkich uszkodzeń. Drugą w kolejności grupę awaryjności silników małej mocy tworzą uszkodzenia stojana, które stanowią blisko 37% wszystkich uszkodzeń [25, 30, 32–35]. Należy również wspomnieć, że ta grupa uszkodzeń przeważa w przypadku silników dużej mocy, powyżej 149 kW [36]. Szczegółową analizę przyczyn awarii silników indukcyjnych autor rozprawy zawarł w rozdziale 2.1.

Do najczęściej występujących uszkodzeń uzwojenia stojana należą zwarcia międzyzwojowe [37]. Powodem ich pojawiania się jest uszkodzenie izolacji drutów nawojowych [38, 39]. Uszkodzenie izolacji może nastąpić z wielu przyczyn np. w wyniku długotrwałego przepływu prądu kilku lub kilkunastokrotnie większego od prądu znamionowego, nadmiernych naprężeń mechanicznych związanych z siłami elektrodynamicznymi działającymi na przewody z prądem czy zbyt wysokiej temperatury wewnątrz maszyny [40–45]. Kolejną przyczyną uszkodzeń izolacji jest coraz powszechniejsze stosowanie przetworników częstotliwości w układzie zasilania. Szybkie kluczowanie tranzystorów może powodować przyspieszenie procesu degradacji izolacji [46, 47]. W wyniku wystąpienia zwarcia międzyzwojowego w uzwojeniu stojana pojawia się asymetria zarówno napięć, jak i prądów fazowych o dużych wartościach skutecznych, co może doprowadzić do całkowitego uszkodzenia maszyny [48]. W badaniach diagnostycznych, ocena stanu izolacji dokonywana jest najczęściej za pomocą pomiarów wielkości dielektrycznych, takich jak współczynnik rozproszenia, pojemność czy rezystancja izolacji [49]. Popularne i rozpowszechnione metody diagnostyczne badania stanu izolacji to pomiar wyładowań niezupełnych, obliczanie indeksu polaryzacji, współczynnika rozproszenia czy też współczynnika mocy [50]. Niemniej metody wymienione powyżej bazują na diagnostyce *offline* i wymagają doświadczenia diagnosty oraz zastosowania kompleksowego systemu pomiarowego [46].

Popularnymi i często stosowanymi technikami diagnostycznymi w przypadku maszyn elektrycznych są te, wykorzystujące sygnał przebiegu prądu lub drgania. Do technik tych zaliczyć można np. Analizę Sygnatury Prądu Silnika (ang. *Motor Current Signature Analysis, MCSA*) [30, 51, 52], czy Analizę Sygnatury Wibracji Silnika (ang. *Motor Vibration Signature Analysis, MVSA*) [53]. Techniki te pozwalają na nieinwazyjną akwizycję sygnału diagnostycznego bez konieczności wyłączenia urządzenia. Zachowane zostaje utrzymanie w ruchu procesu technologicznego, co ma istotne znaczenie z ekonomicznego punktu widzenia przedsiębiorstwa. W związku z powyższym autor w niniejszej rozprawie wykorzystał technikę, w której diagnostykę uszkodzeń silnika IM realizuje się na podstawie sygnału diagnostycznego, jakim jest przebieg prądu fazowego maszyny. Zaletą tego podejścia w odróżnieniu do innych metod diagnostycznych jest rejestracja i analiza tylko jednego sygnału, bez konieczności bezpośredniej ingerencji w pracę układu napędowego. Zaproponowane podejście odróżnia się od innych aktualnie stosowanych metod diagnostycznych

w wykrywaniu zwarć międzyzwojowych, tym, że do analizy wymaga tylko jednego sygnału elektrycznego, mianowicie jego przebiegu. Nie ma więc konieczności rejestrowania innych sygnałów diagnostycznych, do których należą np. przebieg momentu obrotowego [25, 54–56], rozkład strumienia magnetycznego [54, 57–60], zmiany współczynnika mocy układu [55, 61], rozkład temperatury w maszynie [62, 63], czy odpowiedź napięciowa między uzwojeniami na próbę impulsową [64, 65].

Współczesne badania dotyczące rozwoju diagnostyki silników indukcyjnych prowadzone są w wielu kierunkach, wśród nich można wskazać dwa wiodące podejścia. Pierwsze, skupiające się na obliczeniach analitycznych [9, 27]. Drugie, wykorzystuje metody numeryczne [12, 55], przede wszystkim metodę elementów skończonych rzadziej metodę różnic skończonych [66]. Jak wcześniej wspomniano, często wykorzystywanymi sygnałami w diagnostyce silników elektrycznych są przebiegi prądów fazowych lub wibracji. Innymi sygnałami mogą być sygnały akustyczne lub przebiegi momentu obrotowego. Niestety wadą procesu pozyskiwania sygnału diagnostycznego w postaci przebiegów momentu obrotowego, może być konieczność zatrzymania układu napędowego w celu zainstalowania układu pomiarowego, co wiąże się np. z unieruchomieniem procesu produkcji i znacznymi kosztami finansowymi. Więcej informacji na temat diagnostyki na podstawie momentu obrotowego maszyny zawarto m.in. w artykułach [32, 43]. Diagnostyka silników indukcyjnych za pomocą sygnałów wibroakustycznych daje zadowalające wyniki w przypadku wykrycia uszkodzeń mechanicznych maszyny, takich jak niewspółosiowość czy uszkodzenie łożysk. Awaryjne mechaniczne często skutkują znacznymi zmianami symetrii osiowej maszyny, co przekłada się na dodatkowe drgania i hałas [12, 13, 41]. Niestety awaryjne uzwojenia stojana, szczególnie w początkowej fazie występowania, nie wpływają znacząco na wibracje czy sygnał akustyczny. Pomimo tego, że sygnały te mogą być agregowane w sposób nieinwazyjny, ich wykorzystanie w diagnostyce zwarć międzyzwojowych jest możliwe, ale znacznie utrudnione. Mimo, że zwarcia międzyzwojowe znacząco wpływają na odkształcenia przebiegów prądów fazowych silnika, to w początkowej fazie ich występowania, tak jak w przypadku sygnału wibroakustycznego, odkształcenie to może być trudne do identyfikacji, nawet przez eksperta. Niemniej dynamiczny rozwój zarówno w zakresie metod przetwarzania sygnałów, jak i metod sztucznej inteligencji, umożliwia diagnostykę maszyn elektrycznych na podstawie wcześniej niezbyt często stosowanych sygnałów diagnostycznych. Ze względu na to, że zwarcia międzyzwojowe we wczesnym stadium

ich występowania nie wpływają znacząco na przebiegi prądów fazowych, a tym samym są trudne do wykrycia i jednoznacznej interpretacji, autor rozprawy zaproponował zastosowanie zaawansowanych modeli głębokich sieci neuronowych w wykrywaniu takich uszkodzeń stojanów silników indukcyjnych.

Cel i teza pracy

Celem rozprawy jest opracowanie skutecznej metody diagnostyki uzwojeń stojanów silników indukcyjnych, wykorzystującej polowo-obwodowy model zjawisk elektromagnetycznych oraz konwolucyjne sieci neuronowe.

W rozważaniach przyjęto, że zastosowanie w układach napędowych nowych i zaawansowanych konstrukcji silników indukcyjnych nie zapewnia całkowitej bezawaryjności ich pracy. Dlatego też, aby ograniczyć skutki występowania awarii, niezbędna jest wczesna i nieinwazyjna diagnostyka. Z uwagi na to, że skutki awarii silnika są widoczne m.in. w przebiegach prądów, mogą być one z powodzeniem wykorzystane jako sygnały diagnostyczne. Na podstawie wyników analizy tych wielkości można dokonać skutecznej oceny stanu technicznego silnika. Do wnioskowania o stanie technicznym można zastosować metody uczenia maszynowego. Sygnał diagnostyczny do trenowania, walidacji i testowania konwolucyjnej sieci neuronowej, można pozyskać z wykorzystaniem polowo-obwodowego modelu trójfazowego silnika indukcyjnego.

Postawiono tezę, że zastosowanie metod uczenia maszynowego z wykorzystaniem polowo-obwodowego modelu zjawisk elektromagnetycznych może poprawić skuteczność metod diagnostyki uzwojenia stojana trójfazowych silników indukcyjnych.

Zakres pracy

Prezentowana rozprawa skoncentrowana jest na opracowaniu skutecznej metody diagnostyki silników indukcyjnych z uwzględnieniem zwarć międzyzwojowych uzwojenia stojana. Do pozyskania sygnałów diagnostycznych opracowano polowo-obwodowy model silnika indukcyjnego klatkowego z uwzględnieniem uszkodzeń uzwojenia stojana. Natomiast do klasyfikacji uszkodzenia zastosowano głęboką sieć neuronową. Praca została podzielona na sześć rozdziałów w których poruszone zostały następujące zagadnienia:

Rozdział drugi pracy omawia zagadnienia związane z diagnostyką silników indukcyjnych. Przedstawia klasyfikację sygnałów diagnostycznych, metody ich przetwarzania oraz szczegółowo opisuje proces pozyskiwania sygnału diagnostycznego.

Rozdział trzeci skupia się na modelach matematycznych silników indukcyjnych. Zawiera wprowadzenie do tematyki, opis modelu silnika o parametrach skupionych, matematyczny model uzwojenia stojana uwzględniający zwarcia międzyzwojowe, a także przedstawia model polowo-obwodowy silnika indukcyjnego oraz równania opisujące rozkład pola elektromagnetycznego za pomocą potencjałów skalarnych i wektorowych.

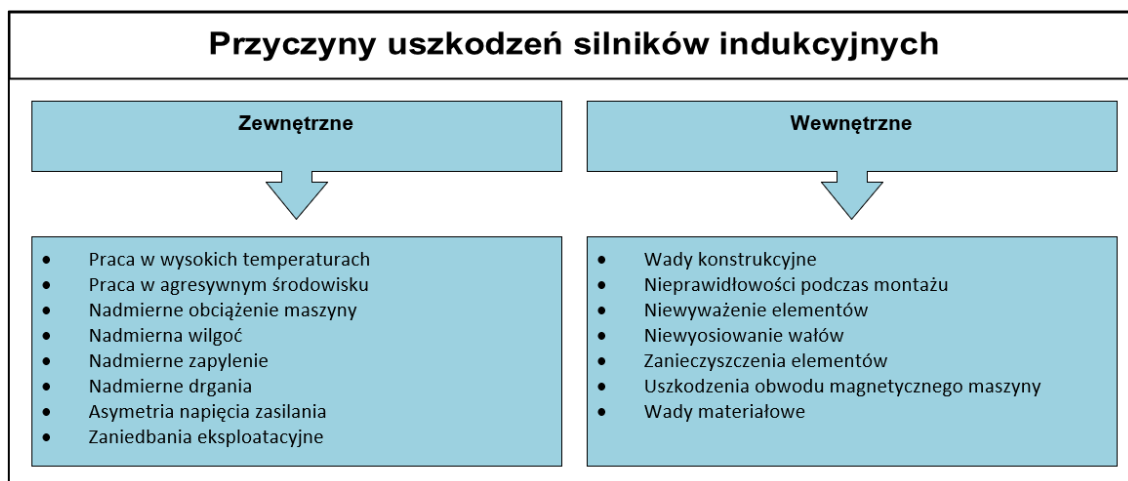
W rozdziale czwartym omówiono metody uczenia maszynowego stosowane w diagnostyce silników elektrycznych. Przedstawiono w nim szczegółowo klasyczne struktury sztucznych sieci neuronowych, takie jak wielowarstwowa sieć perceptronowa i sieci samoorganizujące, a także aktualnie popularne modele głębokich sieci neuronowych, w tym splotowe sieci neuronowe. Dodatkowo w rozdziale czwartym omówiono metody oceny klasyfikatorów neuronowych.

Rozdział piąty dotyczy zastosowania obwodowo-polowego modelu zjawisk elektromagnetycznych i głębokich sieci neuronowych w diagnostyce uzwojenia stojana silnika indukcyjnego. Opisuje opracowane modele trójfazowego silnika indukcyjnego bez oraz z uwzględnieniem uszkodzeń uzwojenia stojana, badania eksperymentalne jak również opracowane modele konwolucyjnych sieci neuronowych. Ponadto w rozdziale piątym przedstawiono wyniki procesu trenowania opracowanych modeli sztucznych sieci neuronowych, zaprezentowano proces strojenia hiperparametrów sieci a także przedstawiono oraz omówiono wyniki opracowanych klasyfikatorów.

Rozdział szósty zawiera wnioski i uwagi końcowe dotyczące tematyki i wyników rozprawy.

2 Diagnostyka silnika indukcyjnego klatkowego

W układach napędowych, w zależności od potrzeb, wykorzystywane są różne typy silników elektrycznych, tj. od silników prądu stałego (ang. *Direct Current motor, DC*), przez bezszczotkowe silniki prądu stałego (ang. *Brushless Direct Current motor, BLDC*), silniki krokowe (ang. *Stepper motor*), reluktancyjne (ang. *Reluctance motor*), synchroniczne (ang. *Synchronous motor, SM*), po silniki asynchroniczne indukcyjne (ang. *Induction motor, IM*). Silniki asynchroniczne stanowią największy udział ze wszystkich silników wykorzystywanych w przemyśle. Mimo rozwoju technologicznego, który umożliwia stosowanie coraz nowszych, a co za tym idzie lepszych rozwiązań konstrukcyjnych i nowoczesnych materiałów w budowie silników indukcyjnych, w dalszym ciągu są one narażone na awarię. Awarie silników indukcyjnych mogą ograniczyć lub wręcz uniemożliwić pracę układu napędowego. Konsekwencją awarii są przestoje technologiczne, które w rezultacie w znacznym stopniu mogą rzutować na aspekt ekonomiczny przedsiębiorstw. Najczęstszą przyczyną awarii silników indukcyjnych jest proces starzenia maszyny. Starzenie się silników indukcyjnych wpływa na stan techniczny ich elementów konstrukcyjnych, takich jak łożyska czy izolacja maszyny. Wraz ze zużywaniem się elementów konstrukcyjnych zmieniają się również parametry użytkowe, co może skutkować np. zmniejszeniem wydajności, zwiększeniem ryzyka wystąpienia zwarć czy zwiększonym nagrzewaniem się maszyny. Na starzenie silników elektrycznych wpływ mogą mieć warunki ich pracy, takie jak temperatura otoczenia w której maszyna pracuje, nadmierne zapylenie czy nadmierna wilgoć, nieprawidłowa eksploatacja, niedopatrzania i niedopilnowania przy konserwacji, jak również nieprawidłowy montaż. Wymienione przyczyny nie są jednak jedynymi, które mogą prowadzić do awarii. Do grupy czynników, które mogą powodować uszkodzenia silników indukcyjnych należy dołączyć także zjawiska powodujące powstawanie sił elektromagnetycznych, elektrodynamicznych, magnetycznych czy mechanicznych, które towarzyszą procesowi przetwarzania energii elektrycznej na mechaniczną podczas pracy silnika. Wybrane przyczyny powstawania uszkodzeń w silnikach indukcyjnych przedstawiono na rysunku 2.1.



Rys. 2.1. Przyczyny powstawania uszkodzeń silników indukcyjnych

Uszkodzenia w silnikach asynchronicznych można podzielić na dwie grupy: uszkodzenia obwodu elektrycznego oraz na uszkodzenia mechaniczne. W pracach badawczych dotyczących uszkodzeń silników indukcyjnych najczęściej wyodrębniane są trzy główne kategorie uszkodzeń maszyn, do których należą:

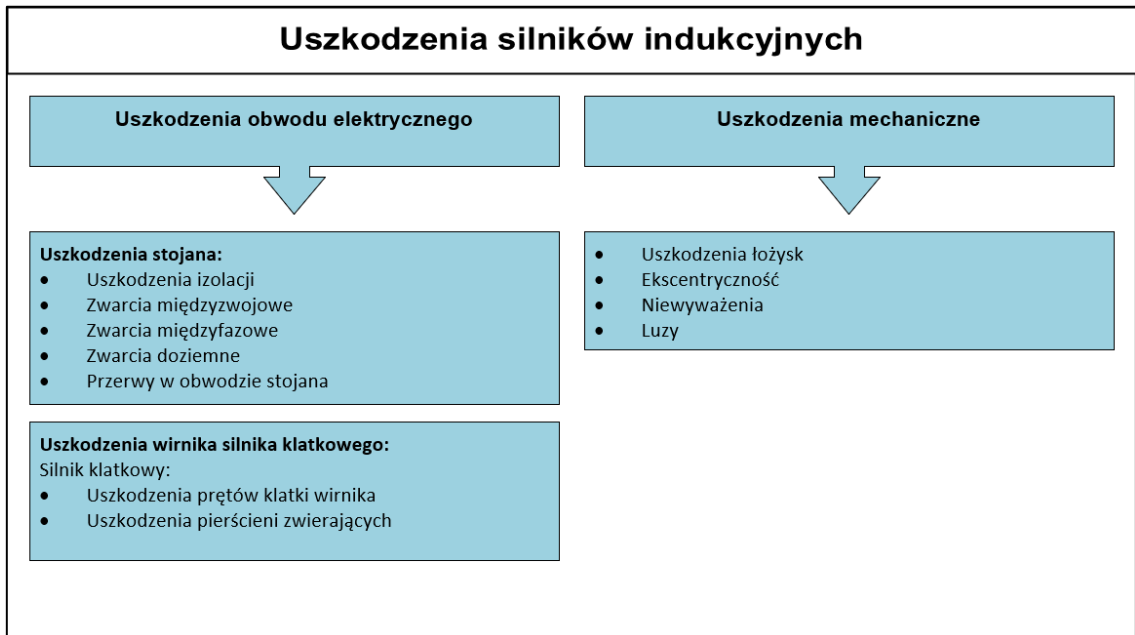
- uszkodzenia stojana,
- uszkodzenia wirnika [67–69],
- uszkodzenia łożysk [70].

Na rysunku 2.2 przedstawiono podział uszkodzeń silników indukcyjnych na podstawie badań prowadzonych przez *Electric Power Research Institute* (EPRI) [71, 72], w którym brane pod uwagę są zarówno silniki małej jak i dużej mocy, oraz przez *IEEE Industry Applications Society* (IAS) [36], gdzie analizowano jedynie silniki większej mocy.



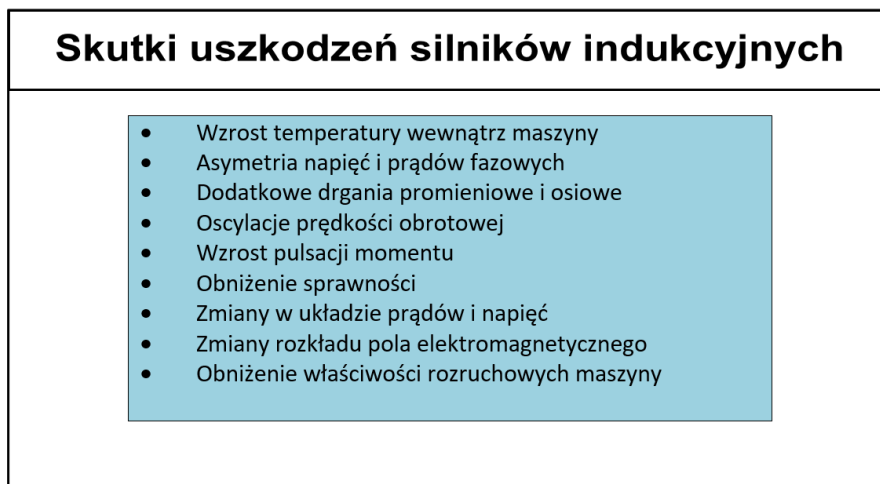
Rys. 2.2. Procentowy podział uszkodzeń poszczególnych elementów silników indukcyjnych
a) EPRI b) IAS

Szczegółowy podział uszkodzeń występujących w silnikach indukcyjnych przedstawiono na rysunku 2.3.



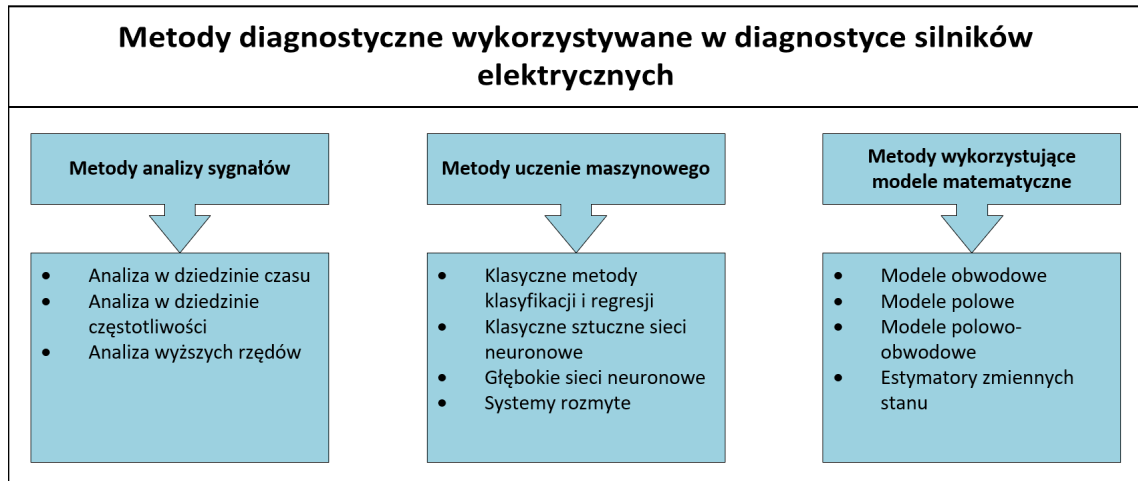
Rys. 2.3. Uszkodzenia silników indukcyjnych

Pojawienie się uszkodzenia, czyli stan awaryjny silnika indukcyjnego jest stanem niepożądanym, ponieważ może on wpływać negatywnie na właściwości eksploatacyjne układu. Stany awaryjne mogą objawiać się np. obniżeniem sprawności, pojawianiem się oscylacji prędkości lub momentu obrotowego, czy pogorszeniem właściwości rozruchowych maszyny, co w skrajnych przypadkach może doprowadzić do całkowitego zniszczenia maszyny. Dodatkowo stany awaryjne, mogą zagrażać życiu lub zdrowiu osób przebywających w pobliżu. Wybrane skutki uszkodzenia silników indukcyjnych przedstawiono na rysunku 2.4.



Rys. 2.4. Skutki uszkodzeń silników indukcyjnych

W celu zapewniania ciągłości pracy silników elektrycznych opracowywano wiele metod pozwalających na ich diagnostykę. Na rysunku 2.5 przedstawiono ogólny podział metod diagnostycznych wykorzystywanych w diagnostyce silników elektrycznych.



Rys. 2.5. Podział metod diagnostycznych silników elektrycznych

Jak pokazano na rysunku 2.5 metody analizy sygnałów diagnostycznych można podzielić na:

- analizę w dziedzinie czasu, gdzie w procesie diagnostycznym wykorzystywane są takie parametry sygnału jak:
 - wartość minimalna,
 - wartość maksymalna,
 - wartość chwilowa,
 - wartość skuteczna,
 - wartość średnia,
 - amplituda.

W przypadku analizy w dziedzinie czasu. powszechnie wykorzystywaną metodą jest metoda analizy wektora przestrzennego Parka (ang. *Park's Vector Approach, PVA*);

- analizę w dziedzinie częstotliwości wykorzystującej przekształcenie Fouriera. W przypadku analizy w dziedzinie częstotliwości najczęściej wykorzystywanymi metodami są:
 - analiza widmowa prądów fazowych (ang. *Motor Current Signature Analysis, MCSA*), która polega na analizie częstotliwościowej przebiegów prądu maszyny,

- analiza widma wektora przestrzennego (ang. *Extended Park Vector Approach, EPVA*), która polega na analizie częstotliwościowej wektora Parka;
- analizę wyższych rzędów, gdzie do popularniejszych metod zalicza się takie metody jak:
 - analiza falkowa (ang. *Wavelet Transform, WT*), która polega na dekompozycji sygnału w dziedzinie czas-częstotliwość,
 - krótkoczasowa transformata Fouriera, (ang. *Short-time Fourier transform, STFT*), polegająca na podziale sygnału na mniejsze fragmenty i zastosowaniu okien czasowych,
 - empiryczny rozkład sygnałów (ang. *Empirical Mode Decomposition, EMD*), polegająca na adaptacyjnej dekompozycji sygnału pierwotnego na funkcje składowe IMF (ang. *Intrinsic Mode Function*),
 - transformacja Hilberta-Huanga (ang. *Hilbert–Huang transform, HHT*), która jest rozszerzeniem metody EMD i umożliwia wyznaczenie wartości chwilowych częstotliwości i amplitud zdekomponowanych składowych sygnału,
 - zwielokrotniona klasyfikacja sygnałów (ang. *Multiple Signal Classification, MUSIC*), dokonująca estymacji widma sygnału z wykorzystaniem dekompozycji i operacji macierzowych.

Drugą wyszczególnioną na rysunku 2.5 grupą metod diagnostycznych wykorzystywanych w diagnostyce maszyn elektrycznych, są metody uczenia maszynowego. W przypadku metod uczenia maszynowego wyróżnia się:

- klasyczne metody klasyfikacji i regresji, do których zalicza się między innymi:
 - metoda drzew decyzyjnych, (ang. *Decision Tree, DT*), wykorzystuje ideę topologii drzewa, w której można wyróżnić takie elementy jak węzły, gałęzie oraz liście,
 - metoda maszyny wektorów nośnych (ang. *Support Vector Machine, SVM*), polega na koncepcji przestrzeni decyzyjnej, która ulega podziałowi, tym samym tworząc granicę pozwalającą na odseparowanie danych należnych do określonej klasy,

- metoda K najbliższych sąsiadów (ang. *k-nearest neighbors*, *k-NN*), polega na przewidywaniu wartości na podstawie k najbliższych obserwacji danych ze zbioru uczącego;
- klasyczne modele sztucznych sieci neuronowych do których zalicza się np.:
 - perceptron wielowarstwowy (ang. *Multilayer Perceptron*, *MLP*), sieci tego typu składają się z trzech rodzajów warstw: wejściowej, ukrytych i wyjściowej, oraz nie posiadają w swojej strukturze sprzężeń zwrotnych,
 - sieci samoorganizujące (ang. *Self-Organizing Map*, *SOM*), w swojej koncepcji wykorzystuje pojęcie sąsiedztwa oraz neuronu zwycięskiego,
 - sieci rekurencyjne (ang. *Recurrent Neural Network*, *RRN*), w strukturze tych sieci występuje sprzężenie zwrotne,
 - sieci radialne, (ang. *Radial Basis Functions*, *RBF*), w warstwie ukrytej wykorzystują neurony z radialną funkcją bazową.
 - sieci uogólnionej regresji (ang. *General Regression Neural Network*, *GRNN*), łączą ze sobą koncepcje sieci MLP i RBF;
- głębokie sieci neuronowe:
 - konwolucyjne sieci neuronowe (ang. *Convolutional neural network*, *CNN*), wykorzystują operację splotu do ekstrakcji cech z danych wejściowych,
 - krótkoczasowa pamięć długotrwała (ang. *Long short-term memory*, *LSTM*) to model rekurencyjny głębokich sieci neuronowych, który w swojej strukturze wykorzystuje trzy bramki: wejściową, wyjściową i zapominania,
 - Seq2Seq (ang. *Sequence 2 sequence*) - ideą sieci tego typu jest jednoczesne uczenie dwóch rekurencyjnych sieci, pierwsza nazywana jest enkoderem a druga dekoderelem,
 - autoenkodery (ang. *Autoencoder*, *AE*), jak w przypadku sieci Seq2Seq, autoenkodery również składają się z enkodera i dekodera; w przypadku AE, w zależności od zastosowania, najczęściej wyodrębnia się dwa typy autoenkoderów: niedopełnione i przepelnione,

- sieci głębokich przekonań (ang. *Deep belief network, DBF*) to sieci, w których podstawowym elementem składowym są połączone w warstwy ograniczone maszyny Boltzmanna,
- generatywne sieci przeciwstawne (ang. *Generative Adversarial Network, GAN*) to model wykorzystujący dwie sieci neuronowe, pierwsza pełni funkcję generatora natomiast druga dyskryminatora;
- systemy rozmyte:

to systemy wykorzystujące logikę rozmytą, w której pomiędzy wartością 0 (oznaczającą fałsz) i 1 (oznaczającą prawdę) określa się szereg wartości pośrednich określających stopień przynależności elementu do określonego zbioru. Logika rozmyta należy do kategorii logik wielowartościowych.

2.1 Klasyfikacja sygnałów diagnostycznych

W procesie diagnostycznym jednym z kluczowych elementów, oprócz samej metody, jest sygnał diagnostyczny wykorzystywany do przeprowadzenia diagnozy. Jako sygnał diagnostyczny można rozumieć zmiany dowolnej mierzalnej wielkości fizycznej w dziedzinie czasu. Na potrzeby opisu matematycznego, sygnały przedstawione są za pomocą funkcji, których argumentem jest czas. W najprostszym wariacie jest to funkcja jednej zmiennej, ale w praktyce najczęściej występują sygnały wielu zmiennych.

W literaturze opisane jest wiele kryteriów podziału sygnałów. Jednym z nich jest podział na sygnały stochastyczne oraz deterministyczne. Sygnałem stochastycznym nazywamy sygnał, który nie może być jednoznacznie opisany przez funkcję matematyczną, a jego wartości w każdej ustalonej chwili jest wartością przypadkową. Natomiast sygnałem deterministycznym określamy sygnał, który można w sposób jednoznaczny opisać przy pomocy funkcji matematycznej, przy czym funkcja ta nie może zawierać żadnych wielkości losowych. Dalszy podział sygnałów deterministycznych $x(t)$ określa sygnały jako sygnały okresowe oraz nieokresowe. Sygnał okresowy $x(t + T)$ to sygnał, który w każdej ustalonej chwili czasowej t spełnia równanie:

$$x(t + T) = x(t), \quad (2.1)$$

gdzie T to okres sygnału.

Natomiast sygnałem nieokresowym nazywamy każdy inny sygnał deterministyczny, który nie spełnia równania (2.1).

W ramach dalszego podziału sygnałów okresowych wyróżnić można sygnały harmoniczne oraz sygnały poliharmoniczne.

Sygnałem harmonicznym nazywany jest sygnał okresowy, który w dziedzinie liczb rzeczywistych dla ustalonej chwili czasu t może być opisany wzorem:

$$x(t) = A \cos(\omega_0 t + \varphi_0), \quad (2.2)$$

gdzie: A to amplituda sygnału, $\omega_0 = 2\pi f_0$ to pulsacja, przy czym f_0 to częstotliwość sygnału, a φ_0 to przesunięcie fazowe sygnału.

Natomiast w dziedzinie liczb zespolonych sygnał $x(t)$ może być określony w następujący sposób:

$$x(t) = A e^{j2\pi f_0 t + \varphi_0}, \quad (2.3)$$

Sygnałem poliharmonicznym nazywany jest sygnał, który jest kombinacją liniową co najmniej dwóch sygnałów harmonicznymi o różnych pulsacjach, nazywanych sygnałami składowymi. Sygnał poliharmoniczny składający się z dwóch sygnałów harmonicznymi określić można następująco:

$$x(t) = A_0 \cos(\omega_0 t + \varphi_0) + A_1 \cos(\omega_1 t + \varphi_1), \quad (2.4)$$

przy czym częstotliwość każdego sygnału składowego musi być całkowitą wielokrotnością częstotliwości podstawowej.

Dodatkowo, sygnały okresowe można opisać za pomocą takich parametrów jak:

- wartość średnia,
- wartość skuteczna,
- współczynnik kształtu,
- współczynnik szczytu,
- współczynnik zawartości harmonicznymi (THD).

Oprócz przedstawionego powyżej podziału sygnałów na sygnały stochastyczne i deterministyczne, sygnały mogą być także grupowane ze względu na ciągłość ich dziedziny. Na przykład w dziedzinie czasu wyróżnia się sygnały ciągłe oraz sygnały dyskretne.

O sygnałach ciągłych mówi się wówczas kiedy są one określone w ciągłym zbiorze argumentów. Najczęściej spotykane dziedziny sygnałów ciągłych to $(-\infty, \infty)$, ale może ona być również określona w przedziale zamkniętym. Natomiast sygnały dyskretne są określone tylko w skończonym zbiorze punktów należących do ich dziedziny.

Do akwizycji i archiwizacji sygnałów na potrzeby diagnostyki maszyn elektrycznych wykorzystuje się głównie skomputeryzowane układy pomiarowe wyposażone w cyfrowe karty pomiarowe. Dlatego można stwierdzić, że sygnały dyskretne są najczęściej wykorzystywane do diagnostyki maszyn.

Wraz z postępem technologicznym w wielu dziedzinach życia pojawiła się potrzeba archiwizacji, obserwacji i analizy sygnałów do celów diagnostycznych. W diagnostyce maszyn elektrycznych, z uwagi na znane algorytmy przetwarzania, oraz względną bezproblemowość przy przetwarzaniu sygnałów, najczęściej wykorzystywanym rodzajem sygnałów są sygnały elektryczne.

2.2 Wybrane metody przetwarzania sygnału

Informacje zwarte w przebiegach sygnałów rejestrowanych na potrzeby diagnostyczne mogą być trudne do interpretacji, co utrudnia, a niekiedy uniemożliwia poprawną diagnostykę badanej maszyny. Dlatego też, w celu poprawy jakości przeprowadzanego procesu diagnostycznego wykorzystuje się różne metody przetwarzania sygnału. Metody te w dużym stopniu zależą od rodzaju sygnału diagnostycznego. Aktualnie jednymi z popularniejszych metod przetwarzania sygnałów wykorzystywanych w diagnostyce silników elektrycznych jest przekształcenie Fouriera (ang. *Fourier Transform, FT*) oraz przekształcenie falkowe (ang. *Wavelet Transform, WT*).

Przekształcenie Fouriera zyskało popularność w diagnostyce silników indukcyjnych ze względu na przystępność interpretacji wyników analizy. Pomimo tego, że przekształcenie Fouriera można stosować zarówno dla funkcji ciągłych, jak i dyskretnych, to w zastosowaniach inżynierskich, z uwagi na charakter sygnałów diagnostycznych, częściej wykorzystywana jest Dyskretna Transformata Fouriera (ang. *Discrete Fourier Transform, DFT*), którą można określić wzorem:

$$X(m) = \sum_{n=0}^{N-1} x(n) \cos 2\pi \frac{n \cdot m}{N} - j \sum_{n=0}^{N-1} x(n) \sin 2\pi \frac{n \cdot m}{N}, \quad (2.5)$$

gdzie: $X(m)$ to wynik DFT w dziedzinie częstotliwości, $x(n)$ to analizowany sygnał dyskretny w dziedzinie czasu, n to numer przetwarzanej próbki, m to rząd harmoniczej, N to liczba próbek analizowanego sygnału dyskretnego.

W praktyce, w celu przyspieszenia obliczeń DFT, wykorzystywany jest algorytm obliczeniowy nazywany Szybka Transformata Fouriera (ang. *Fast Fourier Transform, FFT*). Klasyczne przekształcenie Fouriera wymaga, aby sygnał poddawany przekształceniu był sygnałem stacjonarnym. W celu przetwarzania sygnałów niestacjonarnych stosowana jest Krótkoczasowa Transformata Fouriera (ang. *Short-Time Fourier Transform, STFT*), która umożliwia czasowo-częstotliwościową analizę sygnału diagnostycznego. Zastosowanie STFT umożliwia obserwację zmian pasma częstotliwości sygnału w funkcji czasu, co pozwala na diagnostykę silników w zmiennych warunkach pracy.

Drugą wspomnianą metodą przetwarzania sygnału diagnostycznego jest przekształcenie falkowe (WT). Przekształcenie falkowe z powodzeniem stosowane jest dla sygnałów niestacjonarnych. W zależności od potrzeby przekształcenie WT może być zastosowane na sygnałach ciągłych lub dyskretnych. W przypadku sygnałów ciągłych w czasie stosowaną metodą jest ciągłe przekształcenie falkowe (ang. *Continuous Wavelet Transform, CWT*), natomiast dla sygnałów dyskretnych stosuje się dyskretne przekształcenie falkowe (ang. *Discreet Wavelet Transform, DWT*). W praktyce przekształcenie falkowe często wykorzystywane jest do filtracji sygnału diagnostycznego. W odróżnieniu od metody STFT, w której stosowane jest stałe okno czasowe, w metodzie DWT rozmiar okna czasowego jest funkcją położenia okna w płaszczyźnie t/f. W kontekście analizy sygnałów płaszczyznę t/f można zdefiniować jako dwuwymiarową reprezentację sygnału, która łączy informacje w dziedzinie czasu i dziedzinie częstotliwości. Z uwagi na tę zależność okno czasowe może ulec zmianie, w wyniku czego możliwe jest otrzymanie dokładniejszej charakterystyki czasowo-częstotliwościowej.

2.3 Pozyskiwanie sygnału diagnostycznego

W diagnostyce maszyn elektrycznych istnieją różne sposoby pomiaru i rejestracji prądów fazowych. Wyniki ich analizy pozwalają na monitorowanie stanu technicznego oraz wykrycie ewentualnych awarii. W zależności od potrzeb, do tych celów można wykorzystać zarówno cęgi pomiarowe, klasyczne amperomierze, jak również bardziej zaawansowane układy wykorzystujące karty pomiarowe w technologiach takich jak np. CompactRIO, CompactDAQ czy PXI.

Wykorzystanie cęgów pomiarowych, z uwagi na sposób pomiaru, preferowane jest do pomiaru prądów o dużej wartości. Dzięki swojej budowie zastosowanie cęgów nie wymaga bezpośredniej ingerencji w układ pomiarowy, co zwiększa bezpieczeństwo i wygodę podczas wykonywania pomiarów.

Z kolei podłączenie analogowych amperomierzy wymaga ingerencji w obwód zasilania, przez co może wiązać się z wyłączeniem układu napędowego. Zastosowanie amperomierzy analogowych uniemożliwia komputerową akwizycję danych pomiarowych. Natomiast amperomierze cyfrowe często posiadają niewystarczającą częstotliwość próbkowania sygnału oraz przystosowane są do pomiaru prądu o częstotliwości sieci zasilającej silnik przez co mogą posiadać filtry, które usuwają z sygnału diagnostycznego składowe o wyższych częstotliwościach, co może uniemożliwić zastosowanie bardziej zaawansowanych metod diagnostycznych.

Wykorzystanie kart pomiarowych podobnie jak w przypadku amperomierzy analogowych czy cyfrowych, wymaga ingerencji w obwód zasilania badanego silnika. Niemniej z uwagi na zastosowane technologie, pozwala to na pozyskanie przebiegu sygnału diagnostycznego z uwzględnieniem wyższych częstotliwości występujących w sygnale, a w konsekwencji pozyskany sygnał można z powodzeniem wykorzystać w dalszym procesie diagnostycznym. Dlatego też, karty pomiarowe są bardzo często wykorzystywane tam, gdzie niezbędna jest jak najbardziej dokładna analiza sygnału diagnostycznego. Oprócz sygnału prądowego karty pomiarowe umożliwiają również rejestracje przebiegów takich wielkości fizycznych jak np. napięcie zasilania, wibracje i dźwięk. Do pomiaru wibracji i dźwięku wykorzystywane są dodatkowo czujniki drgań oraz czujniki dźwięku. W przypadku pomiaru drgań lub dźwięku należy pamiętać o ewentualnych zakłóceniach sygnału pomiarowego przez sygnały docierające do układu pomiarowego z zewnątrz.

Jednym z najbardziej rozpowszechnionych sposobów na pozyskiwanie sygnału diagnostycznego do celów badawczych są pomiary wykonywane na obiekcie rzeczywistym. Rozwiązanie to zapewnia wiarygodne wyniki pomiarów ale wiąże się z koniecznością przeprowadzania długotrwałych i problematycznych badań oraz wymaga dostępu do obiektów badanych. Pozyskiwanie odpowiednio dużej i zróżnicowanej puli sygnałów diagnostycznych z obiektu rzeczywistego w proponowanej przez autora metodzie wykorzystującej głębokie sieci neuronowe może być zadaniem trudnym do realizacji.

Z tego powodu w zrealizowanych badaniach zastosowano sygnał diagnostyczny pozyskany z wyników obliczeń symulacyjnych polowo-obwodowego modelu silnika indukcyjnego klatkowego. Podejście to pozwoli na pozyskanie sygnału diagnostycznego bez konieczności przeprowadzania czasochłonnych pomiarów na wielu obiektach rzeczywistych. Ponadto, wykorzystanie modelu polowego uwzględniającego uszkodzenia może umożliwić pozyskiwanie sygnału diagnostycznego już na etapie prototypowania silników, co w znacznym stopniu może poprawić jakość procesu diagnostycznego poprzez wczesną i nieinwazyjną metodę generacji danych wejściowych dla sztucznej sieci neuronowej.

W rozdziale drugim przedstawione zostały informacje na temat diagnostyki silników indukcyjnych. Opisane zostały uszkodzenia silników, klasyfikacja sygnałów diagnostycznych, wybrane metody przetwarzania sygnałów, a także metody pozyskiwania sygnału diagnostycznego. W rozdziale trzecim w nawiązaniu do omówionych w rozdziale drugim zagadnień ze szczególnym uwzględnieniem metod pozyskiwania sygnału diagnostycznego zaprezentowane będą modele matematyczne silników indukcyjnych. Przedstawione w kolejnym rozdziale opisy matematyczne silników indukcyjnych w dalszej części pracy zostaną wykorzystane do przygotowania modeli polowych silników indukcyjnych, które umożliwią akwizycję sygnału diagnostycznego na potrzeby diagnostyki uzwojenia stojana maszyny indukcyjnej.

3 Modele matematyczne silników indukcyjnych

3.1 Wprowadzenie

Zadaniem silników elektrycznych jest przetwarzanie energii elektrycznej na energię mechaniczną za pośrednictwem pola elektromagnetycznego. Powszechnie są stosowane nie tylko w szeroko rozumianym przemyśle, gdzie wchodzi w skład elektrycznego układu napędowego wielu specjalistycznych maszyn takich jak np. pompy, wyciągarki, wentylatory, maszyny CNC czy urządzenia medyczne, ale stosowane są również w urządzeniach użytku codziennego takich jak sprzęty AGD, elektronarzędzia a nawet zabawki. Należy również wspomnieć, że w ostatnich latach ich zastosowanie zyskuje jeszcze bardziej na znaczeniu z uwagi na dynamiczny rozwój gałęzi przemysłu związaną z elektromobilnością, gdzie silniki elektryczne służą jako napęd dla wielu pojazdów elektrycznych [73]. Z przeprowadzonych analiz szacunkowych wynika, że to właśnie silniki elektryczne są odpowiedzialne za zużywanie blisko 50% światowej energii elektrycznej [74], a biorąc pod uwagę dynamiczny rozwój rynku związanego z samochodami elektrycznymi trend ten może w przyszłości wzrastać. Dlatego też, badania dotyczące silników elektrycznych pełnią kluczową rolę w dalszym rozwoju technologicznym. Analiza stanów pracy silników elektrycznych może obejmować wiele różnych aspektów, np. analiza pod względem ich sprawności, stanów pracy, niezawodności czy optymalizacji konstrukcji. W badaniach nad silnikami elektrycznymi, na otrzymane wyniki może wpływać wiele czynników, w tym między innymi zastosowany model matematyczny. Zastosowanie modeli matematycznych silników pozwala na przeprowadzenie obliczeń symulacyjnych i analizy w wybranych stanach pracy maszyny. Ponadto, dokładne modele matematyczne są niezbędne podczas projektowania nowych konstrukcji silników, opracowywania strategii ich optymalizacji oraz zwiększania niezawodności układu napędowego. Dlatego też, badania wykorzystujące modele matematyczne stanowią fundament dla dalszego rozwoju technologii silników elektrycznych, wspierając innowacje i postęp w różnych gałęziach przemysłu takich jak np. motoryzacja, energetyka czy automatyka.

3.2 Opis modelu silnika indukcyjnego o parametrach skupionych

Aktualnie jednym z modeli matematycznych wykorzystywanych do opisu zjawisk zachodzących w silniku indukcyjnym jest model wykorzystujący układ współrzędnych naturalnych. Niemniej istnieją inne modele matematyczne i wykorzystywane są one w zależności od rozpatrywanej problematyki [75–77].

Model w układzie współrzędnych naturalnych obwodu stojana oraz obwodu wirnika silnika indukcyjnego w postaci wektorowej można zapisać następującym układem równań.

$$\begin{cases} \mathbf{U}^S = \mathbf{i}^S \mathbf{R}^S + \mathbf{L}^{SS} \frac{d}{dt}(\mathbf{i}^S) + \frac{d}{dt}(\mathbf{L}'^{SR} \mathbf{i}'^S) \\ \mathbf{U}'^R = \mathbf{i}'^R \mathbf{R}'^R + \mathbf{L}'^{RR} \frac{d}{dt}(\mathbf{i}'^R) + \frac{d}{dt}(\mathbf{L}'^{SR^T} \mathbf{i}'^R) \end{cases} \quad (3.1)$$

gdzie \mathbf{U}^S to wektor napięć uzwojenia stojana, \mathbf{U}'^R to wektor napięć uzwojenia wirnika sprowadzonych na stronę stojana, \mathbf{i}^S to wektor prądów stojana, \mathbf{i}'^R to wektor prądów wirnika sprowadzonych na stronę stojana, \mathbf{R}^S to macierz rezystancji uzwojenia stojana, \mathbf{R}'^R to macierz rezystancji uzwojenia wirnika sprowadzona na stronę stojana, \mathbf{L}^{SS} to macierz indukcyjności uzwojenia stojana, \mathbf{L}'^{SR} to macierz indukcyjności między stojanem a wirnikiem sprowadzonych na stronę stojana, natomiast \mathbf{L}'^{RR} to macierz indukcyjności wirnika sprowadzonej na stronę stojana.

Wektory występujące w układzie równań (3.1) można zapisać w następujący sposób:

$$\mathbf{U}^S = \begin{bmatrix} U_A^S \\ U_B^S \\ U_C^S \end{bmatrix}, \quad \mathbf{U}'^R = \begin{bmatrix} U_A'^R \\ U_B'^R \\ U_C'^R \end{bmatrix}, \quad \mathbf{i}^S = \begin{bmatrix} i_A^S \\ i_B^S \\ i_C^S \end{bmatrix}, \quad \mathbf{i}'^R = \begin{bmatrix} i_A'^R \\ i_B'^R \\ i_C'^R \end{bmatrix}. \quad (3.2)$$

Do dalszej analizy niezbędne jest sprowadzenie napięć i prądów fazowych uzwojenia wirnika, opisanych zależnością (3.2), na stronę stojana zgodnie z następującymi wzorami:

$$U'^R = U^R \frac{z_1 k_{q1}}{z_2 k_{q2}}, \quad (3.3)$$

$$i'^R = i^R \frac{z_2 k_{q2} m_2}{z_1 k_{q1} m_1}, \quad (3.4)$$

gdzie: U_A^S, U_B^S, U_C^S to napięcia fazowe uzwojenia stojana, $U_A'^R, U_B'^R, U_C'^R$ to napięcia fazowe uzwojenia wirnika sprowadzone na stronę stojana, i_A^S, i_B^S, i_C^S to prądy fazowe uzwojenia

stojana, i_A^R, i_B^R, i_C^R to prądy fazowe uzwojenia wirnika sprowadzone na stronę stojana, z_1, z_2 to odpowiednio liczba zwojów uzwojenia stojana i wirnika, k_{q1}, k_{q2} to współczynniki uzwojenia stojana i wirnika, a m_1, m_2 to odpowiednio liczba faz stojana i wirnika silnika indukcyjnego.

Macierze rezystancji uzwojenia stojana \mathbf{R}^S oraz rezystancji uzwojenia wirnika sprowadzonej na stronę stojana \mathbf{R}^R można zapisać w następujący sposób:

$$\mathbf{R}^S = \begin{bmatrix} R_A^S & 0 & 0 \\ 0 & R_B^S & 0 \\ 0 & 0 & R_C^S \end{bmatrix}, \quad (3.5)$$

$$\mathbf{R}^R = \begin{bmatrix} R_A^R & 0 & 0 \\ 0 & R_B^R & 0 \\ 0 & 0 & R_C^R \end{bmatrix}, \quad (3.6)$$

gdzie: R_A^S, R_B^S, R_C^S to odpowiednio rezystancja fazy A, B i C uzwojenia stojana, R_A^R, R_B^R, R_C^R to odpowiednio rezystancje fazy A, B i C uzwojenia wirnika sprowadzone na stronę stojana.

Macierze indukcyjności uzwojenia stojana \mathbf{L}^{SS} , indukcyjności wirnika sprowadzonej na stronę stojana \mathbf{L}^{RR} oraz indukcyjności między stojanem a wirnikiem sprowadzonych na stronę stojana \mathbf{L}^{SR} można zapisać następująco:

$$\mathbf{L}^{SS} = \mathbf{L}_\alpha^S + \mathbf{L}_\beta^S, \quad (3.7)$$

$$\mathbf{L}^{RR} = \mathbf{L}_\alpha^R + \mathbf{L}_\beta^R, \quad (3.8)$$

$$\mathbf{L}^{SR} = \begin{bmatrix} M_A^{SR} \cos(p\theta) & M_A^{SR} \cos(p\theta + 2\pi/3) & M_A^{SR} \cos(p\theta - 2\pi/3) \\ M_B^{SR} \cos(p\theta - 2\pi/3) & M_B^{SR} \cos(p\theta) & M_B^{SR} \cos(p\theta + 2\pi/3) \\ M_C^{SR} \cos(p\theta + 2\pi/3) & M_C^{SR} \cos(p\theta - 2\pi/3) & M_C^{SR} \cos(p\theta) \end{bmatrix}, \quad (3.9)$$

przy czym: \mathbf{L}_α^S to macierz indukcyjności rozproszenia uzwojenia stojana, \mathbf{L}_β^S to macierz indukcyjności własnej uzwojenia stojana, \mathbf{L}_α^R to macierz indukcyjności rozproszenia uzwojenia wirnika sprowadzonej na stronę stojana, \mathbf{L}_β^R to macierz indukcyjności własnej uzwojenia wirnika sprowadzonej na stronę stojana, $M_A^{SR}, M_B^{SR}, M_C^{SR}$ to

indukcyjność wzajemna między fazą A , B i C uzwojenia stojana a uzwojeniem wirnika, sprowadzona na stronę stojana, p to liczba par biegunów, a θ to kąt położenia wirnika względem stojana. Macierze L_{α}^S , L_{β}^S będące składnikami (3.7) oraz L_{α}^{R} , L_{β}^{R} będące składnikami równania (3.8) można przedstawić w następujący sposób:

$$L_{\alpha}^S = \begin{bmatrix} L_{A\alpha}^S & 0 & 0 \\ 0 & L_{B\alpha}^S & 0 \\ 0 & 0 & L_{C\alpha}^S \end{bmatrix}, \quad (3.10)$$

$$L_{\beta}^S = \begin{bmatrix} L_{A\beta}^S & M_{AB\beta}^S & M_{AC\beta}^S \\ M_{AB\beta}^S & L_{B\beta}^S & M_{BC\beta}^S \\ M_{AC\beta}^S & M_{BC\beta}^S & L_{C\beta}^S \end{bmatrix}, \quad (3.11)$$

$$L_{\alpha}^{R} = \begin{bmatrix} L_{A\alpha}^{R} & 0 & 0 \\ 0 & L_{B\alpha}^{R} & 0 \\ 0 & 0 & L_{C\alpha}^{R} \end{bmatrix}, \quad (3.12)$$

$$L_{\beta}^{R} = \begin{bmatrix} L_{A\beta}^{R} & M_{AB\beta}^{R} & M_{AC\beta}^{R} \\ M_{AB\beta}^{R} & L_{B\beta}^{R} & M_{BC\beta}^{R} \\ M_{AC\beta}^{R} & M_{BC\beta}^{R} & L_{C\beta}^{R} \end{bmatrix}, \quad (3.13)$$

gdzie: $L_{A\alpha}^S$, $L_{B\alpha}^S$, $L_{C\alpha}^S$ to indukcyjność rozproszenia fazy A , B i C uzwojenia stojana, $L_{A\beta}^S$, $L_{B\beta}^S$, $L_{C\beta}^S$ to indukcyjność własna fazy A , B i C uzwojenia stojana, $M_{AB\beta}^S$ to indukcyjność wzajemna między fazą A uzwojenia stojana a fazą B uzwojenia stojana, $M_{AC\beta}^S$ to indukcyjność wzajemna między fazą A uzwojenia stojana a fazą C uzwojenia stojana, $M_{BC\beta}^S$ to indukcyjność wzajemna między fazą B uzwojenia stojana a fazą C uzwojenia stojana, $L_{A\alpha}^{R}$, $L_{B\alpha}^{R}$, $L_{C\alpha}^{R}$ to indukcyjność rozproszenia fazy A , B i C uzwojenia wirnika sprowadzona na stronę stojana, $L_{A\beta}^{R}$, $L_{B\beta}^{R}$, $L_{C\beta}^{R}$ to indukcyjność własna fazy A , B i C uzwojenia wirnika sprowadzona na stronę stojana, $M_{AB\beta}^{R}$ to indukcyjność wzajemna między fazą A uzwojenia wirnika a fazą B uzwojenia wirnika sprowadzona na stronę stojana, $M_{AC\beta}^{R}$ to indukcyjność wzajemna między fazą A uzwojenia wirnika a fazą C uzwojenia wirnika sprowadzona na stronę stojana, $M_{BC\beta}^{R}$ to indukcyjność wzajemna między fazą B uzwojenia wirnika a fazą C uzwojenia wirnika sprowadzona na stronę stojana.

Sprowadzenie rezystancji uzwojenia wirnika na stronę stojana można zrealizować zgodnie ze wzorem:

$$R'^R = R^R \left(\frac{z_1 k_{q1}}{z_2 k_{q2}} \right)^2 \frac{m_1}{m_2}, \quad (3.14)$$

gdzie: R^R to rezystancja uzwojenia wirnika widziana od strony wirnika.

Rezystancja uzwojenia wirnika ze wzoru (3.14) może być wyrażona jako suma rezystancji prętów wirnika i rezystancji pierścieni zwierających:

$$R_A^R = R_B^R = R_C^R = R^R = \frac{1}{p} (R_{bar}^R + R_{ring}^R), \quad (3.15)$$

gdzie: R_{bar}^R to rezystancja prętów wirnika, a R_{ring}^R to rezystancja pierścieni zwierających wirnika.

Sprowadzenie indukcyjności uzwojenia wirnika na stronę stojana można zrealizować z wykorzystaniem następujących zależności:

$$L'^R = L^R \left(\frac{z_1 k_{q1}}{z_2 k_{q2}} \right)^2 \frac{m_1}{m_2}, \quad (3.16)$$

$$M'^R = M^R \left(\frac{z_1 k_{q1}}{z_2 k_{q2}} \right)^2 \frac{m_1}{m_2}. \quad (3.17)$$

Napięcia fazowe stojana oraz napięcia fazowe wirnika sprowadzone na stronę stojana z układu równań (3.1), po uwzględnieniu zapisu macierzowego można przedstawić w następujący sposób:

$$\begin{aligned}
 & \begin{bmatrix} U_A^S \\ U_B^S \\ U_C^S \end{bmatrix} \\
 &= \begin{bmatrix} R_A^S & 0 & 0 \\ 0 & R_B^S & 0 \\ 0 & 0 & R_C^S \end{bmatrix} \begin{bmatrix} i_A^S \\ i_B^S \\ i_C^S \end{bmatrix} \\
 &+ \frac{d}{dt} \left(\begin{bmatrix} L_{A\alpha}^S & 0 & 0 \\ 0 & L_{B\alpha}^S & 0 \\ 0 & 0 & L_{C\alpha}^S \end{bmatrix} \right. \\
 &+ \left. \begin{bmatrix} L_{A\beta}^S & M_{AB} \cos(2\pi/3) & M_{AC} \cos(-2\pi/3) \\ M_{AB} \cos(-2\pi/3) & L_{B\beta}^S & M_{BC} \cos(2\pi/3) \\ M_{AC} \cos(2\pi/3) & M_{BC} \cos(-2\pi/3) & L_{C\beta}^S \end{bmatrix} \right) \begin{bmatrix} i_A^S \\ i_B^S \\ i_C^S \end{bmatrix} \\
 &+ \frac{d}{dt} \left(\begin{bmatrix} M_A^{SR} \cos(p\theta) & M_A^{SR} \cos(p\theta + 2\pi/3) & M_A^{SR} \cos(p\theta - 2\pi/3) \\ M_B^{SR} \cos(p\theta - 2\pi/3) & M_B^{SR} \cos(p\theta) & M_B^{SR} \cos(p\theta + 2\pi/3) \\ M_C^{SR} \cos(p\theta + 2\pi/3) & M_C^{SR} \cos(p\theta - 2\pi/3) & M_C^{SR} \cos(p\theta) \end{bmatrix} \right) \begin{bmatrix} i_A^S \\ i_B^S \\ i_C^S \end{bmatrix},
 \end{aligned} \tag{3.18}$$

$$\begin{aligned}
 & \begin{bmatrix} 0 \\ 0 \\ 0 \end{bmatrix} \\
 &= \begin{bmatrix} R_A^{R'} & 0 & 0 \\ 0 & R_B^{R'} & 0 \\ 0 & 0 & R_C^{R'} \end{bmatrix} \begin{bmatrix} i_A^{R'} \\ i_B^{R'} \\ i_C^{R'} \end{bmatrix} \\
 &+ \frac{d}{dt} \left(\begin{bmatrix} L_{A\alpha}^{R'} & 0 & 0 \\ 0 & L_{B\alpha}^{R'} & 0 \\ 0 & 0 & L_{C\alpha}^{R'} \end{bmatrix} \right. \\
 &+ \left. \begin{bmatrix} L_{A\beta}^{R'} & M_{AB}^{R'} \cos(2\pi/3) & M_{AC}^{R'} \cos(-2\pi/3) \\ M_{AB}^{R'} \cos(-2\pi/3) & L_{B\beta}^{R'} & M_{BC}^{R'} \cos(2\pi/3) \\ M_{AC}^{R'} \cos(2\pi/3) & M_{BC}^{R'} \cos(-2\pi/3) & L_{C\beta}^{R'} \end{bmatrix} \right) \begin{bmatrix} i_A^{R'} \\ i_B^{R'} \\ i_C^{R'} \end{bmatrix} \\
 &+ \frac{d}{dt} \left(\begin{bmatrix} M_A^{SR} \cos(p\theta) & M_A^{SR} \cos(p\theta - 2\pi/3) & M_A^{SR} \cos(p\theta + 2\pi/3) \\ M_B^{SR} \cos(p\theta + 2\pi/3) & M_B^{SR} \cos(p\theta) & M_B^{SR} \cos(p\theta - 2\pi/3) \\ M_C^{SR} \cos(p\theta - 2\pi/3) & M_C^{SR} \cos(p\theta + 2\pi/3) & M_C^{SR} \cos(p\theta) \end{bmatrix} \right) \begin{bmatrix} i_A^{R'} \\ i_B^{R'} \\ i_C^{R'} \end{bmatrix}.
 \end{aligned} \tag{3.19}$$

W analizie stanów pracy silników indukcyjnych klatkowych, układ równań opisujący obwód stojana oraz obwód wirnika należy uzupełnić równaniem równowagi mechanicznej:

$$J \frac{d\omega}{dt} = T_e - T_L, \quad (3.20)$$

gdzie: J to moment bezwładności mas wirujących, ω to prędkość kątowna wirnika, $T_e = [\mathbf{i}^S]^T \frac{\partial L^{SR}}{\partial \theta} \mathbf{i}'^R$ to moment elektromagnetyczny, a T_L to moment obciążenia maszyny. Moment elektromagnetyczny T_e wyznacza się na podstawie wielkości polowych [78].

Równanie (3.20) po uwzględnieniu zapisu macierzowego przyjmuje postać:

$$J \frac{d\omega}{dt} = \begin{bmatrix} i_A^S & i_B^S & i_C^S \end{bmatrix} \frac{d}{d\theta} \begin{bmatrix} M_A^{SR} \cos(p\theta) & M_A^{SR} \cos\left(p\theta + \frac{2\pi}{3}\right) & M_A^{SR} \cos\left(p\theta - \frac{2\pi}{3}\right) \\ M_B^{SR} \cos\left(p\theta - \frac{2\pi}{3}\right) & M_B^{SR} \cos(p\theta) & M_B^{SR} \cos\left(p\theta + \frac{2\pi}{3}\right) \\ M_C^{SR} \cos\left(p\theta + \frac{2\pi}{3}\right) & M_C^{SR} \cos\left(p\theta - \frac{2\pi}{3}\right) & M_C^{SR} \cos(p\theta) \end{bmatrix} \begin{bmatrix} i_A'^R \\ i_B'^R \\ i_C'^R \end{bmatrix} - T_L. \quad (3.21)$$

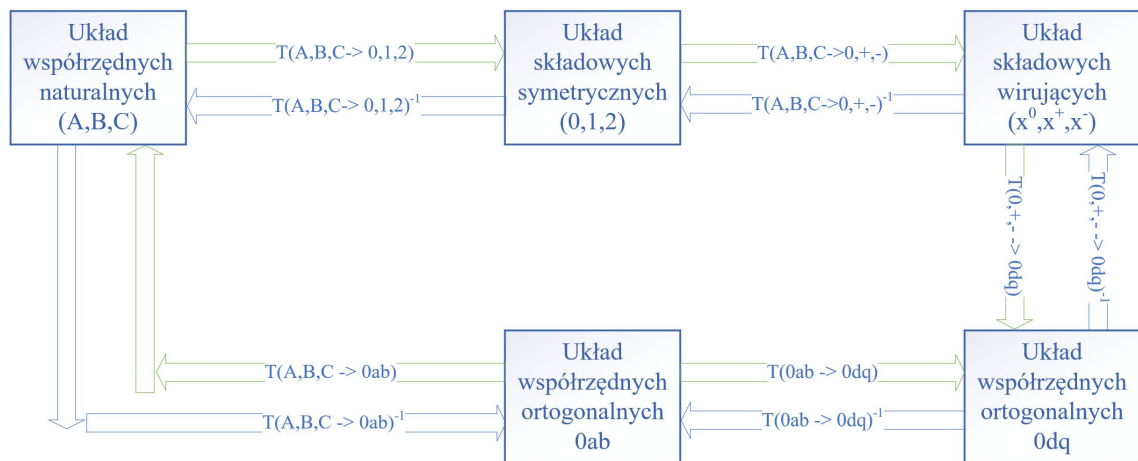
Badania i analiza stanów pracy silników indukcyjnych z zastosowaniem modelu w naturalnym układzie współrzędnych nie zawsze jest podejściem optymalnym. Jednym z takich przypadków może być badanie nad zastosowaniem algorytmów w sterowaniu układu napędowego. W publikacjach poświęconych tematyce sterowania trójfazowymi silnikami elektrycznymi przedstawia się podejście dążące do uproszczenia modelu, gdyż w samej analizie nie jest wymagana szczegółowa informacja o prądach maszyny w każdej z faz uzwojenia. W przypadku układów sterowania, do uproszczenia analizy wykorzystywana jest transformata Clarke i Parka, która pozwala na analizę stanu pracy na podstawie prądu w osiach d oraz q maszyny. W zagadnieniach sterowania trójfazowymi silnikami elektrycznymi zastosowanie modelu w naturalnym układzie współrzędnych jest możliwe, ale takie podejście może utrudnić analizę. Utrudnienia te wynikają z występujących w tym modelu elementów nieliniowych. Ponadto, w modelu w naturalnym układzie współrzędnych występują współczynniki zależne od kąta θ informującego o położeniu wirnika względem stojana,

który dodatkowo jest funkcją czasu. Co więcej, opis układu dynamiki w tym modelu wymaga rozwiązania ośmiu równań różniczkowych. W wielu zastosowaniach nie jest wymagane użycie tak złożonego modelu, dlatego też dążono do jego uproszczenia. W literaturze można wyróżnić modele matematyczne opracowane w innych niż naturalny układach, np.:

- model w układzie składowych symetrycznych 0, 1, 2,
- model w układzie składowych wirujących,
- model w układzie składowych ortogonalnych 0ab,
- model w układzie składowych ortogonalnych 0dq [79, 80].

Przekształcenie modelu z układu naturalnego do jednego z wymienionych powyżej układów, ma na celu uproszczenie zapisu matematycznego wykorzystywanego do opisu maszyny. Przejście z układu składowych naturalnych do układu o składowych ortogonalnych 0ab, przy założeniu symetrii zasilania, umożliwia eliminację równań dla składowych zerowych przez co układ równań upraszcza się do pięciu równań. Z kolei zastosowanie modelu w układzie 0dq pozwala na wprowadzenie współczynników niezależnych od czasu.

Diagram opisujący przekształcenia między modelami matematycznymi opisującymi silnik indukcyjny przedstawiono na rysunku 3.1.



Rys. 3.1. Diagram przekształceń modeli matematycznych opisujących silnik indukcyjny [79]

Współrzędne x_0 , x_1 , x_2 występujące w układzie składowych symetrycznych oraz współrzędne x_0^+ , x_0^- występujące w układzie składowych wirujących, są określone w dziedzinie liczb zespolonych. Zależności między współczynnikami można zapisać w następujący sposób:

$$x^2 = (x^1)^*, \quad (3.22)$$

$$x^- = (x^+)^*, \quad (3.23)$$

gdzie * oznacza sprzężenie zespolone [79].

W celu przekształcenia modeli matematycznych silników indukcyjnych pomiędzy wymienionymi na rysunku 3.1 układami współrzędnych należy wykorzystać macierze transformacji opisane następującymi wzorami:

- macierze transformacji umożliwiające przekształcenie modelu w układzie współrzędnych naturalnych do oraz z modelu w układzie składowych symetrycznych:

$$T_{A,B,C \rightarrow 0,1,2} = \frac{1}{\sqrt{3}} \begin{bmatrix} 1 & 1 & 1 \\ 1 & e^{j120} & e^{j240} \\ 1 & e^{j240} & e^{j120} \end{bmatrix}, \quad (3.24)$$

$$T_{A,B,C \rightarrow 0,1,2}^{-1} = \frac{1}{\sqrt{3}} \begin{bmatrix} 1 & 1 & 1 \\ 1 & e^{j240} & e^{j120} \\ 1 & e^{j120} & e^{j240} \end{bmatrix}, \quad (3.25)$$

- macierze transformacji umożliwiające przekształcenie modelu w układzie składowych symetrycznych do oraz z modelu w układzie składowych wirujących:

$$T_{0,1,2 \rightarrow 0,+,-} = \begin{bmatrix} 1 & 0 & 0 \\ 0 & e^{jp\theta} & 0 \\ 0 & 0 & e^{-jp\theta} \end{bmatrix}, \quad (3.26)$$

$$T_{0,1,2 \rightarrow 0,+,-}^{-1} = \begin{bmatrix} 1 & 0 & 0 \\ 0 & e^{-jp\theta} & 0 \\ 0 & 0 & e^{jp\theta} \end{bmatrix}, \quad (3.27)$$

gdzie θ to kąt położenia wirnika względem stojana.

Przekształcenie modelu w układzie składowych symetrycznych do modelu w układzie składowych wirujących wymaga przekształcenia jedynie wielkości związanych z wirnikiem.

- macierze transformacji umożliwiające przekształcenie modelu w układzie współrzędnych naturalnych do oraz z modelu w układzie składowych ortogonalnych 0ab:

$$T_{A,B,C \rightarrow 0ab} = \sqrt{\frac{2}{3}} \begin{bmatrix} \frac{1}{\sqrt{2}} & \frac{1}{\sqrt{2}} & \frac{1}{\sqrt{2}} \\ 1 & -\frac{1}{2} & -\frac{1}{2} \\ 0 & \frac{\sqrt{3}}{2} & -\frac{\sqrt{3}}{2} \end{bmatrix}, \quad (3.28)$$

$$T_{A,B,C \rightarrow 0ab}^{-1} = \sqrt{\frac{2}{3}} \begin{bmatrix} \frac{1}{\sqrt{2}} & 1 & 0 \\ \frac{1}{\sqrt{2}} & -\frac{1}{2} & \frac{\sqrt{3}}{2} \\ \frac{1}{\sqrt{2}} & -\frac{1}{2} & -\frac{\sqrt{3}}{2} \end{bmatrix}, \quad (3.29)$$

- macierze transformacji umożliwiające przekształcenie modelu w układzie składowych ortogonalnych 0ab do oraz z modelu w układzie składowych ortogonalnych 0dq :

$$T_{0ab \rightarrow 0dq} = \begin{bmatrix} 1 & 0 & 0 \\ 0 & \cos(\gamma) & \sin(\gamma) \\ 0 & -\sin(\gamma) & \cos(\gamma) \end{bmatrix}, \quad (3.30)$$

$$T_{0ab \rightarrow 0dq}^{-1} = \begin{bmatrix} 1 & 0 & 0 \\ 0 & \cos(\gamma) & -\sin(\gamma) \\ 0 & \sin(\gamma) & \cos(\gamma) \end{bmatrix}, \quad (3.31)$$

gdzie w przypadku stojana $\gamma = \omega t$, natomiast w przypadku wirnika $\gamma = \omega t - p\theta$;

- macierze transformacji umożliwiające przekształcenie modelu w układzie współrzędnych symetryczny do oraz z modelu w układzie składowych ortogonalnych 0ab a także modelu o układzie składowych wirujących do oraz z modelu w układzie składowych ortogonalnych 0dq:

$$T_{0,1,2 \rightarrow 0ab} = T_{0,+,- \rightarrow 0dq} = \frac{1}{\sqrt{2}} \begin{bmatrix} \sqrt{2} & 0 & 0 \\ 0 & 1 & 1 \\ 0 & j & -j \end{bmatrix}, \quad (3.32)$$

$$T_{0,1,2 \rightarrow 0ab}^{-1} = T_{0,+,- \rightarrow 0dq}^{-1} = \frac{1}{\sqrt{2}} \begin{bmatrix} \sqrt{2} & 0 & 0 \\ 0 & 1 & -j \\ 0 & 1 & j \end{bmatrix}. \quad (3.33)$$

Przykładowe przekształcenie modelu w układzie składowych naturalnych do układu składowych ortogonalnych 0dq przedstawiono w (3.34) oraz (3.35). Model

obwodu stojana oraz wirnika silnika indukcyjnego w układzie składowych ortogonalnych $0dq$ przyjmuje postać:

$$\begin{aligned}
 \begin{bmatrix} U_0^S \\ U_d^S \\ U_q^S \end{bmatrix} &= \begin{bmatrix} R_A^S & 0 & 0 \\ 0 & R_B^S & 0 \\ 0 & 0 & R_C^S \end{bmatrix} \begin{bmatrix} i_0^S \\ i_d^S \\ i_q^S \end{bmatrix} \\
 &+ \omega \left(\begin{bmatrix} L_{A\alpha}^S & 0 & 0 \\ 0 & L_{B\alpha}^S & 0 \\ 0 & 0 & L_{C\alpha}^S \end{bmatrix} + \frac{3}{2} \begin{bmatrix} L_{A\beta}^S & M_{AB\beta} \cos(2\pi/3) & M_{AC\beta} \cos(-2\pi/3) \\ M_{AB\beta} \cos(-2\pi/3) & L_{B\beta}^S & M_{BC\beta} \cos(2\pi/3) \\ M_{AC\beta} \cos(2\pi/3) & M_{BC\beta} \cos(-2\pi/3) & L_{C\beta}^S \end{bmatrix} \right) \begin{bmatrix} 0 & 0 & 0 \\ 0 & 0 & -1 \\ 0 & 1 & 0 \end{bmatrix} \begin{bmatrix} i_0^S \\ i_d^S \\ i_q^S \end{bmatrix} \\
 &+ \left(\begin{bmatrix} L_{A\alpha}^S & 0 & 0 \\ 0 & L_{B\alpha}^S & 0 \\ 0 & 0 & L_{C\alpha}^S \end{bmatrix} + \frac{3}{2} \begin{bmatrix} L_{A\beta}^S & M_{AB\beta} \cos(2\pi/3) & M_{AC\beta} \cos(-2\pi/3) \\ M_{AB\beta} \cos(-2\pi/3) & L_{B\beta}^S & M_{BC\beta} \cos(2\pi/3) \\ M_{AC\beta} \cos(2\pi/3) & M_{BC\beta} \cos(-2\pi/3) & L_{C\beta}^S \end{bmatrix} \right) \begin{bmatrix} 0 & 0 & 0 \\ 0 & 1 & 0 \\ 0 & 0 & 1 \end{bmatrix} \frac{d}{dt} \begin{bmatrix} i_0^S \\ i_d^S \\ i_q^S \end{bmatrix} \\
 &+ \frac{3}{2} \omega \begin{bmatrix} M_A'^{SR} \cos(p\theta) & M_A'^{SR} \cos(p\theta + 2\pi/3) & M_A'^{SR} \cos(p\theta - 2\pi/3) \\ M_B'^{SR} \cos(p\theta - 2\pi/3) & M_B'^{SR} \cos(p\theta) & M_B'^{SR} \cos(p\theta + 2\pi/3) \\ M_C'^{SR} \cos(p\theta + 2\pi/3) & M_C'^{SR} \cos(p\theta - 2\pi/3) & M_C'^{SR} \cos(p\theta) \end{bmatrix} \begin{bmatrix} 0 & 0 & 0 \\ 0 & 0 & -1 \\ 0 & 1 & 0 \end{bmatrix} \begin{bmatrix} i_0^R \\ i_d^R \\ i_q^R \end{bmatrix} \\
 &+ \frac{3}{2} \begin{bmatrix} M_A'^{SR} \cos(p\theta) & M_A'^{SR} \cos(p\theta + 2\pi/3) & M_A'^{SR} \cos(p\theta - 2\pi/3) \\ M_B'^{SR} \cos(p\theta - 2\pi/3) & M_B'^{SR} \cos(p\theta) & M_B'^{SR} \cos(p\theta + 2\pi/3) \\ M_C'^{SR} \cos(p\theta + 2\pi/3) & M_C'^{SR} \cos(p\theta - 2\pi/3) & M_C'^{SR} \cos(p\theta) \end{bmatrix} \begin{bmatrix} 0 & 0 & 0 \\ 0 & 1 & 0 \\ 0 & 0 & 1 \end{bmatrix} \frac{d}{dt} \begin{bmatrix} i_0^R \\ i_d^R \\ i_q^R \end{bmatrix}, \quad (3.34)
 \end{aligned}$$

$$\begin{aligned}
 \begin{bmatrix} 0 \\ 0 \\ 0 \end{bmatrix} &= \begin{bmatrix} R'_A & 0 & 0 \\ 0 & R'_B & 0 \\ 0 & 0 & R'_C \end{bmatrix} \begin{bmatrix} i'_0 \\ i'_d \\ i'_q \end{bmatrix} \\
 &+ \left(\omega - \frac{d\theta}{dt} \right) \left(\begin{bmatrix} L'_{A\alpha} & 0 & 0 \\ 0 & L'_{B\alpha} & 0 \\ 0 & 0 & L'_{C\alpha} \end{bmatrix} + \frac{3}{2} \begin{bmatrix} L'_{A\beta} & M'_{AB} \cos(2\pi/3) & M'_{AC} \cos(-2\pi/3) \\ M'_{AB} \cos(-2\pi/3) & L'_{B\beta} & M'_{BC} \cos(2\pi/3) \\ M'_{AC} \cos(2\pi/3) & M'_{BC} \cos(-2\pi/3) & L'_{C\beta} \end{bmatrix} \right) \begin{bmatrix} 0 & 0 & 0 \\ 0 & 0 & -1 \\ 0 & 1 & 0 \end{bmatrix} \begin{bmatrix} i'_0 \\ i'_d \\ i'_q \end{bmatrix} \\
 &+ \left(\begin{bmatrix} L'_{A\alpha} & 0 & 0 \\ 0 & L'_{B\alpha} & 0 \\ 0 & 0 & L'_{C\alpha} \end{bmatrix} + \frac{3}{2} \begin{bmatrix} L'_{A\beta} & M'_{AB} \cos(2\pi/3) & M'_{AC} \cos(-2\pi/3) \\ M'_{AB} \cos(-2\pi/3) & L'_{B\beta} & M'_{BC} \cos(2\pi/3) \\ M'_{AC} \cos(2\pi/3) & M'_{BC} \cos(-2\pi/3) & L'_{C\beta} \end{bmatrix} \right) \begin{bmatrix} 0 & 0 & 0 \\ 0 & 1 & 0 \\ 0 & 0 & 1 \end{bmatrix} \frac{d}{dt} \begin{bmatrix} i'_0 \\ i'_d \\ i'_q \end{bmatrix} \\
 &+ \frac{3}{2} \left(\omega - \frac{d\theta}{dt} \right) \begin{bmatrix} M'^{SR}_A \cos(p\theta) & M'^{SR}_A \cos(p\theta + 2\pi/3) & M'^{SR}_A \cos(p\theta - 2\pi/3) \\ M'^{SR}_B \cos(p\theta - 2\pi/3) & M'^{SR}_B \cos(p\theta) & M'^{SR}_B \cos(p\theta + 2\pi/3) \\ M'^{SR}_C \cos(p\theta + 2\pi/3) & M'^{SR}_C \cos(p\theta - 2\pi/3) & M'^{SR}_C \cos(p\theta) \end{bmatrix} \begin{bmatrix} 0 & 0 & 0 \\ 0 & 0 & -1 \\ 0 & 1 & 0 \end{bmatrix} \begin{bmatrix} i^S_0 \\ i^S_d \\ i^S_q \end{bmatrix} \\
 &+ \frac{3}{2} \begin{bmatrix} M'^{SR}_A \cos(p\theta) & M'^{SR}_A \cos(p\theta + 2\pi/3) & M'^{SR}_A \cos(p\theta - 2\pi/3) \\ M'^{SR}_B \cos(p\theta - 2\pi/3) & M'^{SR}_B \cos(p\theta) & M'^{SR}_B \cos(p\theta + 2\pi/3) \\ M'^{SR}_C \cos(p\theta + 2\pi/3) & M'^{SR}_C \cos(p\theta - 2\pi/3) & M'^{SR}_C \cos(p\theta) \end{bmatrix} \begin{bmatrix} 0 & 0 & 0 \\ 0 & 1 & 0 \\ 0 & 0 & 1 \end{bmatrix} \frac{d}{dt} \begin{bmatrix} i^S_0 \\ i^S_d \\ i^S_q \end{bmatrix}. \tag{3.35}
 \end{aligned}$$

Układ równań obwodu stojana i wirnika silnika należy uzupełnić równaniem równowagi ruchu, które dla modelu w układzie składowych ortogonalnych $0dq$ przyjmuje postać:

$$\frac{d\omega}{dt} = \frac{1}{J} \left(p * \frac{3}{2} \left(\begin{array}{ccc} M'_A{}^{SR} \cos(\theta) & M'_A{}^{SR} \cos\left(\theta + \frac{2\pi}{3}\right) & M'_A{}^{SR} \cos\left(\theta - \frac{2\pi}{3}\right) \\ M'_B{}^{SR} \cos\left(\theta - \frac{2\pi}{3}\right) & M'_B{}^{SR} \cos(\theta) & M'_B{}^{SR} \cos\left(\theta + \frac{2\pi}{3}\right) \\ M'_C{}^{SR} \cos\left(\theta + \frac{2\pi}{3}\right) & M'_C{}^{SR} \cos\left(\theta - \frac{2\pi}{3}\right) & M'_C{}^{SR} \cos(\theta) \end{array} \right) * \left(I_q^R * I_d^S - I_d^R * I_q^S \right) - T_L \right). \quad (3.36)$$

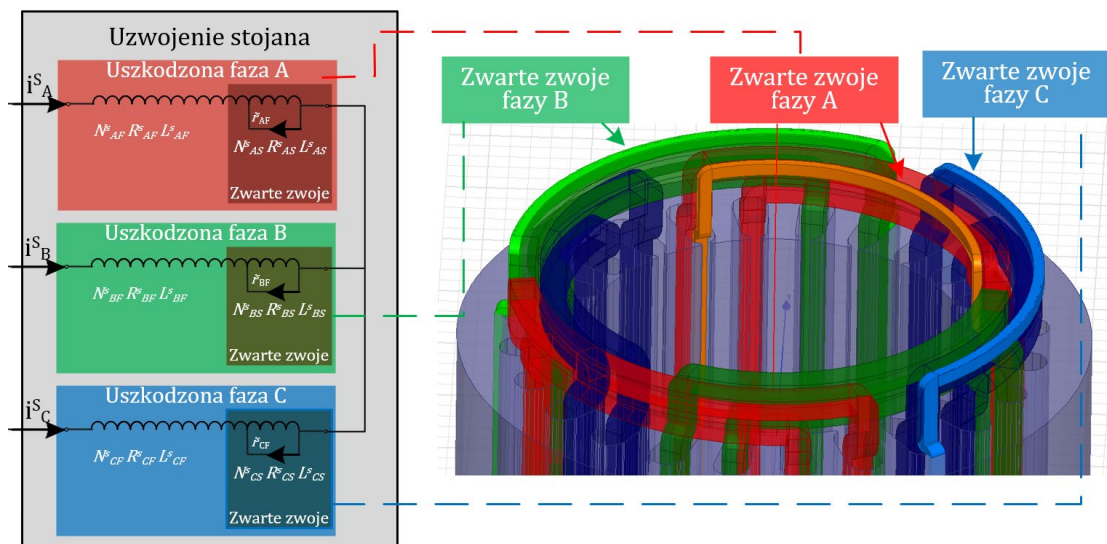
Jak już wspomniano analiza stanów pracy maszyny w układzie osi d oraz q jest powszechnie stosowana na przykład w zagadnieniach sterowania układów napędowych. Niemniej z uwagi na podejmowaną w rozprawie tematykę związaną z uszkodzeniami uzwojenia stojana zastosowanie modelu w układzie składowych ortogonalnych $0dq$ nie jest możliwe. Wynika to z faktu, iż w takim układzie niemożliwe jest uwzględnienie w równaniach elementów określających uszkodzenie obwodu stojana, ze względu na przyjętą przez autora pracy symetrię we wszystkich fazach analizowanego silnika. Dlatego też w dalszej części pracy, to właśnie model w naturalnym układzie współrzędnych stanowi podstawę do opracowania modeli polowych maszyny.

3.3 Opis matematyczny uzwojenia stojana z uwzględnieniem zwarcia międzyzwojowego

W poprzednim podrozdziale opisano model trójfazowego silnika indukcyjnego w układzie współrzędnych naturalnych. Przedstawiony model nie uwzględnia uszkodzeń w obwodzie stojana, takich jak np. zwarcia zwojowe. Z uwagi na tematykę podejmowaną w niniejszej rozprawie, przedstawiony w poprzednim podrozdziale model trójfazowego silnika indukcyjnego rozbudowano w taki sposób, aby umożliwił uwzględnienie zwarcie międzyzwojowych uzwojenia stojana. Dla uproszczenia i zachowania przejrzystości zapisu macierzowego, dalszy opis modelu silnika indukcyjnego w ujęciu obwodowym będzie uwzględniał zwarcia tylko jednej z faz stojana (fazy A). Ponadto, z uwagi na fakt, że autor rozpatruje przede wszystkim

uszkodzenie uzwojenia stojana, w dalszej części tego podrozdziału większy nacisk położono na równania odnoszące się do obwodu stojana. Uwzględnienie uszkodzeń w pozostałych fazach maszyny można zapisać analogicznie przy zachowaniu konsekwentnie odpowiednich oznaczeń.

Na rysunku 3.2 przedstawiono wizualizację zwarć zwojowych uzwojenia stojana z oznaczeniami symboli opisujących parametry uzwojeń A , B i C . Dla fazy A przyjęto, że liczba zwojów N , rezystancja R i indukcyjność L opisujące niezwarłe zwoje cewki uzwojenia stojana, które oznaczone odpowiednio jako: N_{AF}^S , R_{AF}^S , i L_{AF}^S . Indeks górny S oznacza obwód stojana, indeks dolny A oznacza rozpatrywaną fazę, a indeks dolny F niezwarłe zwoje cewki uzwojenia stojana. Natomiast parametry opisujące zwarte zwoje cewki uzwojenia stojana oznaczono jako: N_{AS}^S , R_{AS}^S , i L_{AS}^S , gdzie indeks górny S oznacza zwarte zwoje cewki uzwojenia stojana. Parametry opisujące zwarcie w fazach B i C - rysunek 3.2 - są opisane analogicznie jak dla fazy A .



Rys. 3.2. Graficzna reprezentacja zwarć w trzech fazach silnika indukcyjnego

Modelując uszkodzenie uzwojenia stojana maszyny indukcyjnej wywołane zwarcie międzyzwojowym, wprowadzono podział uzwojenia na tzw. część zwartą i niezwartą. Podział uzwojenia na te dwie części został odzwierciedlony przez wprowadzenie współczynnika opisującego stopień uszkodzenia uzwojenia maszyny. Współczynnik uszkodzenia uzwojenia stojana k_f może być zdefiniowany jako stosunek liczby zwartych zwojów uzwojenia stojana do znamionowej liczby zwojów uzwojenia fazowego stojana i można go opisać następującym wzorem:

$$k_f = \frac{N_S}{N_{ph}}, \quad (3.37)$$

gdzie: N_S to liczba zwartych zwojów fazy uzwojenia stojana, a N_{ph} to znamionowa liczba zwojów fazy uzwojenia stojana.

W przypadku silnika ze zwarcie międzyzwojowym w fazie A współczynnik uszkodzenia opisuje następujący wzór (3.38):

$$k_A^S = \frac{N_{AS}^S}{N_{AN}^S}, \quad (3.38)$$

gdzie: N_{AS}^S to liczba zwartych zwojów cewki fazy A uzwojenia stojana, a N_{AN}^S to znamionowa liczba zwojów fazy A uzwojenia stojana.

Wprowadzenie współczynnika uszkodzenia uzwojenia pozwala na obliczenie wartości rezystancji R_{AF}^S i indukcyjności L_{AF}^S niezwartych zwojów cewki fazy A uzwojenia stojana na podstawie ich wartości znamionowych. Wartość rezystancji i indukcyjności niezwartych zwojów cewki fazy A uzwojenia stojana można zapisać w następujący sposób:

$$\begin{aligned} R_{AF}^S &= (1 - k_A^S)R_A^S, \\ L_{AF}^S &= (1 - k_A^S)^2 L_A^S, \end{aligned} \quad (3.39)$$

gdzie: k_A^S to współczynnik uszkodzenia fazy A uzwojenia stojana, R_A^S to rezystancja znamionowa fazy A uzwojenia stojana, a L_A^S to indukcyjność znamionowa fazy A uzwojenia stojana.

Analogicznie wykorzystując współczynnik uszkodzenia fazy A uzwojenia stojana wartość rezystancji R_{AS}^S i indukcyjności L_{AS}^S zwartych zwojów cewki fazy A uzwojenia stojana w odniesieniu do ich wartości znamionowych można zapisać następująco:

$$\begin{aligned} R_{AS}^S &= (k_A^S)R_A^S, \\ L_{AS}^S &= (k_A^S)^2 L_A^S. \end{aligned} \quad (3.40)$$

Po sprowadzeniu parametrów schematu zastępczego wirnika na stronę stojana, układ równań napięciowych silnika klatkowego opisany jest zależnością (3.1). Natomiast wektory napięć i prądów można zapisać tak jak w przypadku silnika bez uwzględniania zwarć - zależność (3.2).

Jak wspomniano na wstępie niniejszego podrozdziału, w skutek wystąpienia zwarcia międzyzwojowe następuje podział uzwojenia stojana na dwie części. Takie podejście ma wpływ na parametry skupione maszyny. Parametry skupione silnika, takie jak rezystancja uzwojenia stojana oraz uzwojenia wirnika z uwzględnieniem zwarcie międzyzwojowych można przedstawić za pomocą następujących macierzy (3.41):

$$R^S = \begin{bmatrix} R_{AF}^S & -R_{AS}^S & 0 & 0 \\ -R_{AS}^S & R_{AS}^S & 0 & 0 \\ 0 & 0 & R_B^S & 0 \\ 0 & 0 & 0 & R_C^S \end{bmatrix}, R'^R = \begin{bmatrix} R'_A{}^R & 0 & 0 \\ 0 & R'_B{}^R & 0 \\ 0 & 0 & R'_C{}^R \end{bmatrix}, \quad (3.41)$$

gdzie: R_{AF}^S to rezystancja niezwartych zwojów cewki fazy A uzwojenia stojana, R_{AS}^S to rezystancja zwartych zwojów cewki fazy A uzwojenia stojana, R_B^S to rezystancja fazy B uzwojenia stojana, a R_C^S to rezystancja fazy C uzwojenia stojana, $R'_A{}^R$ to rezystancja fazy A uzwojenia wirnika sprowadzona na stronę stojana, $R'_B{}^R$ rezystancja fazy B uzwojenia wirnika sprowadzona na stronę stojana, a $R'_C{}^R$ to rezystancja fazy C uzwojenia wirnika sprowadzona na stronę stojana.

Macierze opisujące indukcyjności uzwojenia stojana oraz indukcyjności między stojanem a wirnikiem sprowadzonych na stronę stojana z uwzględnieniem zwarcia międzyzwojowego można przedstawić następująco:

$$L^{SS} = \begin{bmatrix} L_{AF\alpha}^S & 0 & 0 & 0 \\ 0 & L_{AS\alpha}^S & 0 & 0 \\ 0 & 0 & L_{B\alpha}^S & 0 \\ 0 & 0 & 0 & L_{C\alpha}^S \end{bmatrix} + \begin{bmatrix} L_{AF\beta}^S & -(L_{AS\beta}^S + M_{AFAS\beta}^S) & (M_{AFB\beta}^S + M_{ASB\beta}^S)\cos(2\pi/3) & (M_{AFC\beta}^S + M_{ASC\beta}^S)\cos(-2\pi/3) \\ -(L_{AS\beta}^S + M_{AFAS\beta}^S) & L_{AS\beta}^S & -M_{ASB\beta}^S\cos(2\pi/3) & -M_{ASC\beta}^S\cos(-2\pi/3) \\ M_{AFB\beta}^S\cos(-2\pi/3) & -M_{ASB\beta}^S\cos(-2\pi/3) & L_{B\beta}^S & M_{BC\beta}^S\cos(2\pi/3) \\ M_{AFC\beta}^S\cos(2\pi/3) & -M_{ASC\beta}^S\cos(2\pi/3) & M_{BC\beta}^S\cos(-2\pi/3) & L_{C\beta}^S \end{bmatrix}, \quad (3.42)$$

$$L'^{SR} = \begin{bmatrix} M_{AF}^{'SR}\cos(\theta) & M_{AF}^{'SR}\cos(\theta + 2\pi/3) & M_{AF}^{'SR}\cos(\theta - 2\pi/3) \\ -M_{AS}^{'SR}\cos(\theta + \gamma_{AS}) & -M_{AS}^{'SR}\cos(\theta + \gamma_{AS} + 2\pi/3) & -M_{AS}^{'SR}\cos(\theta + \gamma_{AS} - 2\pi/3) \\ M_B^{'SR}\cos(\theta - 2\pi/3) & M_B^{'SR}\cos(\theta) & M_B^{'SR}\cos(\theta + 2\pi/3) \\ M_C^{'SR}\cos(\theta + 2\pi/3) & M_C^{'SR}\cos(\theta - 2\pi/3) & M_C^{'SR}\cos(\theta) \end{bmatrix}, \quad (3.43)$$

gdzie: $L_{AF\alpha}^S$ to indukcyjność rozproszenia niezwartych zwojów cewki fazy A uzwojenia stojana, $L_{AS\alpha}^S$ to indukcyjność rozproszenia zwartych zwojów cewki fazy A uzwojenia stojana, $L_{B\alpha}^S$ to indukcyjność rozproszenia fazy B uzwojenia stojana, $L_{C\alpha}^S$ to indukcyjność rozproszenia fazy C uzwojenia stojana, $L_{AF\beta}^S$ to indukcyjność własna niezwartych zwojów cewki fazy A uzwojenia stojana, $L_{AS\beta}^S$ to indukcyjność własna

niezwartych zwojów cewki fazy B uzwojenia stojana, $L_{B\beta}^S$ to indukcyjność własna fazy B uzwojenia stojana, $L_{C\beta}^S$ to indukcyjność własna fazy C uzwojenia stojana, $M_{AFAS\beta}^S$ to indukcyjność wzajemna między niezwartymi zwojami cewki fazy A uzwojenia stojana, a zwartymi zwojami cewki fazy A uzwojenia stojana, $M_{AFB\beta}^S$ to indukcyjność wzajemna między niezwartymi zwojami cewki fazy A uzwojenia stojana a fazą B uzwojenia stojana, $M_{ASB\beta}^S$ to indukcyjność wzajemna między zwartymi zwojami cewki fazy A uzwojenia stojana a fazą B uzwojenia stojana, $M_{AFC\beta}^S$ to indukcyjność wzajemna między niezwartymi zwojami cewki fazy A uzwojenia stojana a fazą C uzwojenia stojana, $M_{ASC\beta}^S$ to indukcyjność wzajemna między zwartymi zwojami cewki fazy A uzwojenia stojana a fazą C uzwojenia stojana, $M_{BC\beta}^S$ to indukcyjność wzajemna między fazą B uzwojenia stojana a fazą C uzwojenia stojana, natomiast M'_{AF}^{SR} to indukcyjność wzajemna między niezwartymi zwojami cewki fazy A uzwojenia stojana a uzwojeniem wirnika sprowadzona na stronę stojana, M'_{AS}^{SR} to indukcyjność wzajemna między zwartymi zwojami cewki fazy A uzwojenia stojana a uzwojeniem wirnikiem sprowadzona na stronę stojana, $M'_B{}^{SR}$ to indukcyjność wzajemna między fazą B uzwojenia stojana a uzwojeniem wirnika sprowadzona na stronę stojana, $M'_C{}^{SR}$ to indukcyjność wzajemna między fazą C uzwojenia stojana a uzwojeniem wirnikiem sprowadzona na stronę stojana, θ to kąt opisujący położenie wirnika względem stojana, a γ to kąt pomiędzy zwartą cewką a cewkami uzwojenia stojana.

W przypadku modelu silnika z uwzględnieniem zwarć międzyzwojowych, tak samo jak w modelu bez uwzględnienia zwarć, równania napięciowe (3.1) należy uzupełnić równaniem równowagi mechanicznej (3.20).

Pomimo tego, że w modelu obwodowym silnika trójfazowego w naturalnym układzie współrzędnych można uwzględnić zwarcia międzyzwojowe, to jego dokładność może być niewystarczająca do wyznaczenia sygnału diagnostycznego. Dlatego, do obliczenia wartości indukcyjności uzwojeń silnika trójfazowego, korzystniej jest posłużyć się polowym modelem maszyny. W modelu polowym wartości indukcyjności są obliczane na podstawie rozkładu pola magnetycznego. Obliczenia realizowane są w dwóch krokach. W pierwszym kroku na podstawie rozkładu pola magnetycznego w maszynie obliczane są strumienie skojarzone z uzwojeniami fazowymi. W drugim kroku obliczane są indukcyjności uzwojenia na podstawie strumieni skojarzonych i prądów fazowych.

3.4 Opis matematyczny silnika indukcyjnego w ujęciu polowym

W związku z tym, że silniki elektryczne działają na zasadzie przetwarzania energii z wykorzystaniem pola elektromagnetycznego, zjawiska zachodzące w tych maszynach mają charakter polowy. Oprócz pola elektromagnetycznego w silniku elektrycznym występują inne rodzaje pól takich jak pole związane z naprężeniami mechanicznymi, temperaturą czy przepływem czynnika chłodzącego maszynę, które są zmienne w czasie. Dodatkową trudnością jest złożona budowa silnika oraz występowanie w maszynach elementów wprowadzających nieliniowość, co jeszcze bardziej komplikuje analizę zjawisk i utrudnia rozwiązanie zagadnień polowych w sposób analityczny. Aby dokonać analizy zjawisk w ujęciu polowym niezbędne jest zastosowanie metod umożliwiających dyskretyzację zarówno przestrzeni jak i czasu.

Z uwagi na charakter prezentowanej pracy, w pracy pominięto analizę pól związanych z temperaturą, naprężeniami mechanicznymi i przepływem czynnika chłodzącego. Natomiast uwagę skupiono na analizie zjawisk związanych z polem elektromagnetycznym oraz ruchem obrotowym wirnika maszyny. Aktualne rozwiązania służące do wyznaczania trójwymiarowych pól elektromagnetycznych zmiennych w czasie są złożone i wymagają dużego zapotrzebowania na moc obliczeniową, co przekłada się na długi czas obliczeń. Dlatego jedynie układy o prostej strukturze mogą być obliczane w relatywnie krótkim czasie. W przypadku bardziej złożonych struktur jakimi są silniki elektryczne, zastosowanie modeli trójwymiarowych wiąże się ze znacznie dłuższym czasem obliczeń i do tej pory niejednokrotnie wymagało specjalistycznych, a co za tym idzie drogich jednostek obliczeniowych. Mimo tego, że dynamiczny rozwój technologii mikroprocesorowej sprawia, że współczesne komputery osobiste posiadają moc obliczeniową umożliwiającą przeprowadzanie obliczeń trójwymiarowych pól elektromagnetycznych to tam, gdzie jest to możliwe dąży się do uproszczania zagadnień do dwuwymiarowych.

W prezentowanej w pracy maszynie jakim jest silnik elektryczny o strukturze walcowej przy założeniu równej długości elementów obwodu magnetycznego oraz pominięciu skosu żłobków, można założyć, że rozpatrywane wielkości polowe związane z elementami elektromagnetycznie czynnymi maszyny, nie są zależne od współrzędnej równoległej do osi silnika. Stosowanie układów w ujęciu trójwymiarowym ma na celu przede wszystkim uwzględnienie obszaru połączeń

czołowych silnika. W modelu dwuwymiarowym połączenia te są taktowane zerowymiarowo, czyli jako elementy skupione.

Dokładniejsze odwzorowanie obiektu rzeczywistego, zwłaszcza w stanach dynamicznych, wymaga zastosowania zaawansowanych metod modelowania maszyny. Zastosowanie do tego celu modeli obwodowych może nie zapewnić wymaganej dokładności. Wynika to z nieliniowych właściwości obwodu magnetycznego, jak również z występowania takich zjawisk jak np. prądy wirowe w układzie. W celu uzyskania większej dokładności analizy stanów pracy maszyny, wykorzystuje się modele polowe. W przypadku modeli polowych równania pola elektromagnetycznego wymagają uzupełnienia równaniami równowagi mechanicznej, równaniami opisującymi strukturę uzwojeń oraz równaniami opisującymi układ zasilania.

Złożoność obliczeniowa modelu silnika wynikająca ze wspomnianej nieliniowości, złożonej struktury oraz występujących w układzie elementów ruchomych uniemożliwia rozwiązanie powyższych równań w sposób analityczny. W związku z bardzo dużą złożonością obliczeniową do rozwiązywania równań polowego modelu silnika indukcyjnego, można stosować wspomniane wyżej metody numeryczne, umożliwiające dyskretyzację przestrzeni oraz czasu. Do popularniejszych metod rozwiązywania równań polowych zalicza się między innymi metodę różnic skończonych (MRS) [81–84], elementów brzegowych (MEB) [85–88] czy metodę elementów skończonych (MES) w ujęciu węzłowym, krawędziowym, ściankowym i objętościowym [89–101]. W pracy, do utworzenia modelu wykorzystano oprogramowanie Ansys Electronics Desktop, które bazuje na metodzie elementów skończonych [102].

Polowe modele silników elektrycznych z wykorzystaniem MES tworzone są na podstawie równań opisujących rozkład pola elektromagnetycznego. Podstawą do sformułowania równań opisujących rozkład pola elektromagnetycznego są wektory:

- E – wektor natężenia pola elektrycznego,
- H – wektor natężenia pola magnetycznego,
- B – wektor indukcji magnetycznej,
- J – wektor gęstości prądu.

Natomiast do analizy zagadnień związanych z polem elektromagnetycznym powszechnie używa się metod wykorzystujących potencjały elektryczne i magnetyczne:

- V – skalarny potencjał elektryczny,
- Ω – skalarny potencjał magnetyczny,

- \mathbf{T} – wektorowy potencjał elektryczny,
- \mathbf{A} – wektorowy potencjał magnetyczny.

Wprowadzenie potencjałów skalarnych V i Ω oraz wektorowych \mathbf{A} , \mathbf{T} pozwala na sformułowanie równań opisujących rozkłady pól elektrycznych i magnetycznych. Do sformułowania równań wykorzystuje się wspomniane wektory \mathbf{E} , \mathbf{H} , \mathbf{B} i \mathbf{J} oraz operatory rotacji (*rot*), dywergencji (*div*) oraz gradientu (*grad*), które umożliwiają sformułowanie fundamentalnych równań opisujących pole elektryczne i magnetyczne w postaci różniczkowej. Równania opisujące pola z wykorzystaniem potencjału skalarnego przedstawia tabela 3.1, natomiast równania związane z potencjałem wektorowym tabela 3.2.

Tabela 3.1 Równania pola elektrycznego i magnetycznego opisane z wykorzystaniem potencjału skalarnego

Równania dla pola elektrycznego	Równania dla pola magnetycznego
$rot\mathbf{E} = -\frac{\partial\mathbf{B}}{\partial t}$	$rot\mathbf{H} = \mathbf{J}$
$div\mathbf{J} = 0$	$div\mathbf{B} = 0$
$-\frac{\partial\mathbf{B}}{\partial t} = -rot\frac{\partial\mathbf{A}}{\partial t}$	$\mathbf{J} = rot\mathbf{T}$
$gradV = \mathbf{E} - \left(-\frac{\partial\mathbf{A}}{\partial t}\right)$	$grad\Omega = \mathbf{H} - \mathbf{T}$
$rotgradV = rot\left(\mathbf{E} - \left(-\frac{\partial\mathbf{A}}{\partial t}\right)\right) = 0$	$rotgrad\Omega = rot(\mathbf{H} - \mathbf{T}) = 0$
$\mathbf{J} = \left(\sigma + \frac{\partial}{\partial t}\varepsilon\right)\mathbf{E}$	$\mathbf{B} = \mu\mathbf{H}$
$\mathbf{J} = \left(\sigma + \frac{\partial}{\partial t}\varepsilon\right)gradV + \left(\sigma + \frac{\partial}{\partial t}\varepsilon\right)\left(-\frac{\partial\mathbf{A}}{\partial t}\right)$	$\mathbf{B} = \mu grad\Omega + \mu\mathbf{T}$
$div\left(\left(\sigma + \frac{\partial}{\partial t}\varepsilon\right)gradV\right) = div\left(\left(\sigma + \frac{\partial}{\partial t}\varepsilon\right)\frac{\partial\mathbf{A}}{\partial t}\right)$	$div(\mu grad\Omega) = -div(\mu\mathbf{T})$

Tabela 3.2 Równania pola elektrycznego i magnetycznego opisane z wykorzystaniem potencjału wektorowego

Równania dla pola elektrycznego	Równania dla pola magnetycznego
$rot\mathbf{E} = -\frac{\partial\mathbf{B}}{\partial t}$	$rot\mathbf{H} = \mathbf{J}$
$div\mathbf{J} = 0$	$div\mathbf{B} = 0$
$\mathbf{J} = rot\mathbf{T}$	$\mathbf{B} = rot\mathbf{A}$
$div\mathbf{J} = divrot\mathbf{T} = 0$	$div\mathbf{B} = divrot\mathbf{A} = 0$
$\mathbf{E} = \frac{1}{\left(\sigma + \frac{\partial\varepsilon}{\partial t}\right)}\mathbf{J}$	$\mathbf{H} = \frac{1}{\mu}\mathbf{B}$

$\mathbf{E} = \frac{1}{\left(\sigma + \frac{\partial \varepsilon}{\partial t}\right)} \text{rot} \mathbf{T}$	$\mathbf{H} = \frac{1}{\mu} \text{rot} \mathbf{A}$
$\text{rot} \left(\frac{1}{\left(\sigma + \frac{\partial \varepsilon}{\partial t}\right)} \text{rot} \mathbf{T} \right) = -\frac{\partial \mathbf{B}}{\partial t}$	$\text{rot} \left(\frac{1}{\mu} \text{rot} \mathbf{A} \right) = \mathbf{J}$

Jak wspomniano, silniki elektryczne działają na zasadzie przetwarzania energii z wykorzystaniem pól elektromagnetycznych, dlatego też do analizy takich układów pole elektryczne i magnetyczne należy traktować jako pola sprzężone. Aby umożliwić analizę sprzężonych pól elektrycznych i magnetycznych opracowano metody łączące ze sobą potencjały elektryczne i magnetyczne. Do popularnych metod wykorzystywanych w analizie pól elektromagnetycznych należą:

- metoda wykorzystująca wektorowy potencjał magnetyczny \mathbf{A} oraz skalarny potencjał elektryczny V nazywana metodą \mathbf{A} - V ,
- metoda wykorzystująca wektorowy potencjał magnetyczny \mathbf{A} oraz wektorowy potencjał elektryczny \mathbf{T} nazywana metodą \mathbf{A} - \mathbf{T} ,
- metoda wykorzystująca skalarny potencjał magnetyczny Ω oraz wektorowy potencjał elektryczny \mathbf{T} nazywana metodą Ω - \mathbf{T} .

W tabeli 3.3 przedstawiono równania opisujące rozkład pola elektromagnetycznego z wykorzystaniem przedstawionych powyżej metod. Z uwagi na to, że w pracy obiektem analizowanym jest silnik elektryczny zasilany źródłem napięcia o częstotliwości 50Hz, a w układzie nie występują wyższe częstotliwości oraz magnesy trwałe, to nie są rozpatrywane zagadnienia związane z prądami przesunięcia dielektrycznego oraz prądami magnetyzacji.

Tabela 3.3 Metody wykorzystywane w analizie pól elektromagnetycznych

Nazwa metody	Równania opisujące pole elektryczne	Równania opisujące pole magnetyczne	Zależności między wielkościami elektrycznymi i magnetycznymi
\mathbf{A} - V	$\text{div}(\sigma \text{grad} V) = \text{div} \left(\sigma \frac{\partial \mathbf{A}}{\partial t} \right)$	$\text{rot} \left(\frac{1}{\mu} \text{rot} \mathbf{A} \right) = \mathbf{J}$	$\mathbf{J} = \sigma \text{grad} V + \sigma \left(-\frac{\partial \mathbf{A}}{\partial t} \right)$
\mathbf{A} - \mathbf{T}	$\text{rot} \left(\frac{1}{\sigma} \text{rot} \mathbf{T} \right) = -\frac{\partial \mathbf{B}}{\partial t}$	$\text{rot} \left(\frac{1}{\mu} \text{rot} \mathbf{A} \right) = \mathbf{J}$	$\mathbf{J} = \text{rot} \mathbf{T}$ $\mathbf{B} = \text{rot} \mathbf{A}$
Ω - \mathbf{T}	$\text{rot} \left(\frac{1}{\sigma} \text{rot} \mathbf{T} \right) = -\frac{\partial \mathbf{B}}{\partial t}$	$\text{div}(\mu \text{grad} \Omega) = -\text{div}(\mu \mathbf{T})$	$\mathbf{B} = \mu \text{grad} \Omega + \mu \mathbf{T}$

Oprócz wymienionych powyżej potencjałów, niekiedy stosuje się również wektorowy potencjał elektryczny \mathbf{T}_0 . Wprowadzenie potencjału \mathbf{T}_0 umożliwia zastosowanie metod: $A-V-\mathbf{T}_0$, $\Omega-\mathbf{T}_0$, $\Omega-\mathbf{T}-\mathbf{T}_0$, $A-\mathbf{T}_0$ oraz $A-\mathbf{T}-\mathbf{T}_0$ [103, 104]. Podczas formułowania modelu polowo-obwodowego wykorzystano metodę $A-V$.

Wykorzystując do analizy zjawisk w silniku indukcyjnym klatkowym, charakteryzujących się niejednorodnością i nieliniowością środowiska, metodę z potencjałów $A-V$, uzyskuje się następujący układ równań:

$$\text{rot}\left(\frac{1}{\mu}\text{rot}\mathbf{A}\right) = \mathbf{J}, \quad (3.44)$$

$$\mathbf{J} = \sigma \text{grad}V + \sigma \left(-\frac{\partial \mathbf{A}}{\partial t}\right), \quad (3.45)$$

$$\text{div}\mathbf{J} = 0, \quad (3.46)$$

gdzie: μ to przenikalność magnetyczna środowiska, \mathbf{J} to wektor gęstości prądów przewodnictwa, σ to konduktywność elektryczna.

Proponowany model zjawisk elektromagnetycznych uwzględnia także nieliniowość materiałów magnetycznych miękkich:

$$\mathbf{B} = \mu \mathbf{H}, \quad (3.47)$$

W ujęciu 2D, równania (3.44) - (3.46) można opisać w prostszej formie. Wektorowy potencjał magnetyczny \mathbf{A} , gdzie $(\mathbf{B} = \text{rot}\mathbf{A})$, oraz wektor gęstości prądów przewodnictwa \mathbf{J} , mają tylko jedną składową, tj. $\mathbf{A} = \mathbf{1}_z A_z(x, y, t)$ i $\mathbf{J} = \mathbf{1}_z J_z(x, y, t)$. Ponadto, z równań (3.45) i (3.46) uzyskuje się prostsze rozwiązanie opisujące $\text{grad}V = \mathbf{1}_z \frac{\partial V}{\partial z}$, gdzie dla obszarów przewodzących $\frac{\partial V}{\partial z} \neq f(x, y, t)$. Z powyższego wynika, że w obszarze każdego pojedynczego przewodnika $\text{grad}V$ jest stały i jest funkcją czasu. Dlatego, wygodnie jest oddzielnie rozważać układy złożone z cienkich przewodników i układy z litymi przewodnikami, w których występują prądy wirowe. W cienkich przewodnikach zakłada się, że $J_z = \frac{i}{S_c}$, gdzie i jest prądem uzwojenia/cewki, tj. prądem w przewodniku, a S_c jest polem przekroju poprzecznego przewodnika. Jednak w układach z litymi przewodnikami, przyjmuje się $J_z = -\sigma\left(\frac{dA_z}{dt} + \frac{U}{l}\right)$, gdzie U jest napięciem na przewodniku o długości l w kierunku osi z . Zwykle napięcie U można określić na podstawie założenia, że całkowity prąd

w przewodnikach stałych jest równy zeru. Przy takim założeniu, ze względu na symetrię, często uzyskuje się $U = 0$.

Dodatkowo należy zaznaczyć, że podczas modelowania układów z polem elektromagnetycznym, w których występują prądy wirowe oraz elementy nieliniowe przy założeniu wymuszenia napięciowego, nie jest znany, występujący w równaniu Ampera, wektor gęstości prądu \mathbf{J} . Dlatego też, w modelu należy uwzględnić wspomniane w rozdziale 3.2 równania napięciowe (3.1), które w postaci ogólnej z uwzględnieniem układu zasilającego można zapisać następująco:

$$\mathbf{U} = \mathbf{iR} + \mathbf{L} \frac{d}{dt} \mathbf{i} + \frac{d}{dt} (\mathbf{L} \cdot \mathbf{i}), \quad (3.48)$$

gdzie \mathbf{U} to wektor napięć zasilających, \mathbf{i} to wektor prądów stojana, \mathbf{R} to macierz rezystancji uzwojenia stojana oraz układu zasilającego, \mathbf{L} to macierz indukcyjności uzwojenia stojana oraz układu zasilającego.

Przy czym wartości dla wektora prądu z równania (3.48) można wyznaczyć na podstawie wektora gęstości prądu, zdefiniowanego w obszarze uzwojenia.

$$i_k = \iint_{S_k} \mathbf{J} d\mathbf{S}, \quad (3.49)$$

gdzie S_k jest polem powierzchni przekroju k -tego przewodu uzwojenia trójfazowego silnika indukcyjnego. Wektor gęstości prądu występujący w równaniu (3.49), po uwzględnieniu zależności $\mathbf{J} = \sigma \mathbf{E}$, oraz zależności:

$$\mathbf{E} = \text{grad}V - \left(\frac{\partial \mathbf{A}}{\partial t} \right), \quad (3.50)$$

Wynikającej z przekształcenia jednego z równań z tabeli 3.1 można zapisać następująco:

$$\mathbf{J} = \sigma(\text{grad}V - \partial \mathbf{A} / \partial t). \quad (3.51)$$

Tak jak w przypadku modeli obwodowych, równania modelu polowego opisujące pole elektromagnetyczne oraz prądy w obwodach stojana, należy uzupełnić równaniem równowagi mechanicznej (3.20).

Model polowo-obwodowy obejmuje równania opisujące: pole elektromagnetyczne, równania obwodu systemu zasilania i równania ruchu. Rozwiązanie równań przedstawionych w podrozdziale 3.4, zależy od zaprezentowanych warunków brzegowych oraz przyjętych warunków początkowych. W praktyce, podczas analizy układów, w których występuje pole elektromagnetyczne zazwyczaj można skoncentrować się na analizie w ograniczonym obszarze. Warunkiem niezbędnym do przeprowadzenia takiej analizy jest znajomość wartości składowych stycznych i normalnych wektorów pola na powierzchni brzegowej rozpatrywanego obszaru. Znajomość wspomnianych wartości składowych stycznych i normalnych wektorów pola pozwala na sformułowanie warunków brzegowych dla wcześniej wspomnianych w tym rozdziale potencjałów. W przypadku pola elektromagnetycznego powszechnie znane, opisane w literaturze i stosowane są dwa warunki brzegowe. Pierwszy, znany jako warunek Dirichleta (lub warunek pierwszego rodzaju) oraz drugi, warunek Neumanna (warunek drugiego rodzaju). Warunek Dirichleta, zakłada, że na powierzchni brzegowej określony jest rozkład potencjału magnetycznego lub elektrycznego (tj. dla każdego punktu na powierzchni brzegowej, wartość potencjału magnetycznego lub elektrycznego jest ustalona). Warunek Neumanna zakłada, że na powierzchni brzegowej zadany jest rozkład pochodnej normalnej potencjału magnetycznego, bądź elektrycznego.

W rozdziale trzecim przedstawione zostały dwa podejścia do modelowania matematycznego silników indukcyjnych. Pierwsze, wykorzystujące parametry skupione oraz drugie, wykorzystujące potencjały skalarne oraz wektorowe. Jak wspomniano, przedstawione w tym rozdziale opisy matematyczne silników indukcyjnych, posłużyły do utworzenia modeli polowych silnika indukcyjnego. Opracowane modele polowe umożliwią pozyskanie sygnału diagnostycznego na potrzeby metody uczenia maszynowego. W rozdziale czwartym przedstawione zostaną wybrane metody uczenia maszynowego wykorzystywane w diagnostyce silników elektrycznych.

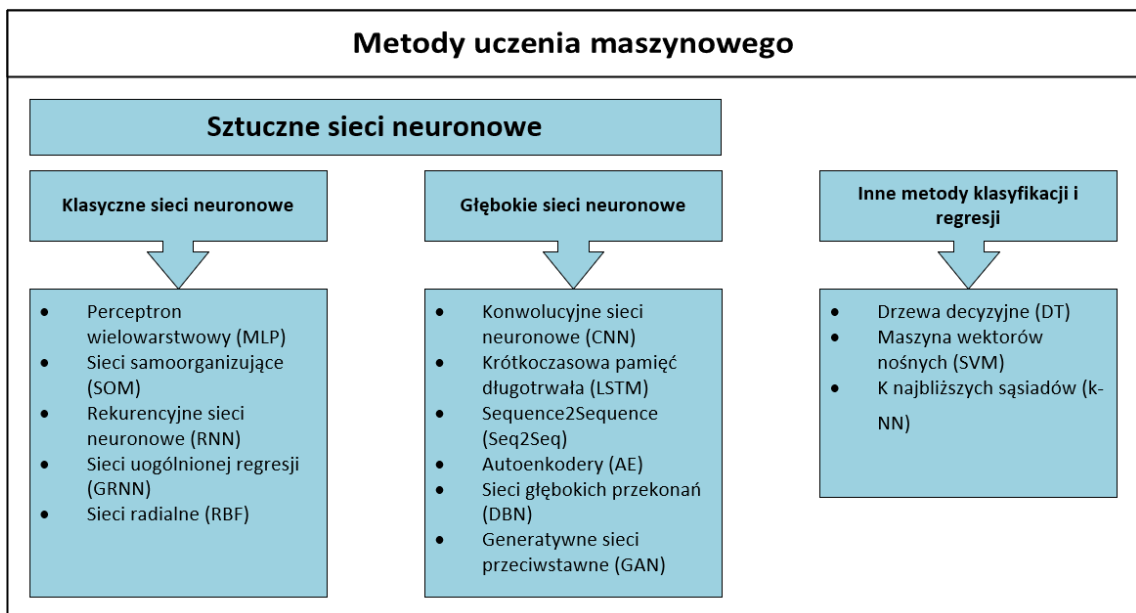
4 Metody uczenia maszynowego w diagnostyce silników elektrycznych

4.1 Wprowadzenie

W czasach, kiedy w diagnostyce maszyn elektrycznych nie wykorzystywano zaawansowanych technologicznie narzędzi pomiarowych, kluczową rolę odgrywał „ekspert”. To na podstawie jego wiedzy i doświadczenia podejmowane były decyzje, dotyczące stanu technicznego obiektu. Z uwagi na kluczową rolę czynnika ludzkiego, podejście to było obarczone wieloma ograniczeniami takimi jak wydłużony proces diagnostyczny czy ograniczone możliwości zrównoleglenia tego procesu. Aby w pewnym stopniu zautomatyzować proces diagnostyczny zaczęto stosować Systemy Eksperskie (ang. *Expert System, ES*). Jako system ekspercki należy rozumieć zbiór współpracujących ze sobą programów, które potrafią wykorzystać bazę wiedzy w celu wspomagania procesu podejmowania oceny stanu technicznego obiektu. Cechą charakterystyczną systemów eksperckich jest operowanie na wcześniej zgromadzonej wiedzy. Informacje potrzebne do zbudowania bazy wiedzy dla *ES* często pozyskiwane były od osoby eksperta w danej dziedzinie. Pomimo tego, że systemy eksperckie w pewnym stopniu umożliwiły automatyzację procesu diagnostycznego, to rola eksperta w tym procesie dalej jest kluczowa. Do zadań eksperta należy nie tylko zapewnienie rzetelnej wiedzy źródłowej na potrzeby utworzenia bazy wiedzy już na wczesnym etapie inżynierii oprogramowania, ale również optymalizacja systemu eksperckiego, jego weryfikacja, a także uzupełnianie bazy wiedzy już podczas eksploatacji danego systemu.

Dynamiczny rozwój techniki, a co za tym idzie ogólnoswiatowy trend do automatyzacji wielu procesów technologicznych sprawia, że jeszcze większy nacisk kładziony jest na niezawodność metod diagnostycznych maszyn elektrycznych. Proces automatyzacji przemysłu, a tym samym stale rosnąca liczba układów napędowych wykorzystujących silniki elektryczne, doprowadziła w konsekwencji do konieczności przetwarzania bardzo dużej ilości danych diagnostycznych na potrzeby diagnostyki silników indukcyjnych. Poskutkowało to rozwojem w dziedzinie przetwarzania sygnałów w zagadnieniach klasyfikacji. Z uwagi na wysoką skuteczność, obecnie popularną grupą metod diagnostycznych umożliwiającą klasyfikacje uszkodzeń w silnikach elektrycznych jest metoda wykorzystująca modele sztucznych sieci neuronowych. Metoda ta wykorzystuje zdolność sieci neuronowych do generalizacji, co

w znaczący sposób wpływa na automatyzację i skuteczność procesu diagnostycznego. Sztuczne sieci neuronowe wykorzystywane w diagnostyce silników elektrycznych można podzielić na dwie grupy. Pierwsza z nich wykorzystuje klasyczne struktury sieci, natomiast druga bazuje na sieciach wykorzystujących struktury głębokie. Metody diagnostyczne wykorzystujące sztuczne sieci neuronowe nie są jedynymi, które z powodzeniem można zastosować w procesie diagnostycznym. Do innych popularnych metod uczenia maszynowego wykorzystywanych w diagnostyce silników elektrycznych należą, między innymi: *Maszyny Wektorów Nośnych* [105–108], *Drzewa Decyzyjne* [39, 109–111], czy *Metoda k Najbliższych Sąsiadów* [112–114]. Podział popularnych metod uczenia maszynowego wykorzystywanych w zagadnieniach diagnostyki trójfazowych silników elektrycznych przedstawiono na rysunku 4.1.



Rys. 4.1. Wybrane metody uczenia maszynowego w diagnostyce trójfazowych silników elektrycznych

W dalszej części pracy, z uwagi na wcześniej wspomnianą dużą skuteczność w zagadnieniach diagnostyki maszyn elektrycznych, przedstawione zostaną zagadnienia związane z zastosowaniem wybranych modeli sztucznych sieci neuronowych.

4.2 Klasyczne struktury sztucznych sieci neuronowych

Od lat obserwowany jest wzrost zainteresowania sztucznymi sieciami neuronowymi. Już we wczesnych latach 90-tych XX wieku, dostrzeżono trendy stanowiące o popularyzacji modeli sztucznych sieci neuronowych. Jednak dopiero

w połowie lat 90-tych XX wieku, nastąpił przełom przyczyniający się do ich rozpowszechnienia. Sukces popularyzacji modeli sztucznych sieci neuronowych przypisywany jest ich przydatności w realizacji wielu praktycznych zadań w różnych dziedzinach życia, takich jak np. medycyna, finanse, fizyka czy zastosowania techniczne. Wspomniane wcześniej dziedziny nie są jedynymi, w których możliwe jest zastosowanie modeli sieci neuronowych. W rzeczywistości modele sieci neuronowych można wykorzystać wszędzie tam, gdzie rozpatrywane są zagadnienia związane z przetwarzaniem i analizą sygnałów, klasyfikacją, predykcją czy sterowaniem.

Zastosowanie sieci neuronowych z uwagi na ich nieliniowy charakter oraz względnie przystępną możliwość implementacji, pozwala w efektywny sposób tworzyć modele umożliwiające opis zjawisk i procesów, w których zastosowanie mniej skomplikowanych i powszechnie stosowanych modeli liniowych jest utrudnione lub niemożliwe. Jednym z wymienionych wcześniej atutów sztucznych sieci neuronowych jest ich względna przystępność. Przystępność w wykorzystaniu modeli sztucznych sieci neuronowych, związana jest ich specyfiką wynikającą z automatyzacji procesu uczenia. Tworzenie modeli sieci neuronowych nie wymaga od projektanta posiadania wyspecjalizowanej wiedzy na temat badanego obiektu czy zjawiska. Dodatkowo sam proces tworzenia modelu nie wymaga wiedzy na temat rozwiązywania skomplikowanych równań wykorzystujących zawiły aparat matematyczny do opisu zjawisk nieliniowych. Niemniej tworzenie modeli sieci neuronowych w dalszym ciągu wymaga od projektanta empirycznej wiedzy dotyczącej rozpatrywanego zagadnienia, co umożliwi mu dobór oraz zastosowanie optymalnego modelu sieci neuronowej, pozwoli na prawidłowe przygotowanie danych wykorzystywanych w procesie uczenia modelu oraz umożliwi poprawną interpretację otrzymanych wyników.

Koncepcja wykorzystania sztucznych sieci neuronowych ukształtowała się w wyniku badań prowadzonych w dziedzinie sztucznej inteligencji, a w szczególności związana była z badaniami z zakresu podstawowych modeli opisujących struktury znajdujące się w mózgach organizmów żywych.

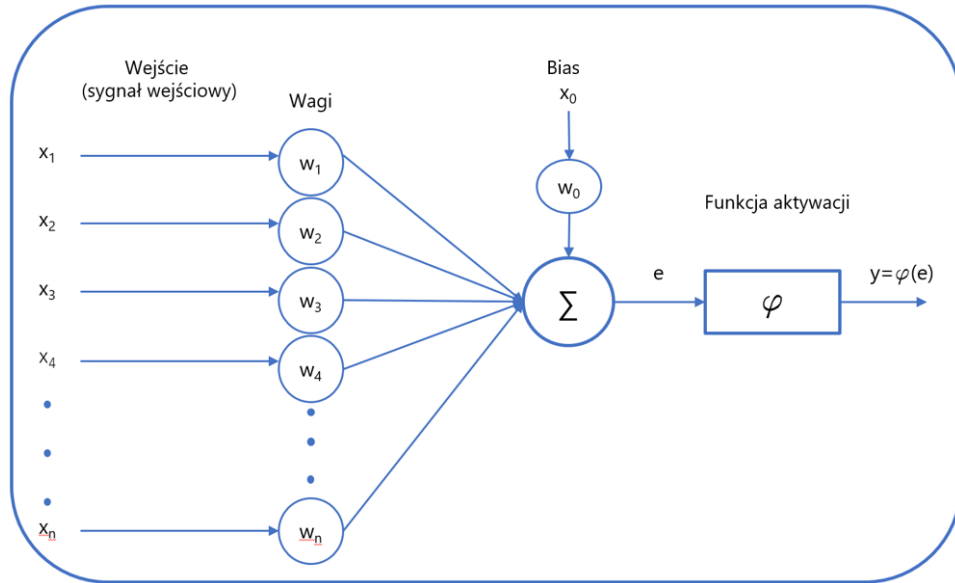
Kolejne badania prowadzone w pierwszej połowie XX wieku, doprowadziły do powstania systemów ekspertowych, które jednak okazały się niewystarczające aby w sposób precyzyjny odwzorować i wyjaśniać kluczowe aspekty ludzkiej inteligencji. Przyczyn tego niepowodzenia doszukiwano się w samej idei systemów ekspertowych, które to nie czerpały z koncepcji odwzorowania struktur znajdujących się w mózgu,

a jedynie wykorzystywały bazy wiedzy. Wspomniane wcześniej niepowodzenie wzbudziło w badaczach przekonanie, że dalsze badania w zakresie sztucznej inteligencji powinny być ugruntowane w bardziej bezpośredni sposób na biologicznym modelu mózgu. Doprowadziło to między innymi do opracowania koncepcji sztucznych sieci neuronowych bazujących na biologicznym modelu elementarnej komórki nerwowej znajdującej się w mózgu, czyli neuronie.

Do tworzenia modeli sztucznych sieci neuronowych wykorzystuje się sztuczne neurony McCullocha-Pittsa wraz z ich modyfikacjami. Neurony McCullocha-Pittsa w modelach sztucznych sieci neuronowych pełnią rolę matematycznego odpowiednika biologicznej komórki nerwowej. Uproszczoną zasadę działania pojedynczego sztucznego neuronu można opisać w czterech krokach.

- Krok 1: Do neuronu doprowadzana jest określona liczba sygnałów wejściowych.
- Krok 2: Każdy z doprowadzonych sygnałów przemnażany jest przez indywidualną wartość, określoną przez wagę. Wartość wagi stanowi odpowiednik biologicznej siły połączenia opisującej efektywność synapsy.
- Krok 3: W neuronie obliczana jest suma ważona wszystkich wejść.
- Krok 4: Sygnał będący sumą ważoną zostaje przekształcony przez ustaloną przez użytkownika funkcję aktywacji neuronu. Obliczona w ten sposób wartość stanowi sygnał wyjściowy neuronu.

Model sztucznego neuronu McCullocha-Pittsa oraz wzory opisujące wartość wyjściową części liniowej i nieliniowej neuronu przedstawiono odpowiednio na rysunku 4.2 oraz opisano wzorami (4.1) i (4.2).



Rys. 4.2. Model sztucznego neuronu McCullocha-Pittsa

gdzie: $x_1, x_2, x_3, \dots, x_n$ to sygnały wejściowe neuronu, x_0 to bias, $w_1, w_2, w_3, \dots, w_n$ to wagi sygnałów wejściowych, w_0 to waga biasu, e to suma ważona sygnału wejściowego neuronu, φ to funkcja aktywacji neuronu, a $y(e)$ to sygnał wyjściowy neuronu.

$$e_i = \sum_{j=1 \dots n} w_{ij} x_j + w_{i0}, \quad (4.1)$$

gdzie: e_i to suma ważona sygnału wyjściowego i -tego neuronu, w_{ij} to waga j -tego wejścia i -tego neuronu, x_j to j -ty sygnał wejściowy neuronu, a w_{i0} to bias i -tego neuronu.


$$y_i = \varphi \left(\sum_{i=0}^n w_i x_i + w_{i0} \right), \quad (4.2)$$

przy czym: y_i to sygnał wyjściowy i -go neuronu, φ to funkcja aktywacji neuronu, a $(\sum_{i=0}^n w_i x_i + w_{i0})$ to suma ważona sygnału wyjściowego i -tego neuronu.

4.2.1 Wielowarstwowa sieć perceptronowa

Pojedynczy sztuczny neuron, jako podstawowy element sztucznych sieci neuronowych nie przedstawia zbyt dużej wartości użytkowej. Za pomocą pojedynczego neuronu nie da się opracować modelu pełniącego rolę np. klasyfikatora dla zbioru danych, które nie są liniowo separowalne. Aby możliwe było opracowanie w pełni funkcjonalnego modelu sieci neuronowej, umożliwiającej klasyfikację zbiorów liniowo

niesperalowanych, niezbędne jest wykorzystanie większej liczby neuronów oraz organizację ich w odpowiednie struktury. Do najpopularniejszych i najprostszych struktur sztucznych sieci neuronowych, w których nie są stosowane pętle sprzężenia zwrotnego, a które z powodzeniem wykorzystywane są np. w diagnostyce maszyn elektrycznych, należą perceptrony wielowarstwowe (ang. *Multilayer Perceptron*, *MLP*). Przykładową strukturę perceptronu wielowarstwowego przedstawiono na rysunku 4.3.



Rys. 4.3. Przykładowa struktura sieci MLP

Na rysunku 4.3 przedstawiono strukturę sieci wielowarstwowej. Neurony wchodzące w skład sztucznej sieci neuronowej zorganizowane zostały w warstwy. W sieciach typu MLP można wyróżnić trzy rodzaje warstw:

- warstwa wejściowa - stanowi pierwszą warstwę w strukturze sieci, do której doprowadzany jest sygnał wejściowy. Liczba neuronów oraz liczba sygnałów wejściowych w tej warstwie modelu zależy od rozpatrywanego zagadnienia.

- warstwy ukryte - są to warstwy znajdujące się wewnątrz struktury sieci neuronowej, liczba neuronów w warstwach ukrytych a także liczba warstw ukrytych zależy od stopnia złożoności rozpatrywanego zagadnienia. Sygnał wejściowy dla neuronów w warstwach ukrytych stanowi sygnał wyjściowy z poprzedniej warstwy.
- warstwa wyjściowa - stanowi ostatnią warstwę w strukturze sieci. Sygnał wyjściowy z tej warstwy jest równocześnie odpowiedzią sieci neuronowej.

Z uwagi na sposób połączenia neuronów względem warstw, warstwy w sieciach typu MLP określane są jako warstwy w pełni połączone.

Jak wspomniano, elementem wprowadzającym nieliniowość do neuronu są funkcje aktywacji. Jednymi z popularniejszych funkcji aktywacji w sieciach typu MLP są funkcje s-kształtne takie jak:

- tangens hiperboliczny $\tanh(x)$ opisany wzorem:

$$\varphi(x) = \frac{e^{\beta x} - e^{-\beta x}}{e^{\beta x} + e^{-\beta x}}, \quad (4.3)$$

- funkcja sigmoidalna opisana wzorem:

$$\varphi(x) = \frac{1}{1+e^{-\beta x}}. \quad (4.4)$$

Zaletą funkcji s-kształtnych jest niewielka złożoność obliczeniowa w wyznaczaniu ich pochodnych, co ma znaczenie w procesie uczenia sieci neuronowych.

Na wyniki uczenia sztucznych sieci neuronowych ma wpływ nie tylko wybór funkcji aktywacji, ale również metoda uczenia sztucznej sieci neuronowej. Istnieje kilka kryteriów podziału metod uczenia. W literaturze, w jednym z podziałów uczenia wyróżnia się:

- uczenie nadzorowane (ang. *Supervised learning*) - metoda uczenia, w której do algorytmu dostarczany jest zbiór danych treningowych wraz z rozwiązaniem (etykietami/klasami);
- uczenie nienadzorowane (ang. *Unsupervised learning*) - uczenie modelu polegające na przekazywaniu nieoznakowanych danych (bez etykiet/klas). W tym sposobie uczenia do algorytmu dostarczane są jedynie dane wejściowe, a zadaniem algorytmu jest odnalezienie powiązań między nimi;

- uczenie półnadzorowane (ang. *Semi-supervised learning*) - polega na dostarczeniu do algorytmu częściowo oznakowanych danych. Wstępne przetwarzanie danych (ang. *preprocessing*) związane z oznakowaniem danych wejściowych jest przeważnie bardzo czasochłonne i nierzadko kosztowne. W rzeczywistości dostępne dane często składają się w większości z danych nieoznakowanych. Większość algorytmów półnadzorowanych stanowi kombinację algorytmów uczenia nadzorowanego i nienadzorowanego zaimplementowanych do sieci neuronowych;
- uczenie przez wzmocnienie (ang. *Reinforcement learning, RL*) - sposób uczenia polegający na interakcji modelu ze środowiskiem, na podstawie zebranych informacji. W odróżnieniu od uczenia nadzorowanego, półnadzorowanego i uczenia nienadzorowanego, w przypadku uczenia przez wzmocnienie nie przygotowuje się danych uczących, a jedynie wskazuje się środowisko, z którego model będzie korzystał zbierając dane uczące. W przypadku uczenia przez wzmocnienie oczekuje się od modelu maksymalizacji nagrody otrzymywanej przez model podczas procesu uczenia.

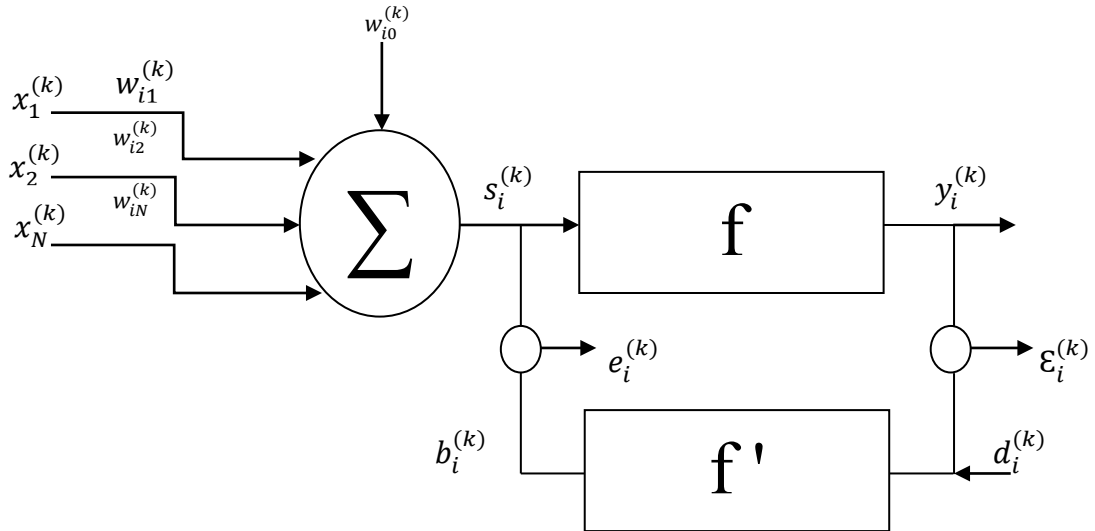
Istotnym elementem przy tworzeniu modeli sztucznych sieci neuronowych jest wybór algorytmu uczenia. W literaturze wyróżnia się następujące algorytmy uczenia sztucznych sieci neuronowych:

- algorytmy bezgradientowe - algorytmy te zakładają, że można odczytać wartość funkcji celu w dowolnym punkcie jej dziedziny, ale nie wymagają żadnych informacji na temat jej pochodnych (tzn. krzywizny). Do tej grupy należą między innymi takie algorytmy, jak:
 - algorytm genetyczny (ang. *Genetic Algorithm, GA*),
 - algorytm roju cząstek (ang. *Particle Swarm Optimization, PSO*),
 - algorytm symulowanego wyżarzania (ang. *Simulated Annealing, SA*),
 - algorytm adaptacji macierzy kowariancji (ang. *Covariance Matrix Adaptation, CMA*);
- Algorytmu gradientowe - polegają na wyznaczaniu kolejnego kierunku poszukiwań na podstawie znajomości gradientu funkcji celu,

w punkcie wyznaczonym w kroku poprzednim. Do algorytmów gradientowych można zaliczyć między innymi:

- algorytmy spadku gradientu (ang. *Gradient Descent, GD*),
- algorytm stochastycznego spadku gradientu (ang. *Stochastic Gradient Descent, SGD*),
- algorytm mini wsadowego spadku gradientu (ang. *Mini-batch Gradient Descent*),
- algorytm spadku gradientu z momentem (ang. *Gradient Descent with Momentum*),
- algorytm gradientu adaptacyjnego (ang. *Adaptive Gradient Algorithm, AdaGrad*),
- algorytm propagacji pierwiastka średniej kwadratowej (ang. *Root Mean Square Propagation, RMSProp*),
- algorytm adaptacyjnej estymacji momentu (ang. *Adaptive Moment Estimation, Adam*).

Zastosowanie algorytmów gradientowych w uczeniu sztucznych sieci neuronowych często związane jest z zastosowaniem algorytmu wstecznej propagacji błędu. Algorytm wczesnej propagacji błędu to jedna z najpopularniejszych metod uczenia wielowarstwowych jednokierunkowych sztucznych sieci neuronowych w uczeniu nadzorowanym. Nazwa tego algorytmu powiązana jest ze sposobem w jakim obliczane są poszczególne błędy w warstwach sieci neuronowych. W pierwszym kroku obliczany jest błąd w warstwie wyjściowej sieci, następnie w kolejnych krokach obliczane są błędy w warstwach ukrytych, a w ostatniej fazie algorytmu wyliczony jest błąd w warstwie wejściowej. A zatem kolejność obliczania błędu następuje w kierunku przeciwnym do kierunku przepływu informacji w sieci, stąd też nazwa algorytm wstecznej propagacji błędu. Cechą charakterystyczną tego algorytmu jest to, że do obliczenia błędu w aktualnym kroku wykorzystywane są błędy obliczone w kroku wcześniejszym, to znaczy błędy obliczone dla późniejszej warstwy sieci. Tak więc błąd propaguje od warstwy wyjściowej, przez warstwy ukryte, do warstwy wejściowej [115]. Realizację metody wstecznej propagacji błędu przedstawiono na rysunku 4.4.



Rys. 4.4 Model neuronu z wykorzystaniem algorytmu wstecznej propagacji błędów

Rysunek 4.4 przedstawia i -ty neuron k -tej warstwy, gdzie $b_i^{(k)}$ oraz $d_i^{(k)}$ są sygnałami wzorcowymi dla odpowiednio liniowej oraz nieliniowej części neuronu, natomiast $e_i^{(k)}$ oraz $\varepsilon_i^{(k)}$ to błędy opisujące różnicę między odpowiedzią sieci, a sygnałami wzorcowymi. Błędy dla neuronów można zapisać wzorami:

$$e_i^{(k)}(n) = b_i^{(k)}(n) - s_i^{(k)}(n), \quad (4.5)$$

$$\varepsilon_i^{(k)}(n) = d_i^{(k)}(n) - y_i^{(k)}(n). \quad (4.6)$$

Proces uczenia sztucznych sieci neuronowych polega na modyfikacji i dobieraniu wektora wag w taki sposób, aby zminimalizować funkcję błędów. Funkcję tę można określić na wiele sposobów. W praktyce często wykorzystuje się błąd średniokwadratowy obliczany dla ostatniej, wyjściowej warstwy sieci. Aby dokonać minimalizacji wcześniej wspomnianego błędów średniokwadratowego, w przypadku klasycznych i nieskomplikowanych struktur sieci neuronowych MLP można wykorzystać metodę najszybszego spadku, którą dla każdego neuronu w sieci można określić wzorem:

$$w_{ij}^{(k)}(n+1) = w_{ij}^{(k)}(n) + \mu \left(-\nabla_{ij}^{(k)}(n) \right), \quad (4.7)$$

przy czym wiedząc, że:

$$\nabla_{ij}^{(k)}(n) = \frac{\partial Q(n)}{\partial w_{ij}^{(k)}(n)} = \frac{\partial Q(n)}{\partial s_i^{(k)}(n)} \frac{\partial s_i^{(k)}(n)}{\partial w_{ij}^{(k)}(n)} = \frac{\partial Q(n)}{\partial s_i^{(k)}(n)} x_j^{(k)}, \quad (4.8)$$

gdzie $Q(n)$ oznacza błąd średniokwadratowy w n -tej iteracji i przyjmując:

$$\delta_i^{(k)}(n) \cong -\frac{1}{2} \frac{\partial Q(n)}{\partial s_i^{(k)}(n)}, \quad (4.9)$$

to składnik wzoru (4.7) dotyczący aktualizacji wag neuronu (związany z obliczaniem gradientu) można zapisać następująco:

$$\frac{\partial Q(n)}{\partial w_{ij}^{(k)}(n)} = -2\delta_i^{(k)}(n)x_j^{(k)}. \quad (4.10)$$

Po uwzględnieniu wzorów (4.8) oraz (4.9), wzór (4.7) przyjmuje postać:

$$w_{ij}^{(k)}(n+1) = w_{ij}^{(k)}(n) + 2\mu\delta_i^{(k)}(n)x_j^{(k)}, \quad (4.11)$$

gdzie: $x_j^{(k)}$ to i -ty sygnał na wejściu warstwy k -tej warstwy, a μ to współczynnik uczenia [115].

Obliczenie $\delta_i^{(k)}(n)$ dla dowolnej innej warstwy, poza warstwą wyjściową sieci, opisuje wzór:

$$\begin{aligned} \delta_i^{(k)}(n) &= -\frac{1}{2} \frac{\partial Q(n)}{\partial s_i^{(k)}(n)} = -\frac{1}{2} \sum_{m=1}^{N_{k+1}} \frac{\partial Q(n)}{\partial s_i^{(k+1)}(n)} \frac{\partial s_m^{(k+1)}(n)}{\partial s_i^{(k)}(n)} \\ &= \sum_{m=1}^{N_{k+1}} \delta_i^{(k+1)}(n) w_{mi}^{(k+1)}(n) f'(s_i^{(k)}(n)) \\ &= f'(s_i^{(k)}(n)) \sum_{m=1}^{N_{k+1}} \delta_i^{(k+1)}(n) w_{mi}^{(k+1)}(n). \end{aligned} \quad (4.12)$$

Ze wzoru (4.12) wynika, że obliczanie $\delta_i^{(k)}(n)$ jest wykonywane, jak wspomniano wcześniej, wstecz, tzn. od ostatniej wyjściowej warstwy do pierwszej wejściowej warstwy sieci. Zatem błąd dla i -tego neuronu w k -tej warstwie można zapisać jako:

$$\varepsilon_i^{(k)} = \sum_{m=1}^{N_{k+1}} \delta_i^{(k+1)}(n) w_{mi}^{(k+1)}(n), \quad (4.13)$$

a podstawiając do wzoru (4.12) zależność (4.13), to wzór ten można przedstawić następująco:

$$\delta_i^{(k)}(n) = \varepsilon_i^{(k)}(n) f'(s_i^{(k)}(n)). \quad (4.14)$$

Jedną z najpopularniejszych i najskuteczniejszych metod uczenia jednokierunkowych wielowarstwowych sztucznych sieci neuronowych, jest metoda wykorzystująca algorytm Levenberga - Marquardta (L-M). Algorytm L-M łączy zalety algorytmu Gaussa - Newtona oraz algorytmu najszybszego spadku. Połączenie tych dwóch algorytmów skutkuje dużą zbieżnością w przypadku, wówczas gdy algorytm zbliża się do rozwiązania optymalnego, a jednocześnie zapewnia dużą efektywność, tzn. szybki spadek wartości błędu, kiedy poszukiwane rozwiązanie jest odległe od bieżącego. Równie opisujące kierunek minimalizacji błędu w przypadku algorytmu L-M można zapisać następująco:

$$p(w(n)) = -[\nabla^2 \varepsilon(w(n-1))]^{-1} \nabla \varepsilon(w(n)), \quad (4.15)$$

gdzie: $p(w(n))$ oznacza kierunek minimalizacji funkcji błędu, $\nabla \varepsilon$ to gradient funkcji błędu, a $\nabla^2 \varepsilon$ to hesjan funkcji błędu.

Z powyższego równania wynika, że aktualizację wag w kolejnym kroku określić można jako:

$$w(n+1) = w(n) - [\nabla^2 \varepsilon(w(n-1))]^{-1} \nabla \varepsilon(w(n)), \quad (4.16)$$

a przyjmując, że funkcja celu opisująca wartość podlegającą minimalizacji, określona jest wzorem:

$$\varepsilon(w) = \sum_{n=1}^P Q_n = \sum_{n=1}^P \sum_{i=1}^{N_L} (d_i^{(L)}(n) - y_i^{(L)}(n))^2, \quad (4.17)$$

gdzie: $d_i^{(L)}(n)$ to wartość wzorcowa, $y_i^{(L)}(n)$ to wartość wyjściowa z neuronu, a L oznacza liczbę warstw w sieci neuronowej, wówczas zarówno gradient, jak i hesjan można zapisać jako:

$$\nabla \mathcal{E}(w(n)) = J^T(w(n))\mathcal{E}(w(n)), \quad (4.18)$$

$$\nabla^2 \mathcal{E}(w(n)) = J^T(w(n))J(w(n)) + I\mu, \quad (4.19)$$

gdzie: J to jacobian funkcji błędu neuronów z ostatniej warstwy sieci, $\mathcal{E}(w(n))$ to błąd neuronów znajdujących się w ostatniej warstwie sieci, I to macierz jednostkową, a μ oznacza współczynnik uczenia [115].

Po uwzględnieniu równań (4.18) i (4.19), zależność opisującą zmiany wartości wag w algorytmie Levenberga - Marquardta można zapisać jako:

$$w(n+1) = w(n) - [J^T(w(n))J(w(n)) + \mu I]^{-1}J^T(w(n))\mathcal{E}(w(n)), \quad (4.20)$$

a ostatecznie kierunek minimalizacji błędu można zapisać następująco:

$$p(w(n)) = -[J^T(w(n))J(w(n)) + \mu I]^{-1}J^T(w(n))\mathcal{E}(w(n)). \quad (4.21)$$

Wartość współczynnika uczenia jest modyfikowalna i zmienia się podczas uczenia MLP. Jednym z najpopularniejszych sposobów modyfikacji współczynnika uczenia jest wprowadzenie dodatkowego parametru β , który pozwala na modyfikację kroku podczas minimalizacji funkcji błędu [116, 117]. Niestety, wraz ze wzrostem skomplikowania struktur sieci neuronowych, proste metody takie jak przedstawiona metoda L-M, mogą okazać się niewystarczające. Współczesne bardziej skomplikowane struktury sieci neuronowych wymagają wykorzystania bardziej zaawansowanych metod uczenia. Do popularnych metod należą wspomniane metody adaptacyjne, takie jak *AdaGrad*, *RMSProp* czy *Adam*. W dalszej części pracy opisane zostały wykorzystane w głębokich modelach sztucznych sieci neuronowych metody uczenia maszynowego *SGD*, *RMSProp* i *Adam*.

Liczne badania dotyczące sieci typu MLP wykazały, że może ona być z powodzeniem wykorzystywana w wielu dziedzinach, w tym w diagnostyce oraz w modelowaniu maszyn elektrycznych. Na przestrzeni lat powstały prace traktujące między innymi o wykorzystaniu modeli MLP w:

- diagnostyce uszkodzeń wirnika silników elektrycznych [118–121],
- diagnostyce uszkodzeń stojana silników elektrycznych [122–125],
- wykrywaniu zwarć doziemnych [126],
- projektowaniu silników elektrycznych [127],

- w układach sterowania np. przy ustalaniu prędkości obrotowej maszyny [128].

4.2.2 Sieci samoorganizujące

Drugim rodzajem podstawowych struktur sieci neuronowych, które z powodzeniem są wykorzystywane w diagnostyce silników elektrycznych są samoorganizujące sieci neuronowe (ang. *Self-Organizing Map, SOM*), z których najpopularniejszą jest samoorganizująca sieć Kohonena [129–131]. W odróżnieniu od sieci typu MLP, w sieci Kohonena stosowana jest odmienna metoda nauczania sieci, czyli uczenie nienadzorowane. Z uwagi na to, że w przypadku uczenia nienadzorowanego do sztucznej sieci neuronowej nie są dostarczane wzorce wyjściowe, to zadaniem stawianym przed tego typu sieciami jest samoistne wytworzenie takiego wzorca. Oznacza to, że sieci typu SOM mają na celu utworzenie takiego modelu sieci, który w jak najdokładniej będzie odwzorowywał zależności pomiędzy danymi znajdującymi się w wektorze wejściowym.

W przypadku sieci Kohonena stosuje się metodę uczenia zwaną uczeniem konkurencyjnym (ang. *Competitive Learning*). W tej metodzie, w przeciwieństwie do klasycznych metod uczenia sieci neuronowych, podczas treningu modyfikowane są tylko wagi wybranego neuronu, który jest określany jako „wygrywający” (ang. *winner*). W zależności od wybranej metody, modyfikacji mogą podlegać również wagi neuronów znajdujących się w jego bezpośrednim otoczeniu.

Wybór wygrywającego neuronu odbywa się na podstawie określonej przez użytkownika metryki, opisującej „podobieństwo” sygnału wejściowego do wektora wag danego neuronu. Z przedstawionych informacji wynika, że to właśnie wybór metryki opisującej zależność między sygnałem wejściowym a wektorem wag neuronu, ma decydujący wpływ na efektywność działania modelu. W praktyce, wybór metryki sprowadza się do określenia miary opisującej odległość wektora wejściowego od wektora wag neuronu. Pierwotnie stosowana była metryka bazująca na iloczynie skalarnym pomiędzy wspomnianymi wektorami. Jednak stosowanie takiej miary prowadziło do problemów z normalizacją wektorów. Obecnie najczęściej stosowaną metryką jest metryka euklidesowa [115].


Tak jak w przypadku sieci typu MLP, tak i w przypadku sieci Kohonena, podczas procesu uczenia sieci dochodzi do aktualizacji wektorów wag. W przypadku sieci Kohonena wyróżnia się dwie metody aktualizacji wag:

- metodę addytywną,
- metodę subtraktywną.

W metodzie addytywnej modyfikacja wektora wag neuronu polega na dodawaniu przeskalowanego przez współczynnik uczenia wektora zawierającego wzorzec wejściowy, a następnie na unormowaniu wyniku. Z uwagi na sposób modyfikacji wektora wag w metodzie addytywnej może dojść do niestabilności modelu. Obecnie częściej stosowana jest metoda subtraktywna. W metodzie subtraktywnej do wektora wag dodawana jest jedynie różnica pomiędzy przeskalowanym wektorem wejściowym a wektorem wag. W wyniku dodawania wspomnianej różnicy, w przypadku kiedy wartość wektora wag i wektora wejściowego są takie same, to proces aktualizacji wektora wag nie zachodzi, co eliminuje zagrożenie w postaci niestabilności modelu.

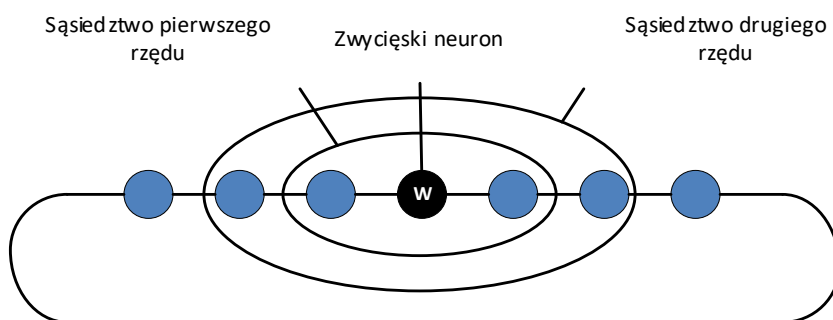
Jak wspomiano, podczas uczenia sieci Kohonena wykorzystywane jest uczenie konkurencyjne. Neurony w sieci Kohonena, w zależności od rozpatrywanego zagadnienia, formowane są przeważnie w struktury jedno- lub dwuwymiarowe. Przyjmują wtedy formę łańcucha (w przypadku struktur jednowymiarowych), lub siatki (w przypadku struktur dwuwymiarowych). Przedstawione struktury służą do uformowania odwzorowania z przestrzeni wielowymiarowej do odpowiednio dyskretnej przestrzeni jedno- lub dwuwymiarowej. Struktury te tworzone są w taki sposób, że punkty w przestrzeni wejść, które leżą blisko siebie są odwzorowywane przez bliskie sobie neurony w łańcuchu lub siatce. Pojedyncze neurony znajdujące się w siatce lub łańcuchu można traktować jako konkretne punkty z przestrzeni wejść. Bardzo duże znaczenie w sieciach Kohonena ma również sposób połączenia między neuronami w siatce lub łańcuchu. Połączenie to określa w sposób jednoznaczny relację sąsiedztwa między neuronami. Do podstawowych topologii sieci należą:

- topologie jednowymiarowego łańcucha:
 - łańcuch otwarty



Rys. 4.5 Topologia łańcucha otwartego

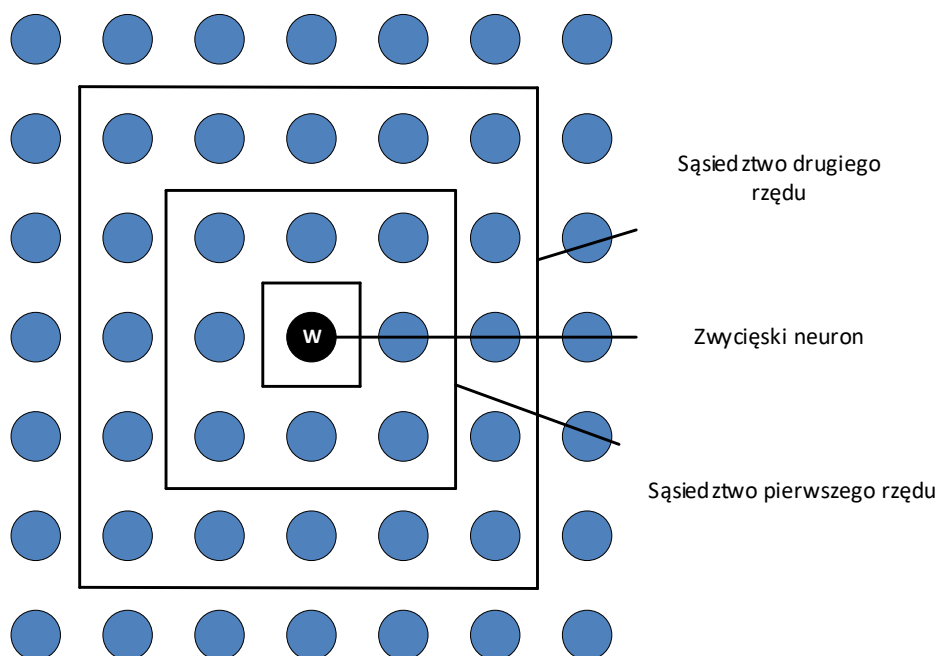
- o łańcuch zamknięty



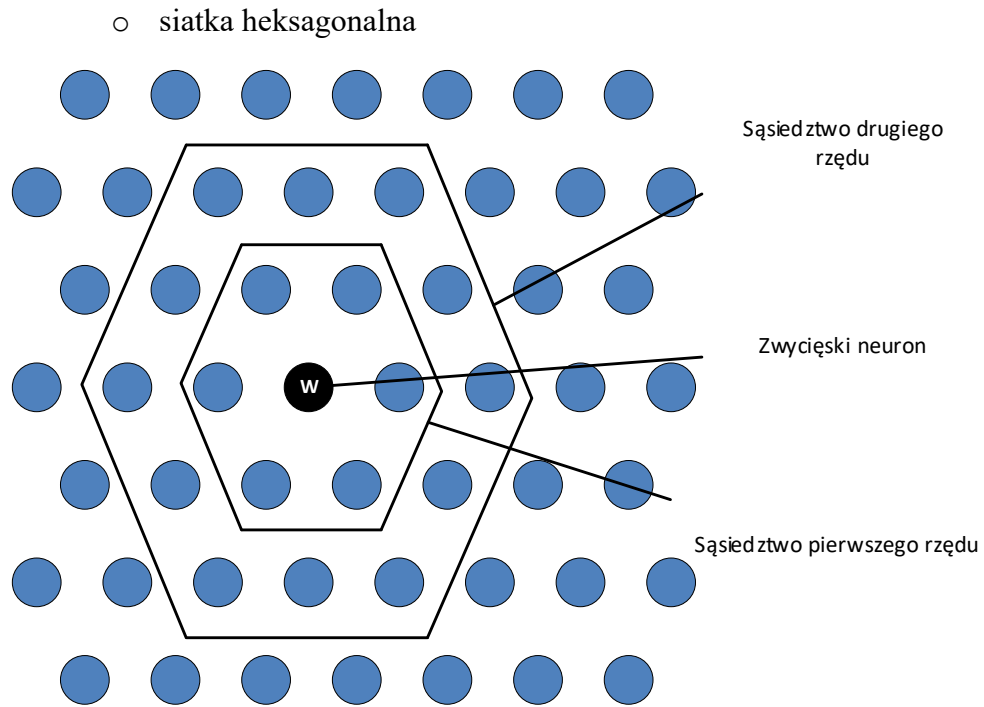
Rys. 4.6 Topologia łańcucha zamkniętego

- topologie dwuwymiarowej siatki:

- o siatka prostokątna



Rys. 4.7 Topologia siatki prostokątnej



Rys. 4.8 Topologia siatki heksagonalnej

Uczenie sieci SOM jest procesem iteracyjnym, a przy zastosowaniu podstawowego algorytmu uczenia, podczas uczenia nie ulega zmianie liczba neuronów. Natomiast redukcji ulega rozmiar sąsiedztwa, w taki sposób, że w etapie końcowym uzyskuje się sąsiedztwo zerowego rzędu, to znaczy sąsiedztwo składa się jedynie z rozpatrywanego neuronu.

Podstawowy algorytm uczenia sieci Kohonena ma postać:

$$w_{ij}(n+1) = w_{ij}(n) + \mu(n)h_{ci}(n)[x_j - w_{ji}(n)], \quad (4.22)$$

gdzie: μ oznacza współczynnik uczenia z przedziału od 0 do 1, h_{ci} oznacza funkcję sąsiedztwa, x oznacza wektor wejściowy a w oznacza wektor współczynników wagowych.

Podobnie jak w przypadku sieci typu MLP również sieci typu SOM znalazły szereg zastosowań w zagadnieniach diagnostyki. Tego typu sieci z powodzeniem wykorzystywane są przy detekcji na przykład:

- ekscentryczności [132],
- uszkodzeń łożysk [133],
- zwarć międzyzwojowych [134],

- niewspółosiowości wału [135],
- uszkodzenia klatki wirnika silników klatkowych [136–138].

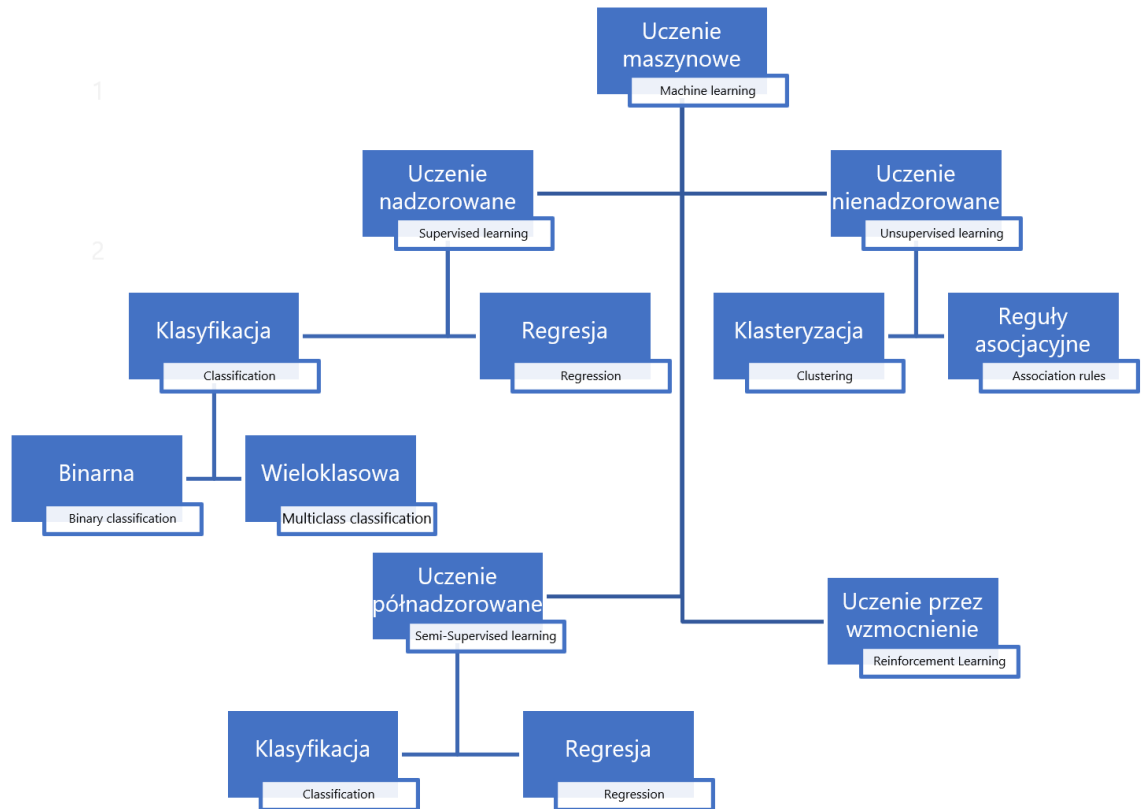
4.3 Głębokie sieci neuronowe

Termin głębokiego uczenia (ang. *Deep Learning*) nie ma wypracowanej ujednoczonej definicji, przez co jego interpretacja jest znacznie utrudniona. W uproszczeniu głębokie uczenie można rozumieć jako odmianę uczenia maszynowego, w której zadaniem nauczyciela jest wytrenowanie sieci w taki sposób, aby była w stanie rozwiązać problemy, które mimo swojej intuicyjności dla człowieka są trudne do opisanego za pomocą prostych aparatów matematycznych, a co za tym idzie są trudne do interpretacji przez maszyny.

Do problemów stawianych przed głębokim uczeniem maszynowym zaliczyć można problemy:

- klasyfikacji,
- regresji,
- klasteryzacji,
- reguł asocjacyjnych.

Podział problemów stawianych przed uczeniem maszynowym z uwzględnieniem sposobów uczenia maszynowego przedstawiono na rysunku 4.9.



Rys. 4.9. Podział uczenia maszynowego w odniesieniu do głębokich sieci neuronowych

Problem klasyfikacji polega na zaklasyfikowaniu danych wejściowych do zdefiniowanych klas lub etykiet. Problem ten ściśle związany jest z przedstawionym i opisanym w rozdziale 4.2.1 pojęciem uczenia nadzorowanego. Nadzorowane uczenie maszynowe polega na uczeniu modelu głębokiej sieci neuronowej (ang. *Deep neural network, DNN*) na podstawie zestawu danych szkoleniowych dostarczanych do sieci przez nauczyciela. W skład wektora wejściowego danych szkoleniowych wchodzi cechy oraz odpowiadające im etykiety/klasy. Na podstawie danych wejściowych podczas procesu uczenia dokonuje się obliczenia oraz modyfikacji parametrów modelu sieci. Pod pojęciem klasyfikacji można wyróżnić dwa podstawowe typy klasyfikacji: klasyfikację binarną oraz klasyfikację wieloklasową. W przypadku klasyfikacji binarnej zadaniem sieci jest określenie czy dane wejściowe należą do jednej z dwóch klas natomiast, w przypadku klasyfikacji wieloklasowej zachodzi konieczność zaklasyfikowania wektora wejściowego do więcej niż dwóch klas. Pomimo tego, że zagadnienia klasyfikacji binarnej i wieloklasowej mogą wydawać się niemalże identyczne, to od strony opisu matematycznego w procesie uczenia głębokiego stosowane są odmienne aparaty matematyczne w postaci np. różnych funkcji aktywacji neuronu. W przypadku uczenia binarnego często stosowaną funkcją aktywacji jest

wspomina w rozdziale 4.2.1 funkcja sigmoidalna, natomiast podczas rozwiązywania problemu klasyfikacji wieloklasowej z powodzeniem stosowana jest funkcja *softmax* (używana jest najczęściej w ostatniej warstwie sieci), oraz funkcja *rectified linear units* powszechniej znana pod nazwą ReLU, wraz z jej odmianami. Przykładowe funkcje aktywacji stosowane w głębokim uczeniu maszynowym przedstawiono poniżej:

- *softmax*

$$\sigma(z)_j = \frac{e_j^z}{\sum_{K=1}^K e_K^z}, \quad (4.23)$$

gdzie: z oznacza wektor wejść ostatniej warstwy sieci, j oznacza numer neuronu wejściowego z zakresu od $1, \dots, K$;

- ReLU

$$R(z) = \begin{cases} z, & z > 0 \\ 0, & z \leq 0 \end{cases}, \quad (4.24)$$

- LeakyReLU

$$R(z) = \begin{cases} z, & z > 0 \\ \alpha z, & z \leq 0 \end{cases}. \quad (4.25)$$

Drugim popularnym problemem stawianym przed głębokim uczeniem jest problem regresji. Naukowcy z całego świata, pracujący w różnych obszarach nauki, od wielu lat budują zbiory danych i opracowują zależności pomiędzy nimi [139–141]. Pomimo tego, że w wielu przypadkach opis matematyczny takich zależności jest dość prosty i nie wymaga stosowania skomplikowanego aparatu matematycznego, to istnieją zagadnienia, których opisanie za pomocą prostych równań, np. równań liniowych, jest niewystarczające lub wręcz niemożliwe. W takich przypadkach konieczne są czasochłonne badania pozwalające na sformułowanie skomplikowanych, nierzadko nieliniowych równań, które w sposób zadowalający pozwolą na odwzorowanie danego fragmentu rzeczywistości. Dzięki swojej specyfice zastosowanie algorytmów głębokiego uczenia pozwala na rozwiązanie tego problemu. Dlatego też w tym przypadku, najczęściej stawianym zadaniem przed osobą opracowującą sztuczną sieć neuronową jest przygotowanie, modelu sieci, który będzie w stanie odwzorować skomplikowane, niejednokrotnie zależne od wielu parametrów, korelacje pomiędzy zestawami danych.

Kolejny problem, czyli klasteryzacja, polega na grupowaniu danych na podstawie ich podobieństwa. Głównym celem klasteryzacji jest znalezienie struktury w zbiorze danych bez etykiet, co oznacza, że model nie zna wcześniej zdefiniowanych kategorii ani wzorców.

Natomiast problem reguł asocjacyjnych to problem, który koncentruje się na znajdowaniu wzorców i związków między elementami w dużych zbiorach danych. Reguły asocjacyjne są często stosowane np. w analizie transakcji handlowych, gdzie pomagają znaleźć korelacje między produktami kupowanymi w jednej transakcji.

Pojęcie głębokiego uczenia nierozdzielnie związane jest z wielowarstwowymi sieciami neuronowymi zwanymi, jak wspomniano, głębokimi sieciami neuronowymi. Cechą charakterystyczną dla większości tego typu sieci jest ich zdolność do pełnia jednocześnie kilku funkcji. Sieci te, w odróżnieniu od klasycznych sieci neuronowych, mogą pełnić jednocześnie funkcję generatora cech diagnostycznych jak również funkcję finalnego klasyfikatora, ale też z powodzeniem mogą realizować zagadnienia regresji. Dlatego też, prawidłowo zbudowany model głębokiej sieci neuronowej może stanowić alternatywę dla np. systemów eksperckich, w których zastosowanie wyspecjalizowanych deskryptorów wymaga niekiedy dużej wiedzy eksperckiej. Jako inspirację dla współczesnych modeli głębokich sieci neuronowych uważa się opracowany przez Kunihiko Fukushimę neocognitron [142]. Niemniej, na aktualną popularność głębokich modeli sztucznych sieci neuronowych miało wpływ miało zdefiniowanie przez profesora Yanna Le Cuna, jednej z popularniejszych w dzisiejszych czasach struktur głębokich sieci neuronowych, nazwanej Konwolucyjną (Splotową) Siecią Neuronową (ang. *Convolutional Neural Network, CNN*) [143–147]. Obecnie, z uwagi na bardzo dużą popularność rozwiązań komercyjnych, w których z powodzeniem wykorzystywane są różne rodzaje sieci neuronowych, oprócz klasycznych, wspomnianych w rozdziale 4.2 sieci neuronowych, takich jak MLP czy SOM, oraz wspomnianej w tym rozdziale, splotowej sieci neuronowej, należy wymienić również rekurencyjne sieci neuronowe (ang. *recurrent neural network, RNN*) [148], ze szczególnym uwzględnieniem takich wariacji jak:

- *Long Short-Term Memory (LSTM)* [149–153],
- *Sequence to Sequence (seq2seq)* [154–158].

Jak wspomniano, proste metody uczenia modeli sztucznych sieci neuronowych takie jak algorytm L-M, które z powodzeniem były wykorzystywane dla prostych

modeli sieci typu MLP, mogą być niewystarczające w przypadku głębokich sieci neuronowych. Do uczenia głębokich modeli sztucznych sieci neuronowych często wykorzystuje się takie metody jak wspomniany algorytm spadku gradientu z momentem czy adaptacyjne metody *RMSProp* oraz *Adam*. Metody *RMSProp* i *Adam* określa się mianem metod adaptacyjnych z uwagi na to, że w odróżnieniu np. od metody algorytmu spadku gradientu z momentem, gdzie tempo uczenia jest stałe (lub zmiana dotyczy wszystkich wag w określonym kroku) mają one możliwość regulacji wpływu kroku dla indywidualnych parametrów modelu, dzięki czemu kierunek minimalizacji wyznaczany przez parametry z obliczoną dużą wartością gradientu ma mniejszy wpływ na aktualizacje niż te parametry, dla których wartość gradientu jest niewielka. Poniżej przedstawiono wymienione wyżej metody.

- algorytm spadku gradientu z momentem

$$\mathbf{w}_{n+1} = \mathbf{w}_n - \mu p(\mathbf{n}), \quad (4.26)$$

gdzie: \mathbf{w}_{n+1} to wektor wag w kolejnym kroku obliczeniowym, \mathbf{w}_n to wektor wag w aktualnym kroku obliczeniowym, a $p(\mathbf{n})$ opisuje kierunek minimalizacji błędu, przy czym równanie opisujące kierunek minimalizacji można przedstawić następująco:

$$p(\mathbf{t}) = \gamma p(\mathbf{n} - 1) + (1 - \gamma) f' \varepsilon(\mathbf{w}_n), \quad (4.27)$$

gdzie: γ to współczynnik pędu, a $\varepsilon(\mathbf{w}_n)$ to funkcja celu.

- *RMSProp*

$$\mathbf{w}_{n+1} = \mathbf{w}_n - \mu \frac{f' \varepsilon_i(\mathbf{w}_n)}{\sqrt{p(n) + \epsilon}}, \quad (4.28)$$

gdzie ϵ to parametr mającym na celu ograniczenie zbyt małej wartości mianownika. Natomiast występujący w równaniu (4.28) składnik $p(n)$ będący wykładniczo ważoną średnią ruchomą można zapisać następująco:

$$p(\mathbf{n}) = \beta p(\mathbf{n} - 1) + (1 - \beta) (f' \varepsilon(\mathbf{w}_n))^2, \quad (4.29)$$

gdzie β to parametr określa wpływ średniej ruchomej na aktualizację wag.

- *Adam*

$$\mathbf{w}_{n+1} = \mathbf{w}_n - \mu \frac{\hat{\mathbf{m}}_n}{\sqrt{\hat{\mathbf{p}}_n + \epsilon}}, \quad (4.30)$$

gdzie estymowane wartości średniej i wariancji momentu można opisać wzorami:

$$\hat{\mathbf{m}}_n = \frac{m_t}{1 - \beta_1^n}, \quad (4.31)$$

$$\hat{\mathbf{p}}_n = \frac{p_t}{1 - \beta_2^n}, \quad (4.32)$$

gdzie β_1^n i β_2^n to współczynniki zanikania odpowiednio dla średniej i wariancji momentu w kroku n .

Składniki określające średnią oraz wariancję gradientu momentu można wyrazić następująco:

$$\mathbf{m}_n = \beta_1 \mathbf{m}_{n-1} + (1 - \beta_1) f' \boldsymbol{\varepsilon}_n, \quad (4.33)$$

$$\mathbf{p}_n = \beta_2 \mathbf{p}_{n-1} + (1 - \beta_2) f' \boldsymbol{\varepsilon}_n^2. \quad (4.34)$$

Przedstawione powyżej metody uczenia głębokich sieci neuronowych wykorzystane zostały w dalszej części pracy w procesie trenowania oraz optymalizacji parametrów spłotowych sieci neuronowych.


4.3.1 Splotowe sieci neuronowe

Splotowe sieci neuronowe są jedną z popularniejszych i częściej stosowanych struktur głębokich sieci neuronowych. Ze względu na swój charakter są z powodzeniem stosowane w zagadnieniach klasyfikacji, co z kolei przekłada się na ich przydatność w zagadnieniach diagnostycznych. Sieci CNN dzięki operacji splotu (konwolucji) umożliwiają uczenie się na strukturalnych danych przestrzennych takich jak np. obrazy, tekst czy wideo. Operacja konwolucji to doskonałe narzędzie do efektywnego wykorzystania lokalnej struktury danych, w efekcie czego znacząco poprawia się efektywność uczenia tego typu sieci. Większość architektur *ConvNet* składa się z kilku podstawowych typów warstw. Do popularniejszych typów warstw wykorzystywanych w CNN należą:

- warstwy splotowe (konwolucyjne) (ang. *convolutional layer*),
- warstwy normalizujące (ang. *normalization layer*),

- warstwy łączące (ang. *pooling layer*),
- warstwy porzucające (ang. *dropout layer*),
- warstwy spłaszczające (ang. *flatten layer*),
- warstwy w pełni połączone (ang. *fullyconnected layer*), warstwy w pełni połączone omówiono szerzej w rozdziale 4.2.1.

Strukturę przykładowej konwolucyjnej sieci neuronowej przedstawia rysunek 4.10. W skład tej sieci wchodzi warstwy: konwolucyjne, łączące, spłaszczające oraz w pełni połączone.



Rys. 4.10. Przykładowa struktura konwolucyjnej sieci neuronowej

Warstwy splotowe w sieciach neuronowych mają za zadanie wyekstrahowanie cech charakterystycznych dla rozpoznawalnego obiektu i charakteryzują się wysoką skutecznością w przypadku wektora wejściowego, który reprezentowany jest ściśle określoną strukturą. Do wyekstrahowania cech, wykorzystują operację splotu matematycznego pomiędzy prezentowanym sygnałem wejściowym lub innymi warstwami, a macierzą wag danej warstwy. Operację splotu matematycznego w ogólnym przypadku można opisać wzorem:


$$h(t) = f(t) * g(t) = \int_a^b f(t-x)g(x)dx, \quad (4.35)$$

gdzie: $h(t)$ to funkcja wynikowa, f i g to funkcje wejściowe, $*$ to symbol oznaczający operację splotu, t to parametr względem, którego oblicza się splot, x zmienna względem której wykonuje się całkowanie, a i b to granice całkowania.

W przypadku *ConvNet*, z uwagi na dyskretny charakter wektora wejściowego wykorzystuje się dyskretną postać operacji konwolucji opisaną wzorem:

$$h(t) = f(t) * g(t) = \sum_k f(t-x)g(x). \quad (4.36)$$

Operację splotu matematycznego w przypadku CNN można rozumieć jako filtrowanie wektora wejściowego. Filtrowanie wektora wejściowego polega na przemnożeniu wartości znajdujących się w wektorze wejściowym przez odpowiednie wartości wchodzące w skład filtra zwanego w literaturze również kernelem, jądrem splotowym lub jądrem. Graficzną reprezentację operacji konwolucji w warstwach konwolucyjnych przedstawia rysunek 4.11.



Rys. 4.11. Graficzna reprezentacja operacji konwolucji w *ConvNet*

Jak wynika z rysunku 4.11 w pierwszym kroku operacji konwolucji (wartości wejściowe zaznaczone kolorem zielonym w warstwie wejściowej), po przemnożeniu wartości wejściowych przez wartości filtra i po zsumowaniu poszczególnych wyników mnożenia $((2 \cdot (-1)) + (3 \cdot 0) + (0 \cdot 0) + (0 \cdot (-1)) + (2 \cdot 1) + (1 \cdot 2) + (7 \cdot 1) + (4 \cdot 0) + (0 \cdot 0))$ w wyniku otrzymywana jest wartość 9. W kroku drugim następuje przesunięcie filtra o 1 (dane wejściowe zaznaczone kolorem żółtym) ponownie następuje mnożenie wartości wejściowych przez wartości filtra i sumowanie wyników mnożenia. W wyniku operacji splotu w kroku drugim otrzymywana jest wartość 18.

Z uwagi na wysoką skuteczność w ekstrakcji informacji konwolucyjne sieci neuronowe bardzo często wykorzystywane są w analizie obrazu i dźwięku [159–164], a tym samym z powodzeniem znajdują zastosowanie w zagadnieniach diagnostyki [149, 165–170].

Do scharakteryzowania warstw konwolucyjnych sieci CNN wykorzystuje się tzw. hiperparametry. Hiperparametrami warstwy konwolucyjnej nazywamy te parametry sieci, które są określane przez użytkownika na potrzeby uczenia modelu. Do hiperparametrów warstwy konwolucyjnej należą między innymi:

- rozmiar jądra (ang. *kernel size*),
- dopełnienie (ang. *padding*),
- krok (ang. *stride*).

Rozmiar jądra w literaturze często nazywany również rozmiarem filtra, które określa wymiary jądra jakie stosowane jest na danych wejściowych. Parametr ten ma bardzo duży wpływ na proces uczenia i bezpośrednio przedkłada się na jakość klasyfikatora. Przykładowo, zastosowanie jądra o niewielkim wymiarze sprawia, że sieć jest w stanie wyekstrahować większą liczbę cech z danych wejściowych. Dodatkowo zastosowanie jąder splotowych o małym rozmiarze zapewnia możliwość budowania głębszych architektur CNN. Jest to możliwe dlatego, że stosowanie filtrów o małym rozmiarze, nie wpływa tak znacząco na redukcję wymiarowości macierzy wyjściowej, jak jądra o dużych wymiarach. Pomimo tego, że stosowanie filtrów o dużych wymiarach często skutkuje gorszą jakością klasyfikacji finalnego modelu, to w skutek stosowania filtrów o dużych wymiarach można uzyskać lepszą zdolność modelu do generalizacji.


Kolejnym hiperparametrem jest dopełnienie. Umożliwia ono dodanie do macierzy wejściowej warstwy konwolucyjnej, dodatkowych wartości na jej krawędziach, co wiąże się z powiększeniem rozmiaru macierzy wejściowej. Najczęściej dodawanymi wartościami są wartości zerowe. Dodanie dopełnienia może zapobiegać redukcji wymiaru macierzy wyjściowej, tak jak zostało to pokazane na rysunku 4.11, gdzie w skutek przeprowadzenia konwolucji na danych w macierzy 5x5 w efekcie otrzymano macierz 3x3. Przykład dopełnienia, gdzie dopełnienie zaznaczono kolorem pomarańczowym przedstawia rysunek 4.12.

0	0	0	0	0	0	0
0	2	3	0	6	1	0
0	0	2	1	7	0	0
0	7	4	0	8	2	0
0	9	1	9	6	0	0
0	1	0	0	12	5	0
0	0	0	0	0	0	0


Rys. 4.12. Przykład zastosowania wypełnienia

Krok to hiperparametr, który określa o ile elementów jądro splotowe powinno zostać przesunięte przy każdym kroku konwolucji. W praktyce, krok można określić jako przesunięcie okna filtra nad macierzą wejściową. Często używanym krokiem dla warstw konwolucyjnych jest krok równy jeden. Na rysunku 4.13 przedstawiono w sposób graficzny operację konwolucji dla kroku równego jeden oraz dla kroku równego dwa.

a)



b)



Rys. 4.13. Operacja konwolucji dla dwóch różnych wartości kroku a) krok równy 1 b) krok równy 2


Jak można zauważyć na rysunku 4.13, w skutek zastosowania kroku równego dwa, macierz wyjściowa została zredukowana z wymiaru 3x3 do wymiaru 2x2, ponadto zmianie uległa wartość wyjściowa drugiej operacji konwolucji.

Drugim często stosowanym rodzajem warstw w sieciach CNN są warstwy normalizujące. Popularnym rodzajem warstw normalizujących są warstwy normalizacji wsadowej (ang. *batch normalization layer*). Warstwa ta normalizuje aktywację wewnątrz wsadu poprzez standaryzację średniej i wariancji, co poprawia stabilność i efektywność podczas procesu uczenia. Umożliwia to tym samym stosowanie wyższych wartości współczynników uczenia przy jednoczesnym obniżeniu podatności na rozbieżność gradientów, co może przyspieszyć proces uczenia. Dodatkowo stabilizuje propagację gradientów, przeciwdziałając problemom eksplozji i zanikania gradientu.

Trzecim popularnym rodzajem warstw w sieciach CNN są warstwy łączące. Warstwy łączące wykorzystywane są w celu redukcji wymiarowości danych wejściowych. Redukcja wymiarowości danych wejściowych, z uwagi na to, że wpływa bezpośrednio na redukcję liczby parametrów niezbędnych do wytrenowania sieci, wpływa tym samym na zmniejszenie stopnia skomplikowania modelu. Natomiast mniejszy stopień skomplikowania modelu bezpośrednio wpływa na zmniejszenie zapotrzebowania na moc obliczeniową oraz na skrócenie czasu niezbędnego do wytrenowania sieci. Krótszy czas treningu i mniejsze zapotrzebowanie na moc obliczeniową ma bezpośrednie przełożenie na aspekt ekonomiczny uczenia sztucznych sieci neuronowych. Ponadto zastosowanie w modelu warstw łączących, w niektórych przypadkach, tj. np. przy zastosowaniu zbyt złożonego modelu sieci neuronowej do rozwiązania danego problemu, może przełożyć się na zmniejszenie szansy na pojawienie się zjawiska zwanego w sieciach neuronowych przeuczeniem (ang. *overfitting*). Zjawisko przeuczenia polega na zbytym dopasowaniu modelu do zbioru uczącego, przez co sieć efektywnie klasyfikuje przykłady, które były wykorzystywane w procesie uczenia sieci. Natomiast traci ona zdolność do generalizacji, co przekłada się na gorsze wyniki klasyfikacji podczas prezentacji danych, które nie były wykorzystywane w procesie uczenia. Idea łączenia polega na mapowaniu pewnego zbioru danych wejściowych zapisanych np. w macierzy 2×2 , do jednej wartości. Do dwóch najczęściej wykorzystywanych operacji łączenia zalicza się:

- *max (maximum)* – metoda *max* polega na wytypowaniu maksymalnej wartości ze zbioru danych wejściowych, a następnie na przeniesieniu tej wartości do następnej warstwy sieci;
- *avg (average)* – metoda *avg* polega na uśrednieniu wartości ze zbioru danych wejściowych, a następnie na przepisaniu uśrednionej wartości do następnej warstwy sieci.

Graficzną reprezentację warstwy łączącej *max* przedstawia rysunek 4.14.



Rys. 4.14. Reprezentacji idei operacji *max* w warstwie łączącej

Rysunek 4.14 przedstawia operację łączenia *max*. Wartości przedstawione w macierzy po lewej stronie rysunku są wartościami wejściowymi warstwy łączącej, natomiast macierz po prawej stronie jest macierzą wynikową. W powyższym przykładzie rozmiar okna oraz krok warstwy łączącej wynosi 2x2. Przesuwanie okna łączącego w operacji łączenia wykonywane jest od lewej do prawej a następnie od góry do dołu. W pierwszym kroku operacji łączenia (oznaczonym kolorem żółtym), z warstwy wejściowej przenoszona jest wartość maksymalna, czyli w tym przypadku sześć. Kolejny krok zmienia obszar poszukiwania (oznaczony kolorem niebieskim), w którym maksymalna wartość to osiem i to ona jest przenoszona do macierzy wynikowej. Następne kroki są wykonywane analogicznie.

Jak wspomniano wcześniej, częstym problemem występującym podczas uczenia głębokich sieci neuronowych jest problem z przeuczeniem. Wspomniano również, że w niektórych przypadkach warstwy łączące mogą pozytywnie wpłynąć na sieć niwelując w pewnym stopniu problem przeuczenia. Niemniej zastosowanie warstw łączących może być niewystarczające aby uniknąć przeuczenia sieci. Aby poprawić jakość klasyfikacji modelu można zastosować warstwy porzucające. Przeciwdziałanie przeuczeniu sieci w przypadku warstw porzucających polega na losowym wygaszaniu (wyłączaniu) niektórych połączeń pomiędzy kolejnymi warstwami sieci. Losowe wygaszanie połączeń pomiędzy warstwami sieci sprawia, że podczas procesu uczenia struktura sieci ulega ciągłej zmianie. Takie zmiany struktury sieci sprawiają, że sieć nie dopasuje się w prosty sposób do danych uczących, co może przelożyć się na poprawę wyników uczenia sieci. Oprócz warstw porzucających stosuje się również inne metody do ograniczania zjawiska przeuczenia. Do popularniejszych metod można zaliczyć:

- zwiększenie liczby danych uczących,
- regularyzację wag (ang. *Weight regularization*) – metoda ta polega na modyfikacji funkcji kosztu w taki sposób aby funkcja ta uwzględniała wartości wag modelu. Funkcja kosztu przyjmuje wtedy taką postać, dzięki której algorytm uczenia unika przypisywania dużych wartości pojedynczych wag w połączeniach między warstwami, co może przelożyć się na poprawę generalizacji modelu,
- metodę wczesnego zakończenia (ang. *Early stopping*) – metoda wczesnego zakończenia polega na przerwaniu procesu uczenia sieci na epoce, w której wartość funkcji straty nie maleje,
- normalizację wsadową (ang. *Batch normalization*) – metoda ta polega na standaryzacji danych wejściowych do danej warstwy w sieci w oparciu o przyjęte założenia.

W strukturach *ConvNet*, w celu dopasowania wektora danych wejściowych do potrzeb warstw w pełni połączonych, wykorzystuje się warstwy spłaszczające. W warstwach konwolucyjnych, w zależności od liczby jąder konwolucyjnych, dane mogą być przechowywane w postaci trójwymiarowego tensora. Natomiast w celu przeprowadzenia procesu klasyfikacji w sieci CNN wykorzystywane są warstwy w pełni połączone. Dane wejściowe do warstw w pełni połączonych prezentowane są w postaci wektora. Dlatego też, zadaniem warstwy spłaszczającej jest przekształcenie tensora reprezentującego dane wyjściowe warstwy np. konwolucyjnej, do postaci wektora.

Obecnie jednym z bardziej rozpowszechnionych i najczęściej stosowanych typów głębokich sieci neuronowych w zagadnieniach diagnostyki silników elektrycznych są konwolucyjne sieci neuronowe [171, 172]. Powodami popularności sieci CNN w zagadnieniach diagnostyki silników elektrycznych jest wszechstronność ich zastosowania, wsparcie w implementacji dzięki gotowym bibliotekom czy modułom, oraz wydajność obliczeniowa związana między innymi z możliwością wykorzystania nowoczesnych układów graficznych, co pozwala na wydajne trenowanie modeli składających się z wielu warstw na dużych zbiorach danych uczących. Przedstawiony powyżej fakty oraz wysoka skuteczność CNN w zagadnieniach klasyfikacji sprawia, że ten typ sieci z powodzeniem stosowany jest do klasyfikacji uszkodzeń silników

elektrycznych. Obszary zastosowań sieci CNN w diagnostyce silników obejmują między innymi:

- detekcję zwarć międzyzwojowych [173, 174],
- diagnostykę na podstawie drgań [148, 175–177],
- diagnostykę na podstawie sygnału akustycznego [178],
- diagnostykę na podstawie prądu silnika [179–181],
- diagnostykę na podstawie kilku różnych sygnałów diagnostycznych [182].

4.4 Metody oceny klasyfikatora

W celu oceny jakości klasyfikacji uszkodzeń silników elektrycznych przez modele sztucznych sieci neuronowych niezbędne jest określenie reguł umożliwiających ich porównanie. W praktyce do oceny jakości klasyfikatora wykorzystuje się określone metryki. Powszechnie stosowaną metryką do oceny jakości klasyfikatorów jest dokładność (ang. *Accuracy*, *ACC*). Metryka dokładności przedstawiona jest jako stosunek poprawnie sklasyfikowanych elementów do wszystkich elementów zbioru. Należy ona do grupy miar zbalansowanych, tzn. w pewnym stopniu opisuje wyniki całościowo, przez co może być stosowana jako samodzielna metryka, to znaczy, że do oceny klasyfikatora w tym przypadku nie jest wymagana znajomość dodatkowych informacji np. innych metryk. Niestety, w wielu przypadkach, w których rozkład elementów w poszczególnych klasach jest nierównomierny, miara ta jest niewystarczająca, a zastosowanie jej prowadzi do błędnych wniosków. Dlatego też, podczas oceny jakości klasyfikatora ważne jest aby posługiwać się większą liczbą metryk. Oprócz dokładności powszechnie stosowane są inne metryki łatwe w interpretacji, takie jak np.:

- precyzja (ang. *Precision*),
 - precyzja pozytywna (ang. *Positive Predictive Value*, *PPV*),
 - precyzja negatywna (ang. *Negative Predictive Value*, *NPV*),
- czułość (ang. *Sensitivity*, *True Positive Rate*, *Hit Rate*, *Recall*, *TPR*),
- specyficzność (ang. *Specificity*, *True Negative Rate*, *SPC*, *TNR*).

W celu wyznaczenia wspomnianych metryk niezbędne jest wprowadzenie dodatkowych pojęć określających wyniki: prawdziwie pozytywne, fałszywie

pozytywne, fałszywie negatywne i prawdziwie negatywne. Wprowadzenie powyższych pojęć dla dwóch klas w postaci macierzy pomyłek przedstawiono w tabeli 4.1.

Tabela 4.1. Macierz pomyłek dla klasyfikatora binarnego

	Prawidłowa klasa I	Prawidłowa klasa II
Odpowiedź sklasyfikowana jako klasa I	Prawdziwe pozytywne	Fałszywe pozytywne
Odpowiedź sklasyfikowana jako klasa II	Fałszywe negatywne	Prawdziwe negatywne

Jak wynika z tabeli 4.1, w przypadku dwóch klas, podczas klasyfikacji możliwe jest otrzymanie następujących wyników:

- prawdziwe pozytywne (ang. *True Positive, TP*) - wariant, w którym element pierwszej klasy został zaklasyfikowany prawidłowo jako element należący do pierwszej klasy,
- fałszywe negatywne (ang. *False Negative, FN*) - wariant, w którym element pierwszej klasy został zaklasyfikowany niepoprawnie jako element należący do klasy drugiej,
- fałszywe pozytywne (ang. *False Positive, FP*) - wariant, w którym element klasy drugiej rozpoznano niepoprawnie jako element należący do klasy pierwszej,
- prawdziwe negatywne (ang. *True Negative, TN*) - wariant, w którym element klasy drugiej rozpoznano poprawnie jako element należący do klasy drugiej.

Wykorzystując wartości z macierzy pomyłek, wspomniane metryki można zapisać następująco:

$$ACC = \frac{TP + TN}{TP + TN + FP + FN}, \quad (4.37)$$

$$PPV = \frac{TP}{TP + FP}, \quad (4.38)$$

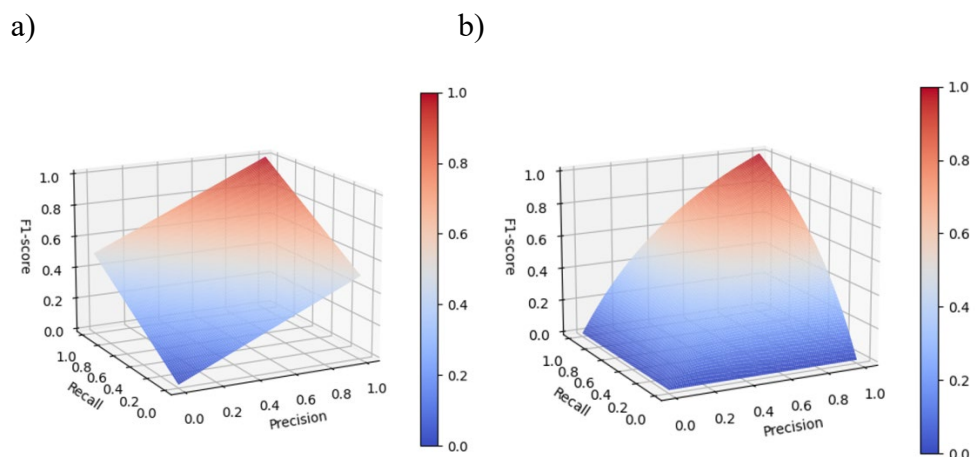
$$NPV = \frac{TN}{TN + FN}, \quad (4.39)$$

$$TPR = \frac{TP}{TP + FN}, \quad (4.40)$$

$$SPC = \frac{TN}{FP + TN} \cdot \quad (4.41)$$

Powyższe metryki, z wyjątkiem dokładności, należą do grupy metryk sparowanych. Oznacza to, że w celu oceny jakości klasyfikatora pod uwagę powinna być brana więcej niż jedna metryka. Powyższy przykład, dla zwiększenia czytelności, odnosił się do klasyfikatora binarnego ale wspomniane metryki można z powodzeniem stosować do klasyfikacji wieloklasowej.

Proste metryki takie jak dokładność, precyzja, czułość i specyficzność są dobrym narzędziem do oceny prostych klasyfikatorów, np. takich, które posiadają nieskomplikowaną strukturę, lub których zadaniem jest klasyfikacja danych wejściowych do niewielkiej liczby klas. Ale w wielu przypadkach, np. przy porównywaniu do siebie dwóch klasyfikatorów, metryki te mogą okazać się niewystarczające, a interpretacja wszystkich metryk jednocześnie bywa kłopotliwa. Dlatego też, poza metrykami prostymi w ocenie klasyfikatorów wykorzystuje się również metryki bardziej złożone. Popularną metryką złożoną, wykorzystywaną w zagadnieniach klasyfikacji, jest miara F1 (ang. *F1-Score*). Miara F1 pozwala na ocenę jakości klasyfikacji na podstawie dwóch wspomnianych metryk prostych, tj. precyzji pozytywnej i czułości. Idea miary F1 polega na uśrednieniu metryki precyzji pozytywnej i czułości. Z uwagi na niewystraszającą dokładność średniej arytmetycznej, w przypadku miary F1 zdecydowano się na zastosowanie średniej harmonicznej. Przykładowe wykresy średniej arytmetycznej i średniej harmonicznej przedstawiono na rysunku 4.15.



Rys. 4.15. Graficzna interpretacja średniej (a) arytmetycznej b) harmonicznej

Jak można zauważyć na rysunku 4.15, zaletą średniej harmonicznej w odniesieniu do średniej arytmetycznej jest przyjmowanie przez średnią harmoniczną mniejszych wartości w przypadku, gdy jedna z dwóch metryk jest wyraźnie mniejsza od drugiej. Dlatego też zastosowanie zmiennej harmonicznej pozwala na łatwiejszą interpretację wyników klasyfikacji. Wzór na miarę F1 można przedstawić jako:

$$F1 = \left(\frac{2}{PPV^{-1} + TPR^{-1}} \right) = 2 \frac{PPV \cdot TPR}{PPV + TPR}, \quad (4.42)$$

lub w przypadku bardziej ogólnym:

$$F_{\beta} = (1 + \beta^2) \cdot \frac{PPV * TPR}{(\beta^2 * PPV) + TPR}. \quad (4.43)$$

Miara F_{β} (ang. F_{β} -Score), dzięki wprowadzeniu współczynnika β , pozwala na określenie z jaką wagą traktowana jest precyzja pozytywna lub czułość podczas obliczania metryki. Zatem podczas obliczania miary F_{β} można zdecydować, która z metryk, precyzja pozytywna czy czułość, ma większe znaczenie dla danego klasyfikatora. Przetawione wyżej rozważania dotyczyły obliczania metryki F dla pojedynczej klasy, ale podobnie jak w przypadku metryk prostych, miarę F1 można rozszerzyć dla klasyfikatorów wieloklasowych poprzez obliczanie metryki F1 dla każdej klasy osobno. W wyniku obliczenia metryk F1 dla wielu klas otrzymane zostanie kilka metryk. Ponownie, aby ułatwić interpretację wyników zdefiniowano metrykę *Macro Average F1* ($\overline{F1}$). Metryka *Macro Average F1* opisana jest wzorem:

$$\overline{F1} = \frac{F1_1 + F1_2 + F1_3 + \dots + F1_n}{n}, \quad (4.44)$$

lub w przypadku ogólnym:


$$\overline{F\beta} = \frac{F\beta_1 + F\beta_2 + F\beta_3 + \dots + F\beta_n}{n}. \quad (4.45)$$

Miara *Weighted Average F* ($\overline{F\beta}$) różni się od *Macro Average F1* ($\overline{F1}$) tym, że dodatkowo brany jest pod uwagę rozmiar zbioru danej klasy. Dlatego też, w przypadku nierównomiernych zbiorów danych uczących, lepszym rozwiązaniem może okazać się zastosowanie miary ($\overline{F\beta}$).

Kolejnym sposobem oceny jakości klasyfikatora są krzywe ROC (ang. *Receiver Operating Characteristic, ROC*). Krzywe ROC służą do graficznej reprezentacji jakości klasyfikacji i pierwotnie używane były w problemach klasyfikacji binarnej, np. podczas porównywania dwóch klasyfikatorów. Do wykreślenia krzywych ROC wykorzystywane są dwie wspomniane metryki proste tj. czułość oraz specyficzność. Z pojęciem krzywych ROC związane są dwa dodatkowe pojęcia takie jak:

- punkt odcięcia (ang. *Cut-off, threshold*) - w krzywych ROC odnosi się do wartości granicznej, powyżej której obserwacje są przypisywane do jednej klasy, a poniżej do drugiej klasy. Dobór odpowiedniego punktu odcięcia zależy od kontekstu problemu i priorytetów. Często stosuje się różne metody optymalizacji punktu odcięcia w zależności od potrzeb, na przykład maksymalizując czułość lub specyficzność, minimalizując błąd klasyfikacji lub optymalizując inne metryki związane z klasyfikacją. Krzywe ROC wyznacza się dla różnych wartości punktu odcięcia;
- obszar pod krzywą (ang. *Area under curve, AUC*) - to miara używana w analizie krzywych ROC. Oznacza ona obszar pod krzywą ROC. Miara AUC określa zdolność klasyfikatora do rozróżniania danych wejściowych między dwiema klasami (np. pozytywną i negatywną) przez obliczenie obszaru pod krzywą ROC. Im większy obszar pod krzywą, tym lepsza skuteczność klasyfikacji. Idealny klasyfikator miałby $AUC = 1,0$, co oznaczałoby, że jest w stanie idealnie rozróżniać obserwacje z różnych klas. Dla klasyfikatora losowego $AUC = 0,5$.

Rozszerzenie koncepcji krzywych ROC do oceny klasyfikatorów wieloklasowych polega na zastosowaniu strategii „jeden kontra wszyscy” (ang. *one vs all*). Oznacza to, że wyznacza się metrykę dla każdej z klas osobno traktując wszystkie inne klasy jako odpowiedź niepoprawną. Przykładowe krzywe ROC przedstawia rysunek 4.16.



Rys. 4.16. Krzywe ROC w klasyfikacji wieloklasowej

W rozdziale czwartym przedstawione zostały metody uczenia maszynowego wykorzystywane w diagnostyce silników indukcyjnych. Przedstawiony został podział metod uczenia maszynowego. Opisane zostały zagadnienia związane z metodologią uczenia zarówno klasycznych modeli sztucznych sieci neuronowych jak również modeli głębokich a także zaprezentowane zostały metody oceny klasyfikatorów.

Przedstawione we wcześniejszych rozdziałach zagadnienia wykorzystane zostały do opracowania metody diagnostycznej uzwojenia stojana silnika indukcyjnego. W kolejnym rozdziale przedstawiona zostanie diagnostyka uzwojenia stojana silnika indukcyjnego z wykorzystaniem polowego modelu zjawisk elektromagnetycznych oraz głębokiej sieci neuronowej.

5 Głębokie sieci neuronowe w diagnostyce uzwojenia stojana silnika indukcyjnego

5.1 Wprowadzenie

W rozdziale 5 przedstawiono wyniki obliczeń symulacyjnych oraz rezultaty badań eksperymentalnych nad zastosowaniem polowo-obwodowego modelu zjawisk elektromagnetycznych oraz konwolucyjnych sieci neuronowych w diagnostyce obwodu stojana trójfazowego silnika indukcyjnego. W badaniach rozpatrywano silnik 3SIE 100L-4B firmy Celma Indukta. Dane znamionowe silnika zestawiono w tabeli 5.1. Celem badań było opracowanie metody diagnostycznej wykorzystującej polowo-obwodowy model trójfazowego silnika indukcyjnego do utworzenia baz danych dla głębokich sieci neuronowych oraz opracowanie i ocena jakości klasyfikacji modeli konwolucyjnych sieci neuronowych w zagadnieniu detekcji i klasyfikacji zwarć międzyzwojowych uzwojenia stojana trójfazowych silników indukcyjnych. Badania prowadzone w ramach niniejszej rozprawy zostały podzielone na kilka kluczowych etapów. Pierwszy etap obejmował opracowanie polowego modelu trójfazowego silnika indukcyjnego. Drugi etap dotyczył weryfikacji i optymalizacji opracowanego modelu z wykorzystaniem wyników z badań eksperymentalnych. Dodatkowo, na podstawie wyników uzyskanych w trakcie badań eksperymentalnych utworzono testową bazę danych dla modeli sieci konwolucyjnych. Trzeci etap skupiał się na obliczeniach symulacyjnych z wykorzystaniem polowo-obwodowego modelu trójfazowego silnika indukcyjnego. Wyniki obliczeń symulacyjnych umożliwiły utworzenie treningowych oraz walidacyjnych baz danych dla modeli konwolucyjnych sieci neuronowych. Czwartym etapem było opracowanie, trenowanie i strojenie modelu konwolucyjnej sieci neuronowej oraz prezentacja wyników klasyfikacji zwarć międzyzwojowych silnika indukcyjnego. W dalszych podrozdziałach szczegółowo omówiono etapy realizowanych badań.

Jak wspomniano, jednym z wielu kroków w badaniach nad zastosowaniem głębokiej sieci neuronowej w diagnostyce uzwojenia stojana silnika indukcyjnego jest zbudowanie zbioru uczącego. W tym celu przeprowadzono obliczenia symulacyjne silnika indukcyjnego z uwzględnieniem jego uszkodzeń.

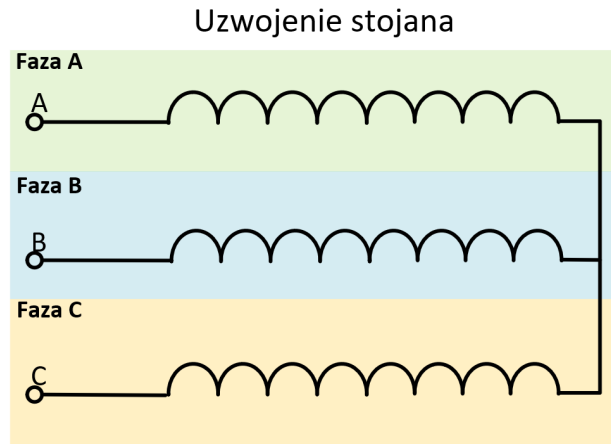
Na potrzeby obliczeń symulacyjnych opracowano polowo-obwodowy model silnika indukcyjnego typu 3SIE 100L-4B. Model numeryczny silnika opracowano w profesjonalnym oprogramowaniu ANSYS Electronics Desktop 2021 R1.

Tabela 5.1. Parametry znamionowe silnika


Parametr	Wartość	Parametr	Wartość
Moc znamionowa	3 kW	Znamionowy współczynnik mocy	0.79
Napięcie znamionowe	400 V	Znamionowy moment obrotowy	19.56 Nm
Prąd znamionowy	6.3 A	Liczba biegunów	4
Prędkość znamionowa	1465 rpm	Średnica zewnętrzna stojana	168 mm
Liczba faz	3	Średnica wewnętrzna stojana	108 mm
Liczba żłobków stojana	36	Średnica zewnętrzna wirnika	107.5 mm
Liczba żłobków wirnika	28	Średnica wewnętrzna wirnika	35 mm
Sprawność znamionowa	87.7 %	Gatunek blachy stojana	M470–50A
Częstotliwość znamionowa	50 Hz	Gatunek blachy wirnika	M470–50A
Rezystancja fazowa uzwojenia stojana	1.46 Ω		

5.2 Modelowanie uzwojenia stojana silnika bez uwzględnienia zwarć międzyzwojowych – wyznaczenie sygnału diagnostycznego

W literaturze schemat uzwojenia stojana przedstawiany jest w sposób zaprezentowany na rysunku 5.1, natomiast w programie ANSYS Electronics Desktop 2021 R1 uzwojenie fazy A stojana silnika 3SIE100L4B przedstawia się jak pokazano na rysunku 5.2



Rys. 5.1. Uzwojenie stojana silnika trójfazowego

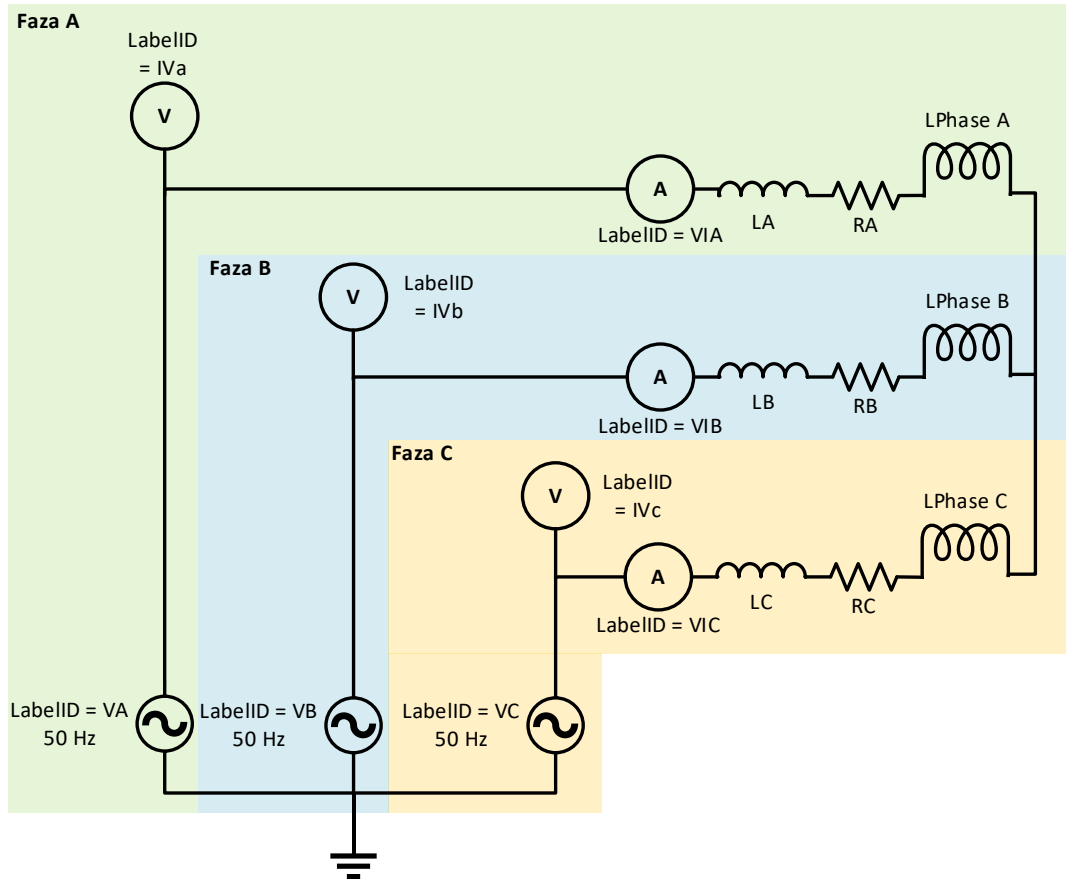


Rys. 5.2. Prezentacja uzwojenia fazowego stojana przyjęta w ANSYS Electronics Desktop 2021 R1

Jak można zauważyć, w zastosowanym programie do modelowania jednej fazy maszyny (rysunek 5.2), wykorzystywane są trzy elementy opisane jako *LA*, *RA* oraz *LPhase A*, gdzie *A* oznacza fazę *A* uzwojenia stojana silnika elektrycznego, przy czym:

- *LA* – reprezentuje cewkę idealną, to znaczy, że nie wprowadza ona dodatkowej rezystancji i pojemności do obwodu fazy *A* uzwojenia stojana.
- *RA* – reprezentuje rezystor idealny, to znaczy, że nie wprowadza dodatkowej indukcyjności i pojemności do obwodu.
- *LPhase A* – reprezentuje uzwojenie, nie wprowadza dodatkowej rezystancji, indukcyjności i pojemności do obwodu fazy *A*.

Stosując oznaczenia przedstawione na rysunku 5.2 i rozszerzając przyjętą koncepcję do uzwojeń silników trójfazowych oraz trójfazowego źródła zasilania, obwód uzwojenia stojana można przedstawić jak na rysunku 5.3.



Rys. 5.3. Obwód uzwojenia stojana silnika trójfazowego

Na przedstawionym powyżej schemacie, oprócz analogicznych do rysunku 5.2 elementów dla fazy B i C, do obwodu wprowadzono dodatkowe elementy takie jak LabelID = VA 50 Hz, LabelID = VB 50 Hz, LabelID = VC 50 Hz. Dodanie do schematu elektrycznego uzwojenia stojana wymienionych wyżej parametrów umożliwiło zamodelowanie sinusoidalnego źródła napięcia, które dla fazy A, opisanego następującą zależnością:

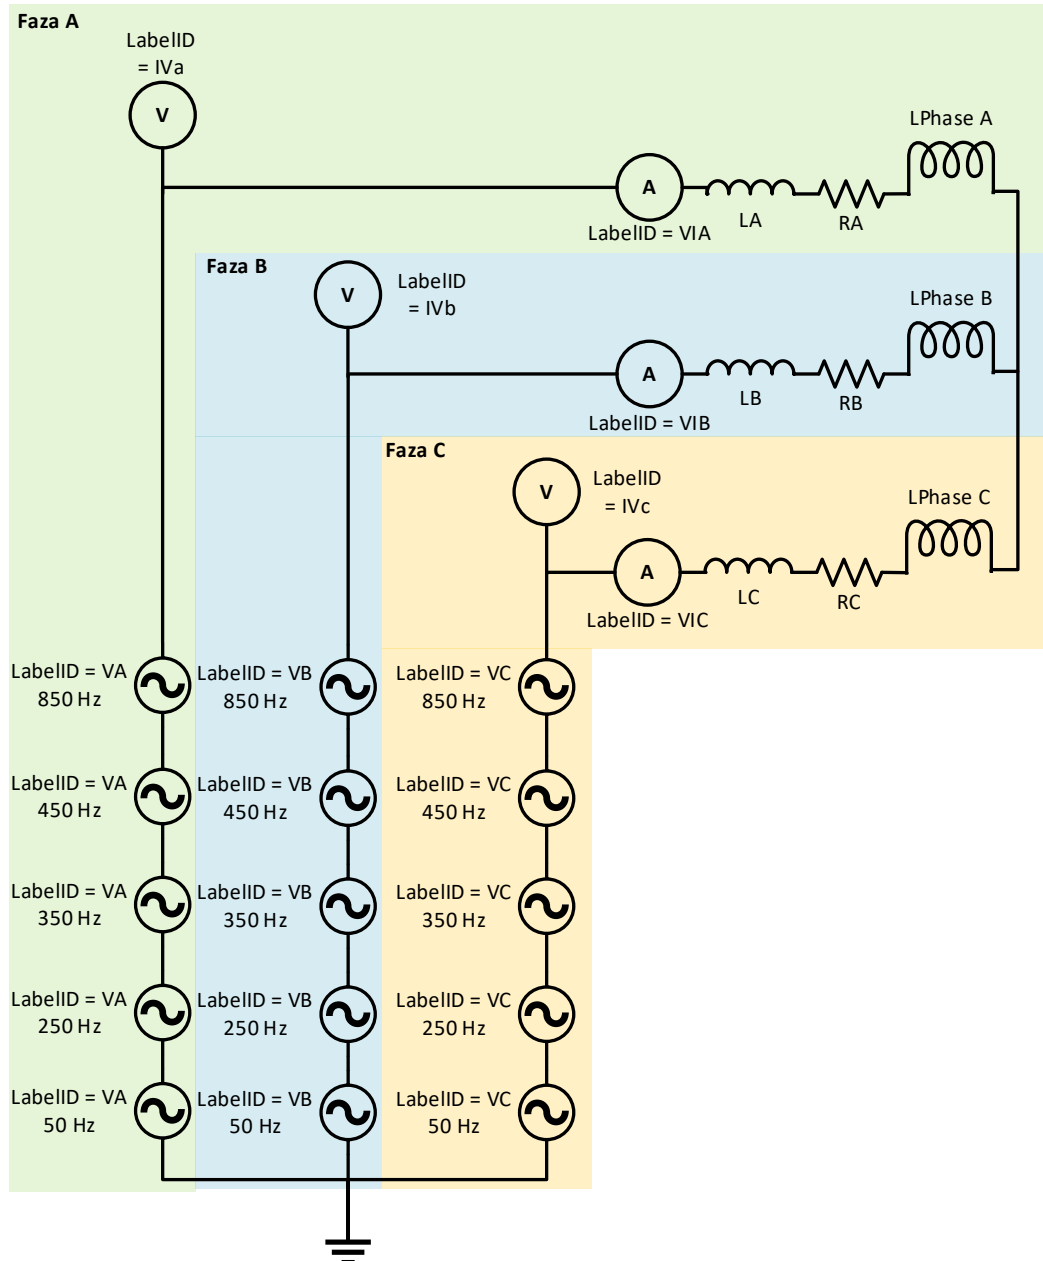
$$V(t) = V_0 + V_a e^{-Df(t-T_d)} \sin[2\pi VFreq(t - T_d) - Phase], \quad (5.1)$$

gdzie: V_0 to składowa stała, V_a to amplituda sygnału w fazie A, $VFreq$ to częstotliwość sygnału, T_d to opóźnienie, $Phase$ to przesunięcie fazowe, a Df to współczynnik tłumienia. Dodatkowo element ten posiada etykietę „LabelID” określającą jego nazwę. Ciąg znaków utworzony został na podstawie wartości częstotliwości napięcia, w przypadku fazy A określony jak „VA 50 Hz”. Analogicznie nazwa źródła dla fazy B to „VB 50 Hz”, a dla fazy C „VC 50 Hz”.

Oprócz samych źródeł napięciowych do schematu na rysunku 5.3 dodano takie elementy takie jak: LabelID = IVa, LabelID = IVb, LabelID = IVc oraz LabelID=VIA, LabelID=VIB, LabelID=VIC.


Element o etykiecie LabelID = IVa oznacza woltomierz, który traktowany jest jako element idealny. Zastosowanie tego elementu umożliwi rejestrację przebiegu napięcia fazowego w celu późniejszej analizy. Parametrem opisującym ten element jest jego nazwa „IVa” dla fazy A. Analogicznie dla fazy B jest to „IVb” oraz dla fazy C „IVc”. Natomiast element LabelID=VIA oznacza amperomierz, który traktowany jest jako element idealny. Zastosowanie tego elementu umożliwi rejestrację przebiegu prądu fazowego do późniejszej analizy. Parametrem opisującym ten element jest jego nazwa „VIA” dla fazy A. Analogicznie dla fazy B jest to „VIB” oraz dla fazy C „VIC”.

Dla dokładniejszego odwzorowania rzeczywistych przebiegów napięć fazowych stojana silnika elektrycznego, w modelach uwzględniono zniekształcenie napięć zasilających układu zasilania. Zniekształcenie napięcia zasilania zamodelowano poprzez połączenie szeregowo źródeł napięciowych różnych częstotliwościach. W opracowanym modelu, oprócz częstotliwości podstawowej, wzięto pod uwagę 4 dodatkowe częstotliwości mające największy wpływ na kształt napięcia zasilania. Wartości częstotliwości wyznaczono na podstawie analizy częstotliwościowej napięcia zasilania wykorzystywanego podczas pomiarów laboratoryjnych. Częstotliwości, które uwzględniono w modelu symulacyjnym w obwodzie zasilania wynoszą odpowiednio 50 Hz (częstotliwość podstawowa), 250 Hz, 350 Hz, 450 Hz oraz 850 Hz. Na rysunku 5.4 zilustrowano obwód uzwojenia stojana silnika z uwzględnieniem odkształcenia napięcia zasilania.



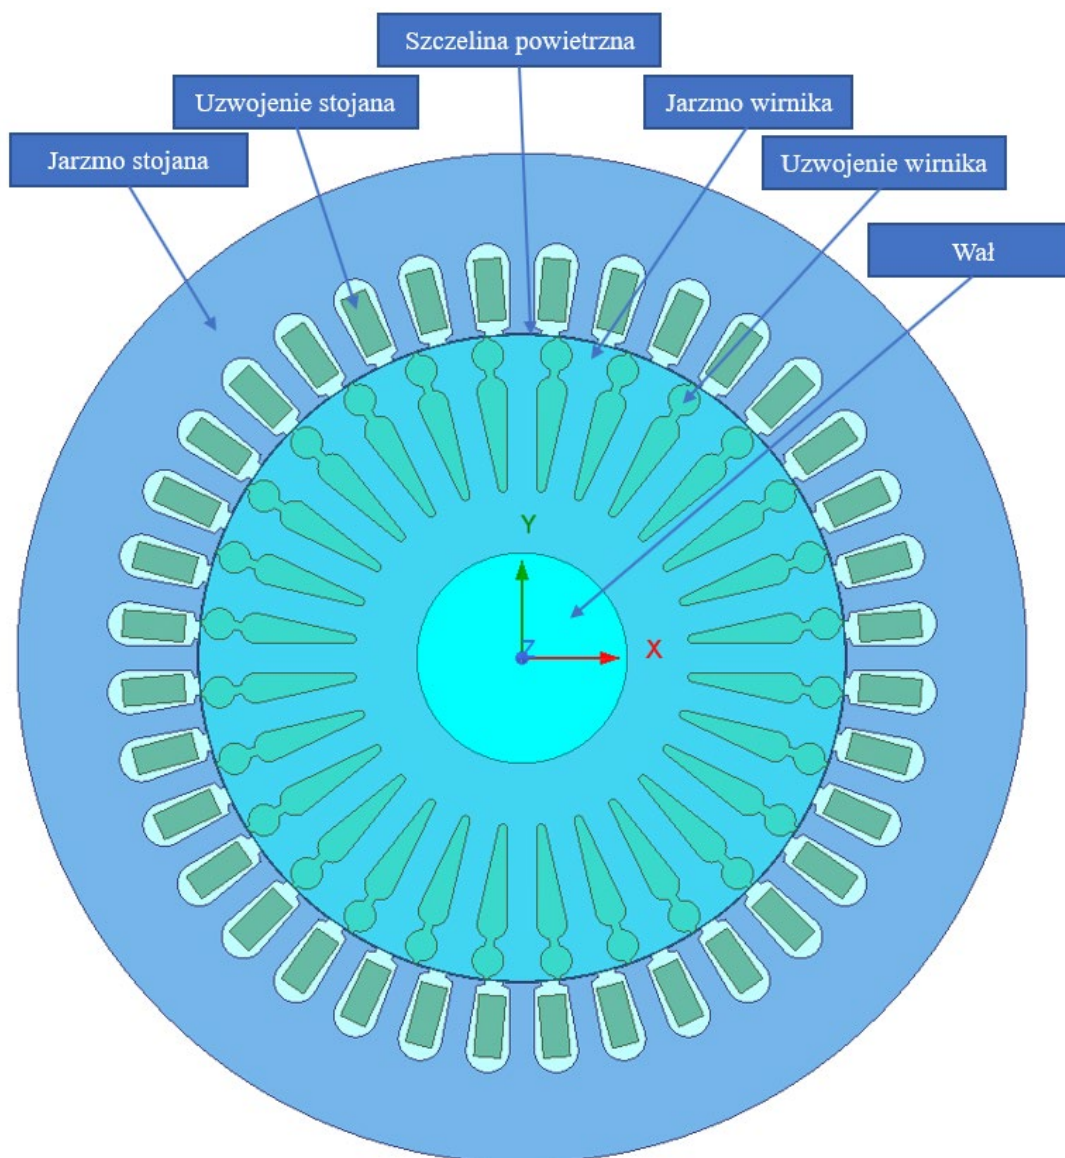
Rys. 5.4. Obwód uzwojenia stojana silnia trójfazowego z uwzględnieniem dodatkowych częstotliwości napięcia zasilającego

W modelowanym silniku indukcyjnym, uzwojenie każdej z faz składa się z sześciu cewek połączonych szeregowo. Liczba zwojów w każdej cewce wynosi 30. Sposób rozmieszczenia cewek w stojanie rozpatrywanego silnika przedstawiono na rysunku 5.5, gdzie kolorem czerwonym zaznaczono fazę A, niebieskim fazę B, natomiast fioletowym fazę C.



Rys. 5.5. Schemat uzwojenia stojana silnika 3SIE100L4B

Zaprezentowany na rysunku 5.4 obwód stojana wykorzystano do utworzenia dwuwymiarowych (2D) i trójwymiarowych (3D) polowych modeli silnika. Modele 2D i 3D zostały wykonane z wykorzystaniem oprogramowania odpowiednio Maxwell 2D oraz Maxwell 3D, które są częścią Ansys Electronics Desktop 2021 R1. Przekrój poprzeczny opracowanego dwuwymiarowego modelu silnika indukcyjnego klatkowego w środowisku Maxwell pokazano na rysunku 5.6. Natomiast strukturę trójwymiarowego modelu silnika klatkowego pokazano na rysunku 5.7.




Rys. 5.6. Geometria silnika w ujęciu dwuwymiarowym

Parametry siatki dyskretyzacyjnej modelu polowego 2D przedstawia tabela 5.2.

Tabela 5.2. Parametry siatki dyskretyzacyjnej modelu 2D

Podobszar	Liczba elementów w [mm]	Minimalna długość krawędzi [mm]	Maksymalna długość krawędzi [mm]	Średnia długość krawędzi [mm]	Minimalne pole elementu [mm ²]	Maksymalne pole elementu [mm ²]	Średnie pole elementu [mm ²]	Odchylenie standardowe (pole) [mm ²]
Szczelina powietrzna	416	0,000125	0,0018434	0,0012606	3,01E-08	1,23E-07	1,02E-07	2,88E-08
Wał	838	0,000654	0,0022838	0,001756	5,20E-07	1,44E-06	1,15E-06	3,15E-07
Region Zewnętrzny	1746	0,000100	0,0051500	0,0019725	2,82E-08	2,58E-06	9,74E-07	7,64E-07
Stojan	2736	0,000539	0,0090951	0,0033828	2,10E-07	2,44E-05	3,53E-06	5,55E-06
Wirnik	7448	7,83E-05	0,0027110	0,0013803	5,15E-09	2,22E-06	7,67E-07	6,16E-07
Klatka wirnika	4592	7,83E-05	0,0027217	0,0011814	6,84E-09	2,46E-06	5,23E-07	6,31E-07
Uzwojenie	378	0,001955	0,0053110	0,0035146	2,30E-06	5,71E-06	4,27E-06	1,38E-06



Rys. 5.7. Geometria silnika w ujęciu trójwymiarowym

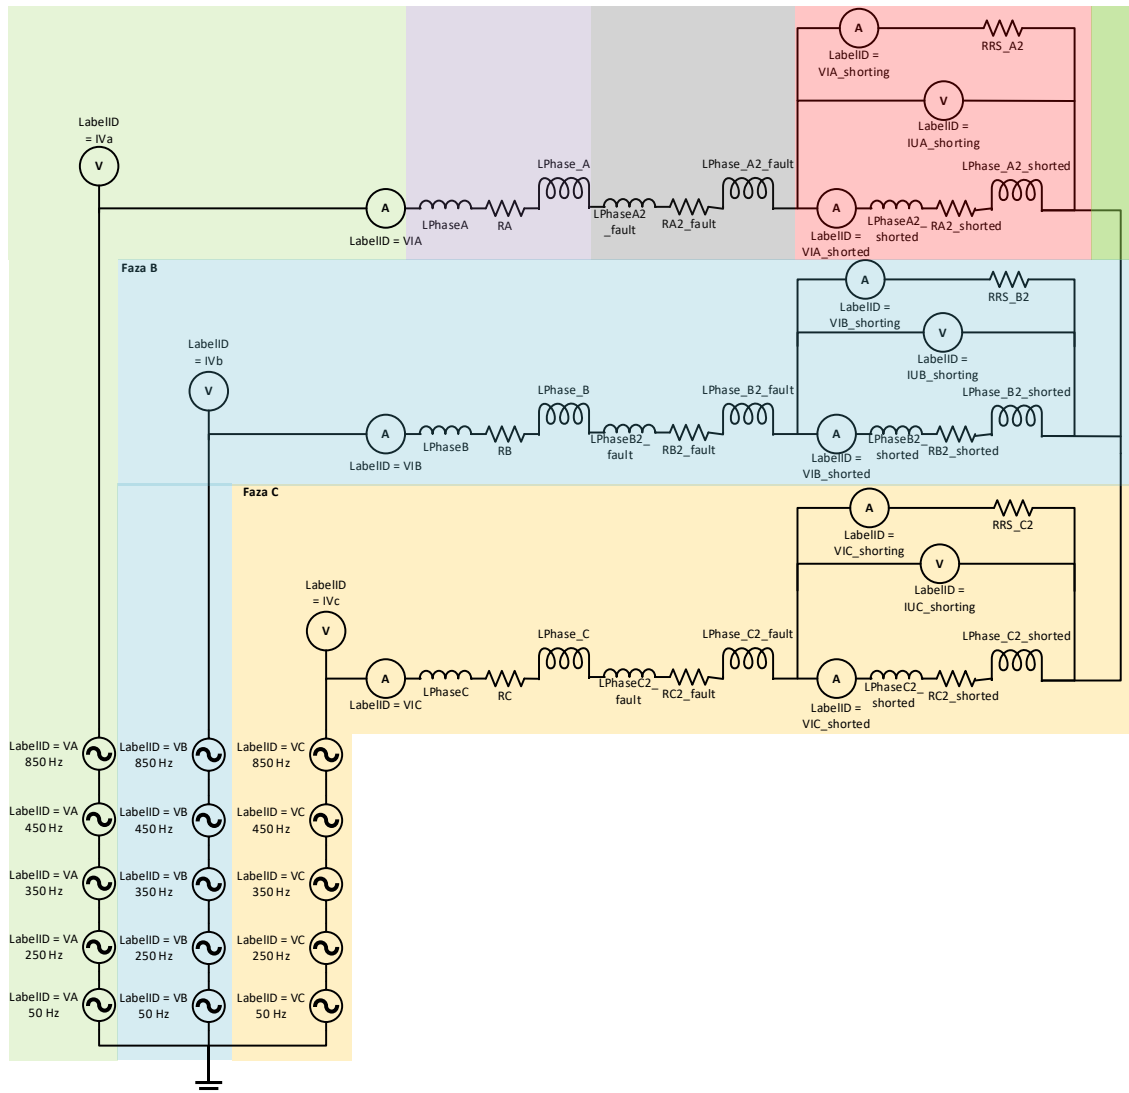
Parametry siatki dyskretyzacyjnej modelu polowego 3D przedstawia tabela 5.3.

Tabela 5.3. Parametry siatki dyskretyzacyjnej dla modelu 3D

Podobszar	Liczba elementów [mm]	Minimalna długość krawędzi [mm]	Maksymalna długość krawędzi [mm]	Średnia długość krawędzi [mm]	Minimalne pole elementu [mm ²]	Maksymalne pole elementu [mm ²]	Średnie pole elementu [mm ²]	Odchylenie standardowe (pole) [mm ²]
Szczelina powietrzna	13410	0,3838	42,2003	17,8249	0,0002	9,7003	0,5691	0,6972
Wał	13562	2,6345	27,9540	18,7951	0,0000	288,5900	11,8637	24,7368
Region Zewnętrzny	15697	0,4762	41,4618	16,6480	0,0000	3134,4200	43,8008	117,7070
Region Wewnętrzny	30625	0,5659	73,5000	23,6786	0,0004	4452,6400	45,2581	200,7260
Stojan	6317	1,7702	73,7430	35,8560	0,0314	2791,0500	111,6940	241,7100
Wirnik	88823	0,0261	38,2839	19,1568	0,0000	338,3330	4,7784	19,0395
Klatka wirnika	96439	0,3108	49,4633	18,2622	0,0000	659,1250	2,6285	13,1706
Uzwojenie	5747	3,9989	40,2553	14,5194	0,0644	115,1302	15,6882	19,3103

5.3 Modelowanie silnika z uwzględnieniem zwarcí międzyzwojowych w obwodzie stojana – wyznaczanie sygnału diagnostycznego

Opracowany w środowisku Maxwell RMXpert model obwodowy silnika został zaimplementowany do zbudowania modelu polowo-obwodowego uwzględniającego zwarcia międzyzwojowe w uzwojeniu stojana. Schemat obwód stojana uwzględniający zwarcia międzyzwojowe w trzech fazach maszyny przedstawia rysunek 5.8.



Rys. 5.8. Obwód uzwojenia stojana uwzględniający zwarcia międzyzwojowe uzwojenia stojana

W celu odwzorowania zwarcí międzyzwojowych uzwojenie stojana zostało podzielone na dwie części: reprezentujące niezwarłe zwoje oraz zwarte zwoje cewki stojana. I tak dla fazy *A* obwód opisany jako *LPhase_A* (tj. obszar oznaczony kolorem fioletowym na rysunku 5.8), odpowiada części niezwarłych zwojów uzwojenia stojana fazy *A*, *LPhase_A2_fault* (tj. obszar oznaczony kolorem szarym na rysunku 5.8), odpowiada niezwarłej części uszkodzonej cewki fazy *A* oraz *LPhase_A2_shorted* (tj.

obszar oznaczony kolorem czerwonym na rysunku 5.8) odnosi się do zwartej części uszkodzonej cewki fazy *A*. Modelowanie zwarc zwojowych w fazach *B* oraz *C* zostały zrealizowane i opisane w taki samo sposób.

Przygotowanie możliwie jak największej liczby wzorców uczących dla głębokiej sztucznej sieci neuronowej wymaga wprowadzenia parametryzacji konfiguracji zwarc międzyzwojowych w polowo-obwodowym modelu trójfazowego silnika indukcyjnego. Parametryzacja dotyczyła obwodu uzwojenia stojana maszyny. W tabeli 5.4 przedstawiono zmienne wykorzystane w parametryzacji:

Tabela 5.4. Zmienne wykorzystane do parametryzacji obwodu stojana silnika elektrycznego

Nazwa zmiennej	Opis
U_A, U_B, U_C	Amplituda napięcia zasilania o częstotliwości podstawowej 50 Hz w fazie <i>A, B</i> i <i>C</i>
U_A_3, U_B_3, U_C_3	Amplituda napięcia zasilania o częstotliwości 250 Hz w fazie <i>A, B</i> i <i>C</i>
U_A_5, U_B_5, U_C_5	Amplituda napięcia zasilania o częstotliwości 350 Hz w fazie <i>A, B</i> i <i>C</i>
U_A_7, U_B_7, U_C_7	Amplituda napięcia zasilania o częstotliwości 450 Hz w fazie <i>A, B</i> i <i>C</i>
U_A_9, U_B_9, U_C_9	Amplituda napięcia zasilania o częstotliwości 850 Hz w fazie <i>A, B</i> i <i>C</i>
A_deg, B_deg, C_deg	Kąt przesunięcia fazowego napięcia zasilania fazy <i>A, B</i> i <i>C</i>
f_A, f_B, f_C	Częstotliwość podstawowa napięcia zasilania fazy <i>A, B</i> i <i>C</i>
f_A_3, f_B_3, f_C_3	Częstotliwość 3. harmonicznej napięcia zasilania fazy <i>A, B</i> i <i>C</i>
f_A_5, f_B_5, f_C_5	Częstotliwość 5. harmonicznej napięcia zasilania fazy <i>A, B</i> i <i>C</i>
f_A_7, f_B_7, f_C_7	Częstotliwość 7. harmonicznej napięcia zasilania fazy <i>A, B</i> i <i>C</i>
f_A_9, f_B_9, f_C_9	Częstotliwość 9. harmonicznej napięcia zasilania fazy <i>A, B</i> i <i>C</i>
R_A, R_B, R_C	Rezystancja znamionowa uzwojenia fazy <i>A, B</i> i <i>C</i>
L_A, L_B, L_C	Indukcyjność znamionowa uzwojenia fazy <i>A, B</i> i <i>C</i>
T_L	Moment obciążenia

$N_{coil_A}, N_{coil_B}, N_{coil_C}$	Liczba wszystkich cewek fazy A, B i C
$N_{f_coil_A}, N_{f_coil_B}, N_{f_coil_C}$	Liczba uszkodzonych cewek fazy A, B i C
$N_{h_coil_A}, N_{h_coil_B}, N_{h_coil_C}$	Liczba nieuszkodzonych cewek fazy A, B i C
$k_{f_coil_A}, k_{f_coil_B}, k_{f_coil_C}$	$\frac{N_{f_coil_x}}{N_{coil_x}}$ Współczynnik określający stosunek liczby cewek uszkodzonych do wszystkich cewek, gdzie x oznacza poszczególną fazę
$k_{h_coil_A}, k_{h_coil_B}, k_{h_coil_C}$	$\frac{N_{h_coil_x}}{N_{coil_x}}$ Współczynnik określający stosunek liczby cewek nieuszkodzonych do wszystkich cewek, gdzie x oznacza poszczególną fazę
N_{NA}, N_{NB}, N_{NC}	Znamionowa liczba zwojów fazy A, B i C
N_{fA}, N_{fB}, N_{fC}	Liczba zwartych zwojów fazy A, B i C
k_{fA}, k_{fB}, k_{fC}	$\frac{N_{fx}}{N_{Nx}}$ Współczynnik określający stosunek zwartych zwojów do wszystkich zwojów, gdzie x oznacza poszczególną fazę
$R_{shortingA}, R_{shortingB}, R_{shortingC}$	Rezystancja obwodu zawierającego fazy A, B i C

Należy zaznaczyć, że przygotowanie obiektu rzeczywistego do badań eksperymentalnych w taki sposób aby umożliwiał on dokonywanie zwarc międzyzwojowych spowodowało zmianę wartości rezystancji i indukcyjności każdej fazy stojana. Zmiana ta została uwzględniona w modelach. Wartości tych parametrów obliczono z wykorzystaniem następujących zależności:

faza A :

$$L_{PhaseA} = L_A \cdot k_{h_coil_A} \cdot k_{h_coil_A}, \quad (5.2)$$

$$R_A = R_A \cdot k_{h_coil_A}, \quad (5.3)$$

$$L_{PhaseA2_fault} = L_A \cdot k_{f_coil_A} \cdot k_{f_coil_A} \cdot (1 - k_f) \cdot (1 - k_f), \quad (5.4)$$

$$R_{A2_fault} = R_A \cdot k_{f_coil_A} \cdot (1 - k_f), \quad (5.5)$$

$$L_{PhaseA2_shorted} = L_A \cdot k_{f_coil_A} \cdot k_{f_coil_A} \cdot k_f \cdot k_f, \quad (5.6)$$

$$R_{A2_shorted} = R_A \cdot k_{f_coil_A} \cdot (1 - k_f). \quad (5.7)$$

faza B:

$$L_{PhaseB} = L_B \cdot k_{h_coil_B} \cdot k_{h_coil_B}, \quad (5.8)$$

$$R_B = R_B \cdot k_{h_coil_B}, \quad (5.9)$$

$$L_{PhaseB2_fault} = L_B \cdot k_{f_coil_B} \cdot k_{f_coil_B} \cdot (1 - k_f) \cdot (1 - k_f), \quad (5.10)$$

$$R_{B2_fault} = R_B \cdot k_{f_coil_B} \cdot (1 - k_f), \quad (5.11)$$

$$L_{PhaseB2_shorted} = L_B \cdot k_{f_coil_B} \cdot k_{f_coil_B} \cdot k_f \cdot k_f, \quad (5.12)$$

$$R_{B2_shorted} = R_B \cdot k_{f_coil_B} \cdot (1 - k_f). \quad (5.13)$$

faza C:

$$L_{PhaseC} = L_C \cdot k_{h_coil_C} \cdot k_{h_coil_C}, \quad (5.14)$$

$$R_C = R_C \cdot k_{h_coil_C}, \quad (5.15)$$


$$L_{PhaseC2_fault} = L_C \cdot k_{f_coil_C} \cdot k_{f_coil_C} \cdot (1 - k_f) \cdot (1 - k_f), \quad (5.16)$$

$$R_{C2_fault} = R_C \cdot k_{f_coil_C} \cdot (1 - k_f), \quad (5.17)$$


$$L_{PhaseC2_shorted} = L_C \cdot k_{f_coil_C} \cdot k_{f_coil_C} \cdot k_f \cdot k_f, \quad (5.18)$$

$$R_{C2_shorted} = R_C \cdot k_{f_coil_C} \cdot (1 - k_f). \quad (5.19)$$

Na rysunkach 5.9 oraz 5.10 przedstawiono obszary nieuszkodzonej oraz uszkodzonej części uzwojenia stojana zaimplementowane w opracowanym modelu polowo-obwodowym silnika. Obszar reprezentujący nieuszkodzoną część uzwojenia stojana zaznaczono kolorem niebieskim, natomiast obszar reprezentujący część uszkodzoną kolorem czerwonym.




Rys. 5.9. Modelowanie zwarcia międzyzwojowego uzwojenia stojana




Rys. 5.10. Modelowanie zwarcia międzyzwojowego uzwojenia stojana

W kolejnym etapie badań opracowano trójwymiarowy model silnika z uwzględnieniem zwarć w uzwojeniu stojana. Modelowanie w ujęciu 3D zrealizowano w sposób podobny do modelowania w układzie dwuwymiarowym. Rysunek 5.11 oraz

5.12 przedstawiają odpowiednio fragment zwartej części uzwojenia stojana silnika elektrycznego.

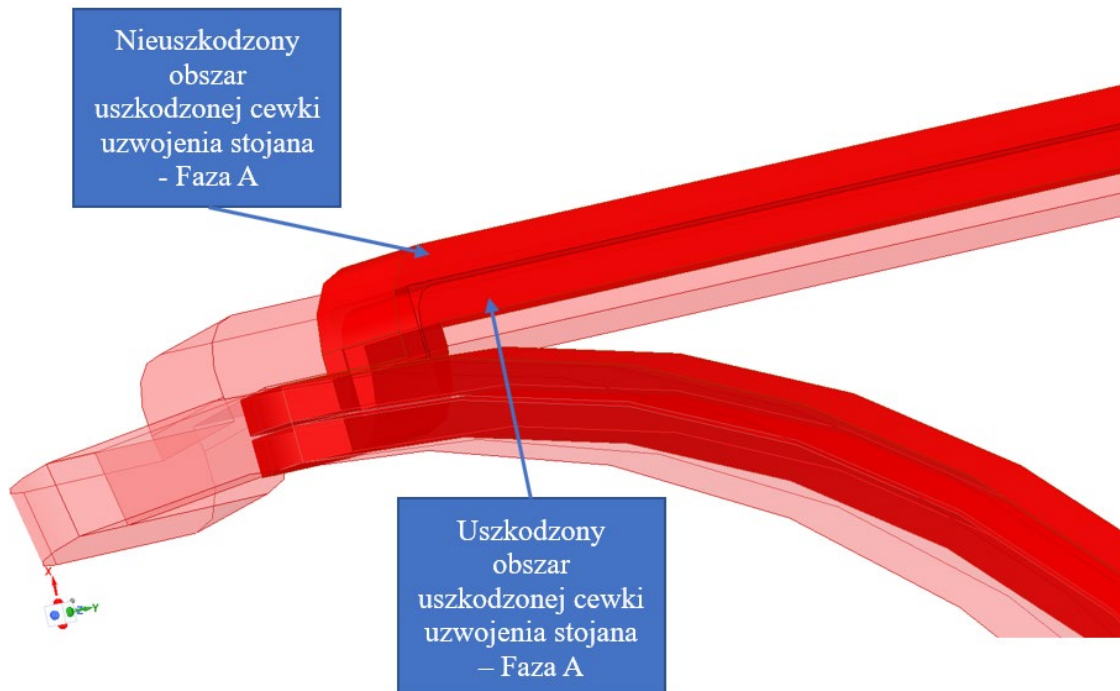


Rys. 5.11. Geometria 3D cewki – zwarcia międzyzwojowe uzwojenia stojana



Rys. 5.12. Geometria modelu w ujęciu 3D – zwarcia międzyzwojowe uzwojenia stojana

Ze względu na wysoki poziom złożoności geometrii silnika w ujęciu trójwymiarowym, na rysunkach zbiorczych nie jest widoczne zwarcie międzyzwojowe cewki stojana. Dlatego, na rysunku 5.13 przedstawiono w powiększeniu fragment uzwojenia fazy A, w którym zilustrowano zamodelowane uzwojenie z uwzględnieniem międzyzwojowego uzwojenia stojana silnika elektrycznego.




Rys. 5.13. Geometria 3D – zwarcie międzyzwojowe w obszarze cewki fazy A.

Opracowane 2D i 3D polowo-obwodowe modele silnika indukcyjnego klatkowego z uwzględnieniem zwarc w uzwojeniu stojana wykorzystano do wyznaczenia przebiegów prądów fazowych, prądów w uszkodzonych cewkach uzwojenia, momentu i prędkości obrotowej. Otrzymane przebiegi parametrów funkcjonalnych zostaną wykorzystane jako sygnały diagnostyczne w kolejnym etapie badań jako dane wejściowe dla głębokiej sieci neuronowej.

5.4 Badania eksperymentalne

W celu potwierdzenia poprawności opracowanych polowo-obwodowych modeli 2D i 3D trójfazowego silnika indukcyjnego klatkowego, pozwalających modelować zwarcia międzyzwojowe, wyniki obliczeń symulacyjnych porównano z rezultatami prac laboratoryjnych. W celu weryfikacji wyników obliczeń symulacyjnych, autor zaprojektował i zbudował skomputeryzowane stanowisko laboratoryjne przedstawione na rysunku 5.14. Stanowisko laboratoryjne składa się z badanego silnika 3SIE 100L-4B firmy Celma Indukta, analogowo-cyfrowych kart pomiarowych firmy National Instruments NI-9242, NI-9247, NI-9229, głowicy tensometrycznej do pomiaru momentu i prędkości obrotowej MT100, aparatury kontrolnej składającej się z laboratoryjnych analogowych mierników napięcia i prądu, rezystorów zwierających

oraz obciążenia. Szczegóły techniczne zastosowanych urządzeń pomiarowych opisano w dalszej części pracy.




Rys. 5.14. Stanowisko pomiarowe

Badany silnik przezwojono w taki sposób, aby umożliwić dokonywanie zwarć w warunkach laboratoryjnych. Zaczepy od uzwojenia stojana wyprowadzone na tabliczkę zaciskową przedstawia rysunek 5.15.




Rys. 5.15 Badany trójfazowy silnik elektryczny

Podczas przeprowadzonych badań pomiarowych wykonano szereg prób pozwalających na wyznaczenie parametrów silnika. Były to próby biegu jałowego, obciążenia oraz próby zwarcia pomiarowego. Wspomniane próby były wykonywane dla różnych konfiguracji zwartych zwojów w trzech fazach uzwojenia stojana trójfazowego silnika indukcyjnego. Przykładowe wyniki z badań eksperymentalnych dla konfiguracji zwarcie: faza A 4 zwarte zwoje, faza B 1 zwarty zwój, faza C 3 zwarte zwoje przedstawiono na rysunkach 5.16 oraz 5.17.



Rys. 5.16. Przebieg prądów fazowych dla $T_L = 0$



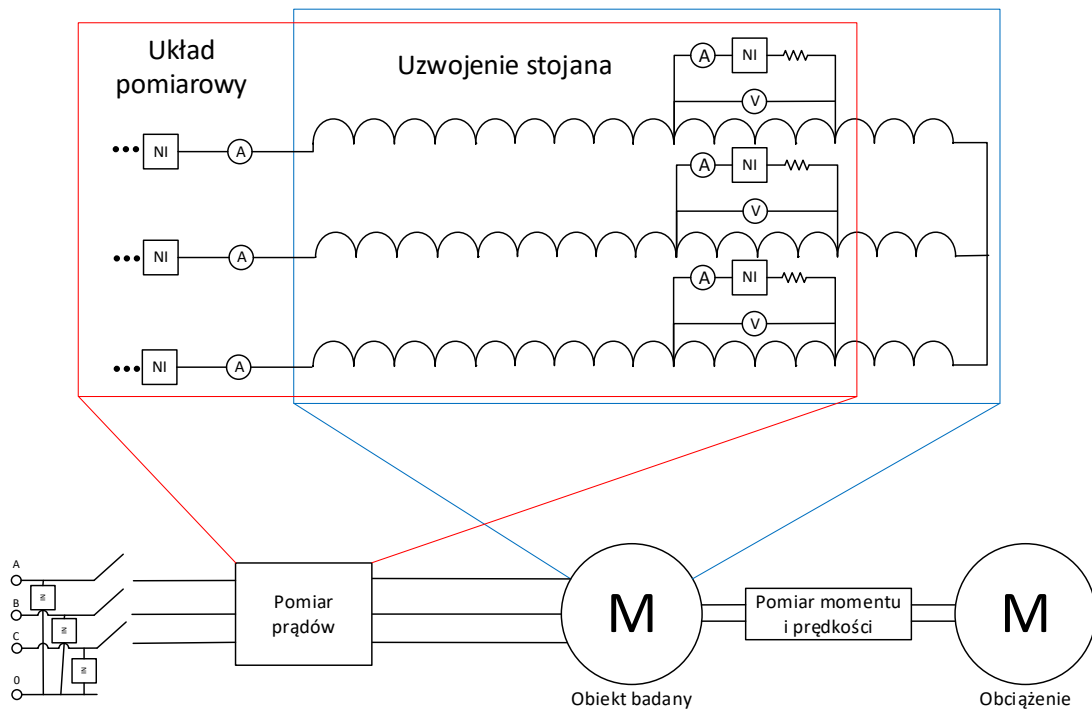
Rys. 5.17 Przebieg prądów fazowych dla $T_L = T_N$

Oprócz pomiarów dla próby biegu jałowego, próby obciążenia i próby zwarcia pomiarowego dokonano pomiarów rezystancji uzwojeń zarówno za pomocą dedykowanych mierników małej rezystancji TM508A, jak również w celach weryfikacyjnych - metodą techniczną. Otrzymane wartości przedstawia tabela 5.5.

Tabela 5.5. Wartości rezystancji uzwojenia stojana

Faza	Rezystancja (miliomierz) [Ω]	Rezystancja (metoda techniczna) [Ω]
A	1.523	1.523
B	1.523	1.523
C	1.523	1.523

Pomiary zrealizowano zarówno w stanie pracy ustalonej jak również podczas rozruchu. Schemat pomiarowy zastosowany podczas badań przedstawiono na rysunku 5.18.



Rys. 5.18. Schemat układu pomiarowego

Z uwagi na zastosowanie w układzie pomiarowym mierników analogowych, cyfrowych jak również kart pomiarowych, w celu zwiększenia czytelności na rysunku 5.18, miejsca połączenia poszczególnych kanałów prądowych i napięciowych kart pomiarowych zostały opisane zbiorczo jako symbol NI. Natomiast elementy układu kontrolnego, w którego skład wchodziły analogowe i cyfrowe amperomierze i woltomierze, oznaczono symbolami A i V. Opracowany układ pomiarowy umożliwił rejestrację napięć fazowych, prądów fazowych, prądów w obwodach zwierających, jak

również prędkości obrotowej i momentu na wale silnika. Do rejestracji przebiegów napięć, prądów, prędkości obrotowej i momentu obrotowego maszyny wykorzystano następujące moduły DAQ (ang. *Data Acquisition*) firmy National Instruments:

- NI-9242 - pomiar napięć fazowych,
- NI-9247 - pomiar prądów fazowych oraz prądów w obwodach zwierających,
- NI-9229 - pomiar prędkości oraz momentu obrotowego.

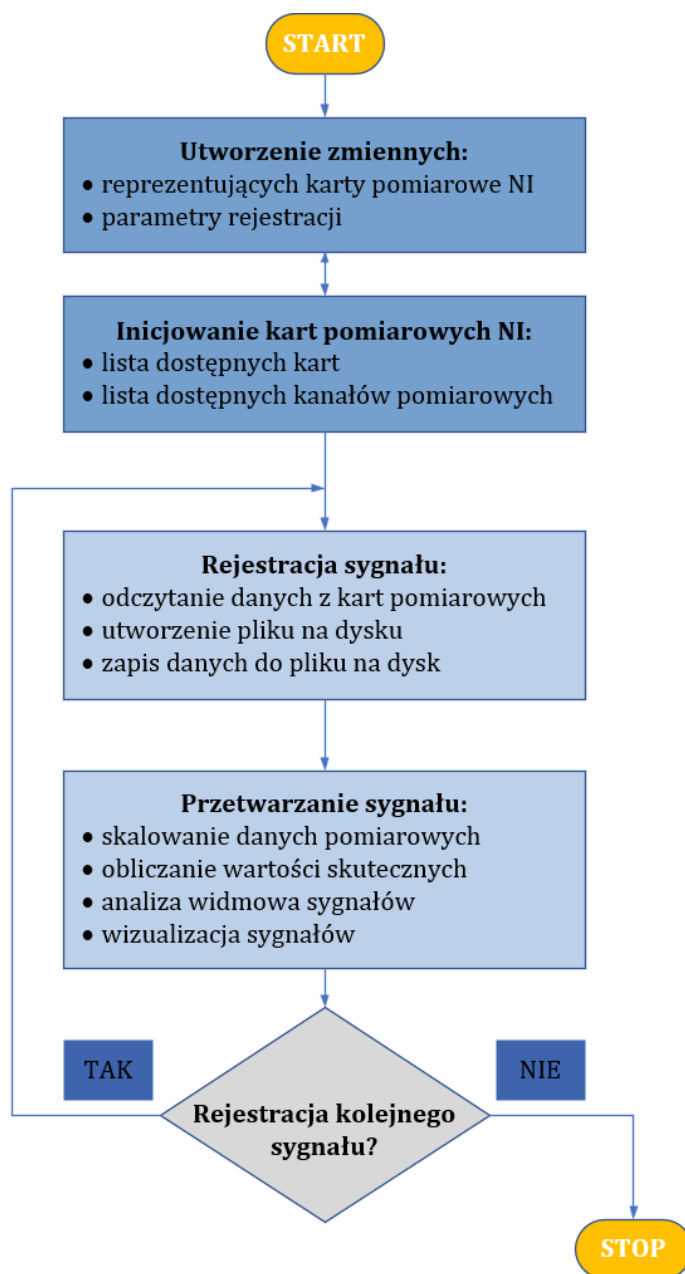
Wyposażona w cztery wejścia analogowe karta NI-9242 umożliwia równoczesny pomiar napięć zarówno fazowych, jak i przewodowych, odpowiednio do 250 V w układzie L-N oraz do 400 V w układzie L-L, z rozdzielczością 24 bitów. Karta NI-9247 dzięki trzem kanałom umożliwia jednoczesny pomiar trzech wartości przebiegów prądu do 50 A, z rozdzielczością 24 bitów. Natomiast zastosowana karta NI-9229 rejestrowała przebieg prędkości i momentu obrotowego. Wszystkie wykorzystane karty pomiarowe obsługują maksymalną częstotliwość próbkowania 50 kS/s. Do pomiaru prędkości oraz momentu zastosowana została głowica pomiarowa MT100, umieszczona na wale maszyny. Parametry znamionowe silnika, które zostały wykorzystane jako obciążenie dla obiektu badanego, przedstawiono w tabeli 5.6.

Tabela 5.6 Parametry znamionowe obciążenia

Parametr	Wartość
Moc znamionowa	15 kW
Napięcie znamionowe	400 V
Prąd znamionowy	31.4 A
Prędkość znamionowa	980 rpm
Liczba faz	3
Liczba par biegunów	3
Częstotliwość znamionowa	50 Hz

Pomimo tego, że prędkość znamionowa obciążenia wynosi jedynie 980 rpm to dzięki zastosowaniu przetwornika częstotliwości prędkość obciążenia została dostosowana do prędkości badanego silnika.

Na potrzeby prowadzonych badań eksperymentalnych zostało opracowane oprogramowanie w środowisku MATLAB. Oprogramowanie pozwala na automatyzację procesu rejestracji i archiwizacji danych pomiarowych. Ponadto, oprogramowanie umożliwia między innymi nawiązanie połączenia (komunikację) z systemem pomiarowym, odczyt danych z poszczególnych kanałów kart pomiarowych, automatyczny zapis wyników do plików na dysku komputera, jak również przetwarzanie sygnału, tj. skalowanie danych pomiarowych, obliczanie parametrów sygnału takich jak np. wartość skuteczna, a także przeprowadzenie analizy FFT oraz jednoczesną wizualizację przebiegów w celach kontrolnych. Schemat blokowy, prezentujący algorytm działania opracowanego programu, przedstawiono na rysunku 5.19.



Rys. 5.19. Algorytm programu do akwizycji danych

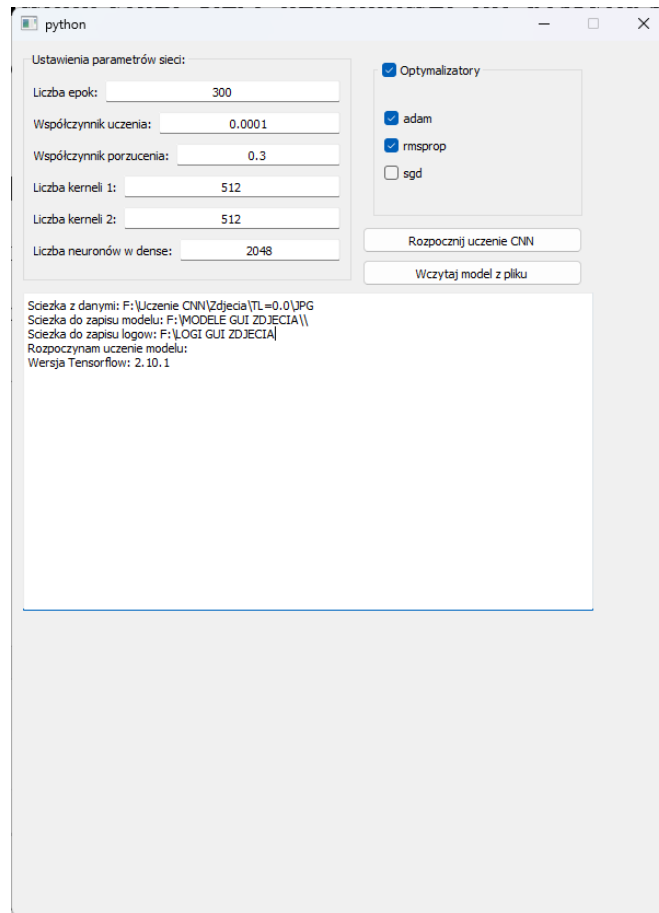
Otrzymane podczas badań eksperymentalnych wyniki pomiarów wykorzystano w realizacji następujących etapach badań:

- weryfikacja modelu polowo-obwodowego,
- optymalizacja modelu,
- weryfikacja głębokiej sieci neuronowej.

5.5 Konwolucyjne sieci neuronowe w diagnostyce uzwojenia stojana silnika indukcyjnego

5.5.1 Wprowadzenie

W ramach prowadzonych badań do klasyfikacji zwarć międzyzwojowych uzwojenia stojana trójfazowego silnika indukcyjnego, opracowano modele konwolucyjnych sieci neuronowych. Na podstawie wyników obliczeń symulacyjnych oraz pomiarowych, opracowano zbiór danych, w którym zawarto 1331 klas odpowiadających stopniu uszkodzenia uzwojenia stojana silnika indukcyjnego. Liczba klas wynika z kombinacji pomiędzy liczbą zwartych zwojów w trzech fazach maszyny. Na potrzeby prowadzonych badań, przygotowano wyniki, które obejmowały konfiguracje zwarć międzyzwojowych od 0 do 10 zwartych zwojów w każdej z trzech faz badanej maszyny. Wyniki badań zaprezentowano w kolejnych podrozdziałach. Podczas prowadzonych badań, określono wpływ struktury konwolucyjnej sieci neuronowej na jakość klasyfikacji zwarć międzyzwojowych silnika indukcyjnego. Opisano procedurę trenowania modeli głębokiej sieci neuronowej. Ponadto przeanalizowano wpływ typu sygnału diagnostycznego na wyniki klasyfikacji. Dodatkowo, porównano metody strojenia hiperparametrów konwolucyjnej sieci neuronowej oraz przedstawiono ich wpływ na wyniki klasyfikacji zwarć międzyzwojowych. Do utworzenia modeli konwolucyjnej sieci neuronowej wraz z wizualizacją wyników i struktury sieci, a także do strojenia hiperparametrów modelu, przygotowano oprogramowanie własne. Oprogramowanie wraz z interfejsem użytkownika zostało napisane w języku Python z wykorzystaniem, między innymi, bibliotek TensorFlow, TensorBoard oraz Keras. Na rysunku. 5.20 przedstawiono interface graficzny opracowanego oprogramowania.



Rys. 5.20. Interface użytkownika oprogramowania własnego

Opracowane oprogramowanie umożliwia wybór wartości hiperparametrów, wybór ścieżki danych do wczytania, wyświetlanie informacji o wynikach treningu ale również wczytanie modelu z pliku zewnętrznego.

5.5.2 Bazowa struktura konwolucyjnej sieci neuronowej do klasyfikacji zwarć międzyzwojowych uzwojenia stojana silnika indukcyjnego

W pierwszym kroku projektowania struktury sieci konwolucyjnej opracowano bazową strukturę modelu splotowej sieci neuronowej. Najważniejsze informacje o strukturze opracowanej sieci przedstawiono w tabeli 5.7. W pierwszej kolumnie przedstawiono typ zastosowanej warstwy, w następnej kolumnie liczbę warstw, natomiast w ostatniej kolumnie znajduje się opis zadania realizowanego przez warstwę.

Tabela 5.7 Warstwy konwolucyjnej sieci neuronowej

Typ warstwy	Liczba warstw	Opis
Warstwy konwolucyjne	6	Ekstrakcja cech z użyciem losowo wybranych filtrów konwolucyjnych
Warstwy	6	Normalizacja wsadowa aktywacji w celu stabilizacji

normalizujące		uczenia
Warstwy łączące	2	Zmniejszenie wymiarowości
Warstwy spłaszczające	1	Redukcja rozmiaru tensora do wektora
Warstwy porzucające	2	Porzucenie, w celu zmniejszenia ryzyka przeuczenia
Warstwy w pełni połączone	2	Warstwy w pełni połączone, wnioskowanie

Parametry poszczególnych warstw sieci neuronowych, zwłaszcza warstw konwolucyjnych, są związane z typem oraz wymiarem danych wejściowych do sieci. Pomimo tego, że konwolucyjne sieci neuronowe kojarzone są głównie z takimi zagadnieniami jak:

- klasyfikacja obrazów,
- detekcja obiektów,
- segmentacja obrazu,
- przetwarzanie obrazów medycznych,
- rozpoznawanie twarzy,
- generowanie obrazu,
- rozpoznawanie ruchu,
- rozpoznawanie mowy,
- klasyfikacja dźwięków,
- generowanie dźwięków,
- redukcja szumów,
- czy rozpoznawanie sygnałów,

to mogą być również stosowane do rozpoznawania wzorców na nieprzetworzonych danych prezentowanych, np. w dziedzinie czasu lub częstotliwości.

W celu porównania wpływu typu danych wejściowych do sztucznej sieci neuronowej, zbadano skuteczność klasyfikacji uszkodzeń uzwojenia stojana z wykorzystaniem modelu konwolucyjnej sieci neuronowej trenowanej na dwóch typach danych wejściowych. Dane zostały przygotowane na podstawie przebiegów prądów fazowych, obliczonych z wykorzystaniem polowo-obwodowego modelu zjawisk elektromagnetycznych. Dane treningowe podzielono na dwie kategorie:

- sygnały w postaci dyskretnej w dziedzinie czasu oraz częstotliwości,

- obrazy bitmapowe przebiegów dyskretnych w dziedzinie czasu i częstotliwości.

W ramach badań, podczas etapu budowania baz danych treningowych, na podstawie modelu polowego otrzymano 16000 wyników dla 1331 konfiguracji zwarć międzyzwojowych uzwojenia stojana silnika indukcyjnego.

Dodatkowo, sprawdzono wpływ metod przetwarzania sygnału na wyniki klasyfikacji uszkodzeń uzwojenia stojana silnika indukcyjnego. Otrzymane wyniki z modelu polowego oraz wyniki otrzymane podczas badań eksperymentalnych, poddano dyskretnej transformacji Fouriera oraz ciągłej transformacji falkowej. Otrzymane wyniki analizy umożliwiają wykrywanie zmian w czasie i częstotliwości badanego sygnału. Zastosowane metody przetwarzania sygnałów omówiono w rozdziale 2.2. Poniżej przedstawiono rodziny falek wraz z wyszczególnieniem jąder transformacji falkowej wykorzystanych podczas dekompozycji sygnału:

- *Gaussian wavelets* (gaus) - wykorzystują pochodne funkcji Gaussa, charakteryzują się efektywną lokalizacją w dziedzinie czasu. Z tej rodziny falek w badaniach wykorzystano następujące falki: gaus1, gaus8.
- *Complex Gaussian wavelets* (cgau) - wykorzystywane w analizie sygnałów, bazują na liczbach zespolonych. Stanowią pochodne funkcji Gaussa, umożliwiając tym samym analizę w dziedzinie częstotliwości i czasu. Z tej rodziny falek w badaniach wykorzystano następujące falki: cgau1, cgau8.
- *Morlet wavelet* (morl) - reprezentuje kombinację funkcji sinusoidalnej z oknem Gaussa. Jako okno Gaussa można rozumieć funkcję, której celem jest modyfikacja sygnałów w dziedzinie czasu, by zredukować zniekształcenia w analizie częstotliwościowej, które mogą wystąpić wskutek skończonej długości sygnału. Z tej rodziny falek w badaniach wykorzystano falkę morl.
- *Complex Morlet wavelets* (cmor) - reprezentują kombinację funkcji sinusoidalnej (w której występują składniki w dziedzinie liczb zespolonych) z oknem Gaussa. Z tej rodziny falek w badaniach wykorzystano falkę cmor1.

- *Frequency B-Spline wavelets* (fbsp) - cechuje je zdolność do reprezentowania sygnałów w domenie częstotliwości w sposób ciągły. Stosowane są w analizie wielorozdzielczej, ze szczególnym zastosowaniem w cyfrowym przetwarzaniu sygnałów. Z tej rodziny falek w badaniach wykorzystano falekę fbsp.
- *Mexican hat wavelet* (mexh) - do tworzenia tej grupy falek wykorzystuje się drugie pochodne funkcji Gaussa. Z tej rodziny falek w badaniach wykorzystano falekę mexh.
- *Shannon wavelets* (shan) - wykorzystują funkcje znormalizowanego sinusa ($\text{sinc}(x)$), oferując wysoką rozdzielczość częstotliwościową. Ich ograniczenie w dziedzinie czasu wynika z szerokości zastosowanego okna. Z tej rodziny falek w badaniach wykorzystano falekę shan.

Strukturę modelu głębokiej sieci neuronowej, wykorzystanej podczas badań wstępnych, z uwzględnieniem najważniejszych parametrów warstw oraz kolejności ich połączenia, przedstawiono odpowiednio w tabeli 5.8 oraz na rysunku 5.21.


Tabela 5.8 Struktura głębokiej sieci neuronowej - dane treningowe: sygnały w postaci dyskretnej w dziedzinie czasu i częstotliwości

Nazwa warstwy	Opis/rola	Parametry
Konwolucyjna 1	Ekstrakcja cech	Liczba filtrów: 64 Rozmiar filtrów: 2x2 Funkcja aktywacji: ReLU Dopełnienie: Same Krok: 1x1
Normalizująca 1	Normalizacja wsadowa	Pęd: 0.99 Epsilon: 0.1
Konwolucyjna 2	Ekstrakcja cech	Liczba filtrów: 64 Rozmiar filtrów: 2x2 Funkcja aktywacji: ReLU Dopełnienie: Same Krok: 1x1
Normalizująca 2	Normalizacja wsadowa	Pęd: 0.99 Epsilon: 0.1
Konwolucyjna 3	Ekstrakcja cech	Liczba filtrów: 64 Rozmiar filtrów: 2x2 Funkcja aktywacji: ReLU Dopełnienie: Same Krok: 1x1
Łącząca 1	Redukcja wymiaru	Rozmiar 2x2 Krok: 2x2 Dopełnienie: Valid
Normalizująca 3	Normalizacja wsadowa	Pęd: 0.99

K. Górny. Metody uczenia maszynowego w diagnostyce uzwojenia stojana silnika indukcyjnego z wykorzystaniem polowego modelu zjawisk elektromagnetycznych

		Epsilon: 0.1
Konwolucyjna 4	Ekstrakcja cech	Liczba filtrów: 64 Rozmiar filtrów: 2x2 Funkcja aktywacji: ReLU Dopełnienie: Same Krok: 1x1
Normalizująca 4	Normalizacja wsadowa	Pęd: 0.99 Epsilon: 0.1
Konwolucyjna 5	Ekstrakcja cech	Liczba filtrów: 64 Rozmiar filtrów: 2x2 Funkcja aktywacji: ReLU Dopełnienie: Same Krok: 1x1
Normalizująca 5	Normalizacja wsadowa	Pęd: 0.99 Epsilon: 0.1
Konwolucyjna 6	Ekstrakcja cech	Liczba filtrów: 64 Rozmiar filtrów: 2x2 Funkcja aktywacji: ReLU Dopełnienie: Same Krok: 1x1
Łącząca 2	Redukcja wymiaru	Rozmiar: 2x2 Krok: 2x2 Dopełnienie: Valid
Normalizująca 6	Normalizacja wsadowa	Pęd: 0.99 Epsilon: 0.1
Splaszczająca	Konwersja na wektor	
Porzucająca 1	Porzucenie	Współczynnik porzucenia: 0.3
W pełni połączona 1	Klasyfikacja	Liczba neuronów: 2048 Funkcja aktywacji: ReLU
Porzucająca 2	Porzucenie	Współczynnik porzucenia: 0.3
W pełni połączona 2	Klasyfikacja	Liczba neuronów: 1331 Funkcja aktywacji: Softmax

Struktura sieci konwolucyjnej



Rys. 5.21. Wizualizacja struktury sieci neuronowej

Dodatkowe parametry wykorzystane podczas treningu sieci przedstawia tabela 5.9.

Tabela 5.9. Dodatkowe parametry uczenia

Parametr	Wartość
Optymalizator	ADAM
Funkcja straty	Sparse Categorical Crossentropy
Liczba epok	300
Liczba przykładów we wsadzie	64
Regularyzacja wag	L2
Rozmiar danych wejściowych	64x64

Podczas badań, w celu ograniczenia efektu przeuczenia sieci zastosowano metodę wczesnego zatrzymania. Dlatego też mimo, że hiperparametr określający maksymalną liczbę epok podczas treningu został ustawiony na wartość 300, to wyniki dotyczące trenowania modeli konwolucyjnej sieci neuronowej mogą nie uwzględniać wszystkich epok.

Zastosowaną funkcję straty (tabela 5.9), można zapisać jako:

$$SCCE = -\frac{1}{N} \sum_{i=1}^N \log(\hat{y}_{i,y_i}), \quad (5.20)$$

gdzie: N to liczba przykładów uczących, y_i to prawidłowa etykieta (liczba całkowita reprezentująca klasę) dla i -tej próbki, a \hat{y}_{i,y_i} to przewidywane prawdopodobieństwo, że i -ta próbka należy do prawidłowej klasy y_i .

Wybór funkcji straty wynika ze sposobu kodowania klas. Na etapie wstępnego przetwarzania danych do trenowania sieci, klasy zostały zakodowane jako wektor składający się z dodatnich wartości całkowitych z zakresu od 0 do 1330, w którym każda wartość odpowiadała jednej z konfiguracji zwarć międzyzwojowych. Dla przykładu, klasa 0 odpowiada konfiguracji „0 0 0”, przy czym pierwsza liczba oznacza liczbę zwartych zwojów w fazie A , druga liczba to liczba zwartych zwojów w fazie B natomiast trzecia liczba to liczba zwartych zwojów w fazie C . Ostatnią klasą w przygotowanym zbiorze jest klasa 1330, która odpowiada konfiguracji „10 10 10”, tj. po 10 zwartych zwojów w każdym uzwojeniu fazowym.

Przetwarzanie sygnału diagnostycznego z wykorzystaniem przekształcenia Fouriera oraz przekształcenia falkowego pozwoliło na utworzenie trzech niezależnych baz danych treningowych. W tabeli 5.10 przedstawiono liczbę przykładów uczących wchodzącą w skład przygotowanych baz danych.

Tabela 5.10 Konfiguracje przykładów uczących: dane uczące – sygnał dyskretny przebiegów prądów fazowych


Typ danych	Moment obciążenia (T_L)	Liczba przykładów
Sygnał dyskretny przebiegów prądów fazowych prądów fazowych	$T_L = 0 \text{ Nm}$	58 616
	$T_L = T_N = 19.56 \text{ Nm}$	58 616
Przekształcenie Fouriera	$T_L = 0 \text{ Nm}$	175 848
	$T_L = T_N = 19.56 \text{ Nm}$	175 848
Przekształcenie falkowe	$T_L = 0 \text{ Nm}$	395 658
	$T_L = T_N = 19.56 \text{ Nm}$	395 658

Dane treningowe w każdej z wymienionych w tabeli 5.10 baz danych podzielono na zbiór treningowy i walidacyjny. Zbiór treningowy składał się z 80% wszystkich danych z bazy i zawiera przykłady, które są dostarczane algorytmowi uczącemu w celu dostosowania wag lub parametrów modelu. Zbiór treningowy stanowi bazę dla modelu, na podstawie której model ma się nauczyć wzorców występujących w danych. Zbiór walidacyjny składał się z 20% wszystkich danych z bazy i używany był do oceny jakości klasyfikacji modelu podczas treningu. W celu weryfikacji zdolności modelu do generalizacji po każdej epoce, model był oceniany na zbiorze walidacyjnym. Oprócz zbioru treningowego i walidacyjnego utworzono również zbiór danych testowych. W skład zbioru danych testowych wchodziły dane, które nie były wykorzystywane podczas treningu. Zbiór danych testowych składał się z przykładów otrzymanych podczas badań eksperymentalnych. Aby zachować czytelność w rozdziale poniżej przedstawiono wyniki dla procesu uczenia sieci. Wyniki na danych testowych zostaną przedstawione zbiorczo na końcu rozdziału.

Parametry jednostki obliczeniowej, na której przeprowadzono trenowanie konwolucyjnej sieci neuronowej, to: procesor Intel i9 9900k 5 GHz, karta graficzna Nvidia GeForce RTX 2080 Ti, pamięć RAM 64 GB. Do trenowania konwolucyjnej sieci neuronowej wykorzystano obliczenia równoległe z zastosowaniem GPGPU.

Dane wejściowe – sygnały dyskretnie

Podstawą oceny modelu podczas trenowania były wartości funkcji straty oraz metryka dokładność. Stratę oraz dokładność w funkcji epok treningu konwolucyjnej sieci neuronowej, uczonej na danych wejściowych w postaci wartości chwilowych prądów fazowych maszyny, przedstawia rysunek 5.22.



Rys. 5.22. Dokładność i strata w funkcji epok – dane wejściowe: sygnał dyskretny przebiegów prądów fazowych prądu fazowego silnika klatkowego

Na osi odciętych na rysunku 5.22 zaznaczono numery epok treningowych, natomiast na osi rzędnych wartości dokładności oraz strat. Linie ciągłe odpowiadają wartościom dla zbioru treningowego, natomiast linie przerywane dla zbioru walidacyjnego. Dokładność dla danych treningowych, jak i walidacyjnych w miarę postępu treningu rośnie, osiągając wartości maksymalne 0.862 i 0.829 odpowiednio dla zbioru treningowego oraz walidacyjnego. Kształty krzywych dokładności o przebiegu rosnącym niemonotonicznym wskazują skuteczność procesu uczenia sieci. Strata na zbiorze treningowym i walidacyjnym o przebiegu malejącym niemonotonicznym, osiąga wartości minimalne 0.886 i 0.885, odpowiednio dla zbioru treningowego i walidacyjnego.

Wzrost wartości dokładności w funkcji epok jest zgodny z oczekiwaniami, ponieważ sieć neuronowa, w miarę postępu treningu, maksymalizuje liczbę poprawnie zaklasyfikowanych danych wejściowych, maksymalizując dokładność klasyfikacji.

Wyższe wartości dokładności na zbiorze treningowym, w stosunku do zbioru walidacyjnego, mogłyby wskazywać na możliwe przeuczenie modelu. Przeuczenie występuje, kiedy model zbyt dobrze dopasowuje się do danych treningowych tracąc tym samym zdolność do generalizacji co utrudnia poprawną klasyfikację nowych danych wejściowych (tj. danych spoza bazy treningowej). Ogólnie wysoka wartość dokładności i niska wartość straty na zbiorze treningowym wskazują, że model dobrze dopasowuje się do danych treningowych, ale może mieć trudności z generalizacją na nowych danych. Niemniej niewielkie różnice w dokładności na zbiorze treningowym

i walidacyjnym pozwalają wnioskować, że opracowany model może osiągać zadowalające wyniki zarówno na zbiorze danych treningowych jak i na zbiorze danych walidacyjnych. Z uwagi na zastosowaną metodę wczesnego zatrzymania, proces uczenia sieci neuronowej został wstrzymany w 88. epoce, kiedy zaobserwowano stabilizację wartości zarówno dokładności jak i funkcji błędu, co wskazywało na osiągnięcie stanu zbliżonego do konwergencji.

Z uwagi na słabą czytelności oraz utrudnienia w interpretacji wyników w postaci graficznej, wynikające z dużej liczby klas, zrezygnowano z prezentacji wyników w postaci macierzy pomyłek oraz krzywych ROC. Wyniki klasyfikacji zwarć międzyzwojowych uzwojenia stojana na zbiorze walidacyjnym przedstawiono zbiorczo poniżej, z wykorzystaniem metryk takich jak precyzja pozytywna, czułość i F1-score o których więcej można przeczytać w rozdziale 4.4. Wyniki przedstawiono w tabelach od 5.11 do 5.14. W tabeli 5.11 przedstawiono średnie wartości metryk. Tabela 5.12 zawiera informację o najskuteczniej sklasyfikowanych konfiguracjach zwarć międzyzwojowych uzwojenia stojana silnika indukcyjnego. Tabela 5.13 zawiera informację o najmniej skutecznie sklasyfikowanych konfiguracjach zwarć międzyzwojowych silnika indukcyjnego, natomiast w tabeli 5.14 przedstawiono wyniki dla kwantyli. Dla skrócenia zapisu, precyzja pozytywna w dalszej części rozdziału nazywana jest „precyzją”. Dodatkowo, w tabelach, oprócz numeru klasy, w nawiasie podano odpowiadającą numerowi klasy konfigurację zwarć.

W tabeli 5.11 przedstawiono średnie wartości metryk precyzji, czułości oraz F1-Score. Średnie wartości metryk wskazują na wysoką skuteczność modelu w klasyfikacji zwarć międzyzwojowych uzwojenia stojana. Wartości średniej makro i średniej ważonej są zbliżone, co sugeruje, że model radzi sobie dobrze zarówno z klasami równoważnymi (takimi, w których liczba przykładów jest zbliżona), jak i nierównoważnymi (takimi, w których liczba przykładów w poszczególnych klasach jest znacząco różna). Wysokie wartości precyzji i czułości w przypadku średniej makro oznaczają, że model dobrze radzi sobie z klasyfikacją bez brania pod uwagę liczebności przykładów w danej klasie. Natomiast wysokie wartości metryk dla średniej ważonej, uwzględniającej liczebność przykładów występujących w danej klasie, wskazuje na stabilność klasyfikacji modelu w kontekście całego zbioru danych.

Tabela 5.11 Średnie wartości metryk – sygnał dyskretny przebiegów prądów fazowych

Rodzaj Średniej	Precyzja	Czułość	F1-Score
Średnia Makro	0.815	0.811	0.813
Średnia Ważona	0.809	0.805	0.807

W tabeli 5.12 zestawiono wyniki metryk dla pięciu najsukuteczniej sklasyfikowanych konfiguracji zwarć międzyzwojowych w zestawie danych. Najlepsze konfiguracje osiągnęły wartość precyzji w zakresie od 0.961 do 0.979, wartość czułości od 0.907 do 0.947 natomiast wartość metryki F1-Score od 0.933 do 0.957. Wysokie wartości zaprezentowanych metryk mogą wynikać z dużej liczby przykładów w tych klasach oraz wyraźnych wzorców cech, które model konwolucyjnej sieci neuronowej jest w stanie skutecznie wyekstrahować.

Tabela 5.12 Metryki dla pięciu klas o najlepszej skuteczności klasyfikacji – sygnał dyskretny przebiegów prądów fazowych

Klasa (konfiguracja)	Precyzja	Czułość	F1-Score
688 (4 6 5)	0.961	0.907	0.933
871 (6 10 10)	0.951	0.927	0.939
953 (6 8 6)	0.956	0.940	0.948
1179 (8 7 10)	0.968	0.947	0.957
1198 (8 8 9)	0.979	0.915	0.946

W tabeli 5.13 przedstawiono wyniki metryk dla pięciu najmniej skutecznie sklasyfikowanych konfiguracji zwarć międzyzwojowych w zestawie danych. Jak można zauważyć, precyzja dla tych konfiguracji wyniosły od 0.307 do 0.477, czułość od 0.276 do 0.388 a F1-Score od 0.329 do 0.402. Niskie wartości metryk dla tych klas mogą wynikać z ich niewielkiej reprezentatywności w zbiorze danych, większej złożoności wzorców do wyekstrahowania, lub zbyt dużego podobieństwa tych klas do innych. W modelach sztucznych sieciach neuronowych, dla klas z niewielką liczbą przykładów w określonym zbiorze danych, często może dochodzić do problemów z niedouczeniem, co prowadzi do niższych wartości metryk, np. precyzji i czułości. Zauważyć można, że w tabeli 5.12 prezentującej najsukuteczniej sklasyfikowane konfiguracje znajdują się konfiguracje o większej liczbie zwartych zwojów niż w tabeli 5.13 prezentującej najmniej skutecznie klasyfikowane konfiguracje. Gorsza jakość klasyfikacji zwarć w przypadku stosunkowo niedużej liczby zwartych zwojów może wynikać z mniejszego wpływu zwarć międzyzwojowych, we wczesnym etapie ich występowania, na przebiegi prądów fazowych silników indukcyjnych, a zatem ekstrakcję cech przez warstwy konwolucyjne.

Tabela 5.13 Metryki dla pięciu klas o najgorszej skuteczności klasyfikacji – sygnał dyskretny przebiegów prądów fazowych

Klasa (konfiguracja)	Precyzja	Czułość	F1-Score
125 (1 0 3)	0.416	0.388	0.402
202 (1 6 3)	0.477	0.276	0.350
236 (1 9 4)	0.337	0.322	0.329
413 (2 3 5)	0.451	0.284	0.349
553 (3 5 2)	0.307	0.371	0.336


W tabeli 5.14 zawarto wartości kwantyli dla metryk precyzji, czułości i F1-Score. Kwantyl Q1 dla metryki precyzja wyniosły 0.684, dla czułości 0.683 natomiast dla F1-Score 0.666, co wskazuje na istnienie przypadków, w których model ma znaczące trudności. Wartość precyzji dla mediany (kwantyl Q2) wyniosły 0.822, dla czułość 0.810, a dla F1-Score 0.808, co sugeruje, że model osiąga solidne wyniki w większości przypadków. Wartości kwantyla Q3, dla którego precyzja równa jest 0.944, czułość 0.944, a F1-Score 0.941, dowodzą, że dla najskuteczniej klasyfikowanych konfiguracji klas opracowany model wykazuje bardzo wysoką skuteczność.

Tabela 5.14 Wartości kwantyli dla metryk – sygnał dyskretny przebiegów prądów fazowych

Kwantyl	Precyzja	Czułość	F1-Score
25% (Q1)	0.684	0.683	0.666
50% (Q2)	0.822	0.810	0.808
75% (Q3)	0.944	0.944	0.941

W ramach realizowanego etapu zbadano wpływ danych wejściowych na wyniki klasyfikacji zwarć międzyzwojowych uzwojenia stojana trójfazowego silnika indukcyjnego. W tym celu dane w postaci sygnału dyskretnego przebiegów prądów fazowych poddano transformacie Fouriera oraz transformacie falkowej.

Stratę oraz dokładność w funkcji epok dla danych treningowych, otrzymanych w wyniku przekształcenia Fouriera oraz przekształcenia falkowego przebiegu prądów fazowych, zaprezentowano odpowiednio na rysunku 5.23.



Rys. 5.23. Dokładność i strata w funkcji epok a) dane wejściowe – wyniki transformaty Fouriera, b) dane wejściowe – wyniki transformaty falkowej

Jak można zauważyć, z wyników procesu trenowania modeli konwolucyjnej sieci neuronowej przedstawionych na rysunku 5.23, zarówno dokładność, jak i strata dla modeli uczonych na danych uzyskanych z przekształcenia Fouriera i przekształcenia falkowego, osiągają wyższe wartości w krótszym czasie niż w przypadku modelu trenowanego na sygnale dyskretnym przebiegów prądu fazowego. Krzywe przedstawione na rysunku 5.23 sugerują szybszą konwergencję oraz stabilizację dokładności i straty w przypadku modelu uczonego na danych w postaci wyników

transformaty Fouriera. Jak wynika z rysunku 5.22, model trenowany na danych w postaci sygnału dyskretnego przebiegów prądu fazowego silnika indukcyjnego, potrzebuje więcej epok, aby osiągnąć stabilizację, a jego dokładność na zbiorze walidacyjnym jest niższa niż w przypadku danych po przekształcenia Fouriera. Zastosowanie transformaty Fouriera może być bardziej efektywne i ostatecznie wpływać na poprawę wydajności modelu klasyfikacyjnego zwarcia międzyzwojowe silnika indukcyjnego, w porównaniu z modelami trenowanymi na danych w postaci wyników transformaty falkowej oraz danych nieprzetworzonych. Dane po przekształceniu Fouriera pozwalają modelowi szybciej osiągnąć konwergencję, a wyniki są bardziej stabilne. W przypadku treningu na danych prezentujących wyniki transformaty falkowej, mimo tego, że liczba epok potrzebna do osiągnięcia maksymalnej wartości dokładności i minimalnej wartości straty jest znacząco mniejsza, w odniesieniu do treningu na danych nieprzetworzonych, to maksymalna wartość dokładności na zbiorze walidacyjnym dla modelu trenowanego na danych poddanych przekształceniu falkowym jest nieznacznie mniejsza i wynosi 0.818.

Na podstawie przedstawionych krzywych uczenia, można zauważyć, że model wykorzystujący jako dane wejściowe wyniki transformaty Fouriera, wykazuje mniejsze wahania wartości dokładności i straty na zbiorze walidacyjnym, w porównaniu do modelu trenowanego na wynikach transformaty falkowej. Mniejsze wahania wartości na zbiorze walidacyjnym sugerują, że model uczy się w sposób bardziej spójny i jest mniej podatny na przetrenowanie niż model wykorzystujący wyniki transformaty falkowej. Ponadto, maksymalna wartość dokładności na zbiorze walidacyjnym modelu uczonego na podstawie wyników transformaty Fouriera jest wyższa i wynosi 0.832, zarówno od tej dla modelu wykorzystującego nieprzetworzone dane (0.829), jak również dla modelu wykorzystującego wyniki transformaty falkowej (0.818), co może wskazywać na potencjalnie lepszą zdolność do generalizacji na nowych danych.

Wybrane metryki modelu trenowanego na podstawie danych w postaci wyników transformaty Fouriera, przedstawiają tabele 5.15, 5.16, 5.17 oraz 5.18. Metryki dla modelu trenowanego na podstawie danych w postaci wyników przekształcenia falkowego przedstawiają tabele 5.19, 5.20, 5.21 oraz 5.22.

W tabeli 5.15 przedstawiono średnie wartości metryk, uzyskane na danych wejściowych poddanych transformacji Fouriera. Wartości metryk są nieco wyższe niż

dla danych uczących w postaci sygnału dyskretnego, co sugeruje, że transformata Fouriera może poprawić wydajność klasyfikacji modelu.

Tabela 5.15 Średnie wartości metryk - dane wejściowe: wyniki transformaty Fouriera

Rodzaj Średniej	Precyzja	Czułość	F1-Score
Średnia Makro	0.820	0.812	0.816
Średnia Ważona	0.814	0.806	0.810

Podobnie jak w przypadku pięciu najskuteczniej sklasyfikowanych konfiguracji przedstawionych w tabeli 5.12, pięć najlepszych konfiguracji zwarć międzyzwojowych dla danych wejściowych poddanych przekształceniu Fouriera, przedstawionych w tabeli 5.16, również osiągnęło wysokie wartości dla metryk. W tym przypadku, również są to konfiguracje zwarć z większą liczbą zwartych zwojów. W przypadku najskuteczniej sklasyfikowanych klas, zakresy zmienności dla metryki precyzja to od 0.953 do 0.983, dla czułości od 0.910 do 0.949 natomiast dla F1-Score od 0.938 do 0.958. Wartości metryk powyżej 0.9, wskazują na bardzo dużą skuteczność modelu w przypadku klasyfikacji reprezentatywnych klas. Jest to prawdopodobnie wynik wyraźnych wzorców w danych transformaty Fouriera, które model jest w stanie skutecznie rozpoznawać.

Tabela 5.16 Metryki dla pięciu klas o najlepszej skuteczności klasyfikacji - dane wejściowe: wyniki transformaty Fouriera

Klasa (konfiguracja)	Precyzja	Czułość	F1-Score
1075 (7 8 7)	0.968	0.910	0.938
1151 (8 4 6)	0.953	0.928	0.940
1205 (8 9 5)	0.960	0.940	0.950
1206 (8 9 6)	0.967	0.949	0.958
1295 (9 6 7)	0.982	0.915	0.947

W tabeli 5.17 przedstawiono wyniki modelu dla najmniej skutecznie sklasyfikowanych konfiguracji zwarć międzyzwojowych uzwojenia stojana uczonego z wykorzystaniem danych wejściowych, będących wynikami transformaty Fouriera. Wyniki są porównywalne do tych z tabeli 5.13, ale zauważalna jest nieco wyższa precyzja i czułość, co może wskazywać na poprawę klasyfikacji po przekształceniu Fouriera. Mimo poprawy, wyniki dla najmniej skutecznie sklasyfikowanych konfiguracji mogą sugerować, że wskazane konfiguracje posiadają dużą liczbę cech wspólnych z innymi klasami, co może powodować trudności z ich jednoznacznym sklasyfikowaniem.

Tabela 5.17 Metryki dla pięciu klas o najgorszej skuteczności klasyfikacji – dane wejściowe: wyniki transformaty Fouriera

Klasa (konfiguracja)	Precyzja	Czułość	F1-Score
12 (0 1 1)	0.425	0.389	0.407
39 (0 2 5)	0.485	0.278	0.352
59 (0 4 3)	0.345	0.320	0.332
63 (0 4 7)	0.455	0.290	0.353
232 (1 9 1)	0.308	0.370	0.334

W tabeli 5.18 zestawiono wartości kwantyli dla metryk dla modelu trenowanego na wynikach transformaty Fouriera. Wartości metryk są dla większości wyników wyższe, w porównaniu do modelu trenowanego na danych w postaci wartości chwilowych. Wartości metryk dla kwantyli wynoszą odpowiednio: kwantyl 25% (precyzja 0.689, czułość 0.680, F1-Score 0.670), kwantyl 50% (precyzja 0.823, czułość 0.815, F1-Score 0.811), natomiast kwantyl 75% (precyzja 0.944, czułość 0.948, F1-Score 0.945). Otrzymane wyniki wskazują, że przekształcenie Fouriera może poprawić wydajność modelu.

Tabela 5.18 Wartości kwantyli dla metryk – dane wejściowe: wyniki transformaty Fouriera

Kwantyl	Precyzja	Czułość	F1-Score
25% (Q1)	0.689	0.680	0.670
50% (Q2)	0.823	0.815	0.811
75% (Q3)	0.944	0.948	0.945

W tabeli 5.19 zaprezentowano średnie wartości metryk dla modelu trenowanego na podstawie wyników transformaty falkowej. Zarówno średnie wartości makro (precyzja 0.805, czułość 0.798, F1-Score 0.802), jak i średnie wartości ważone (precyzja 0.798, czułość 0.792, F1-Score 0.795) dla wszystkich trzech metryk są niższe niż te uzyskane przez modele trenowane na wynikach transformaty Fouriera i danych w postaci dyskretnych wartości chwilowych przebiegów prądów fazowych, co sugeruje, że przekształcenie falkowe w przypadku klasyfikacji zwarć międzyzwojowych dla prezentowanego modelu sztucznej sieci neuronowej skutkuje zmniejszeniem efektywności klasyfikacji zwarć międzyzwojowych.

Tabela 5.19 Średnie wartości metryk – dane wejściowe: wyniki przekształcenia falkowego

Rodzaj Średniej	Precyzja	Czułość	F1-Score
Średnia Makro	0.805	0.798	0.802
Średnia Ważona	0.798	0.792	0.795

W tabeli 5.20 zestawiono, wyniki dla pięciu najskuteczniej sklasyfikowanych konfiguracji zwarć międzyzwojowych dla modelu trenowanego na wynikach

transformaty falkowej. Wartości metryk dla precyzji od 0.947 do 0.975, czułość od 0.900 do 0.935 i F1-Score od 0.927 do 0.942. Pomimo tego, że otrzymane wyniki nadal przekraczają wartość 0.9, to wykazują spadek wartości metryk, co przekłada się na spadek jakości klasyfikacji zwarć międzyzwojowych przed opracowany model.

Tabela 5.20 Metryki dla pięciu klas o najlepszej skuteczności klasyfikacji – dane wejściowe: wyniki przekształcenia falkowego

Klasa (konfiguracja)	Precyzja	Czułość	F1-Score
933 (6 6 8)	0.955	0.900	0.927
999 (7 10 8)	0.947	0.920	0.933
1088 (7 9 9)	0.950	0.935	0.942
1256 (9 3 10)	0.960	0.930	0.945
1285 (9 5 8)	0.975	0.905	0.939

W tabeli 5.21 zaprezentowano wyniki dla modelu trenowanego na podstawie danych wejściowych w postaci wyników transformaty falkowej. Otrzymane wyniki dla najmniej skutecznie klasyfikowanych klas są najniższe, w porównaniu z dwoma modelami zaprezentowanymi powyżej. Ponownie, można zauważyć, że najmniej skuteczne w klasyfikacji były konfiguracje dla niewielkiej liczby zwartych zwojów w uzwojeniach silnika indukcyjnego.

Tabela 5.21 Metryki dla pięciu klas o najgorszej skuteczności klasyfikacji – dane wejściowe: wyniki przekształcenia falkowego

Klasa (konfiguracja)	Precyzja	Czułość	F1-Score
0 (0 0 0)	0.415	0.380	0.397
45 (0 3 1)	0.470	0.270	0.340
179 (1 4 2)	0.330	0.310	0.320
184 (1 4 7)	0.445	0.280	0.345
828 (5 8 2)	0.305	0.360	0.330

Analiza wyników przedstawionych w tabeli 5.22, pozwala wnioskować, że model trenowany na danych będącymi wynikami transformaty falkowej, wykazuje pogorszenie wartości metryk, w odniesieniu do dwóch modeli prezentowanych powyżej.

Tabela 5.22 Wartości kwantyli dla metryk – dane wejściowe: wyniki przekształcenia falkowego

Kwantyl	Precyzja	Czułość	F1-Score
25% (Q1)	0.675	0.670	0.660
50% (Q2)	0.815	0.800	0.805
75% (Q3)	0.935	0.940	0.937

Na podstawie analizy porównawczej trzech modeli przedstawionych powyżej, można zauważyć, że model uczony na podstawie wyników transformaty Fouriera


wykazuje najlepsze wyniki, uzyskując najwyższą dokładność (0.832) oraz najwyższe średnie wartości metryk precyzji i czułości w obu kategoriach (makro i ważonej). Model uczony na podstawie sygnału dyskretnego prądów fazowych miał nieco niższą dokładność (0.829), ale wciąż osiągał wysokie wyniki dla wybranych metryk. Model uczony na podstawie wyników transformaty falkowej charakteryzował się najniższymi wartościami metryk, z najniższą dokładnością (0.818), co może wynikać z większej złożoności danych wejściowych lub większej liczby przykładów w zbiorze walidacyjnym, co mogło wpływać na spadek wydajności modelu.

Na podstawie tych wyników, można stwierdzić, że model uczony na podstawie danych wejściowych w postaci wyników transformaty Fouriera, był najbardziej skuteczny w klasyfikacji zwarć międzyzwojowych uzwojenia stojana silnika indukcyjnego. Mimo mniejszej skuteczności klasyfikacji dwóch pozostałych modeli konwolucyjnych sieci neuronowych, otrzymane wyniki były tylko nieznacznie niższe, a dalsza optymalizacja tych modeli mogłaby wpłynąć na poprawę jakości klasyfikacji zwarć międzyzwojowych.

Dane wejściowe – bitmapy

Kolejny etap badań obejmował wyznaczenie metryk dla modelu klasyfikacji zwarć międzyzwojowych uzwojenia stojana uczonego na podstawie bitmap. Utworzono oprogramowanie własne, które na podstawie przebiegów prądów fazowych, otrzymanych z modelu polowego, jak również badań eksperymentalnych, wizualizowało te przebiegi, a następnie zapisywało do plików graficznych. Najważniejsze parametry wygenerowanych bitmap to wymiary wynoszące 2400x1800 pikseli oraz rozdzielczość w pionie i poziomie równe 300 dpi.

Przykładowe przebiegi prądu dla następującej konfiguracji zwarć zwojowych: w fazie A - 9 zwartych zwojów (kolor niebieski), w fazie B - 1 zwarty zwoj (kolor pomarańczowy), a w fazie C - 10 zwartych zwojów (kolor zielony), wykorzystano w procesie trenowania głębokiej sieci neuronowej i przedstawiono na Rys. 5.24. Aby dokładniej przedstawić kształt przebiegów prądu fazowego na Rys. 5.24 ograniczono zakres dziedzin czasu.




Rys. 5.24. Przebiegi prądu fazowego - konfiguracja zwarcia faza A - 9 zwartych zwojów, faza B - 1 zwarty zwoj, faza C - 10 zwartych zwojów

Jak wspomniano, na podstawie polowo-obwodowych modeli trójfazowego silnika indukcyjnego zbudowano zbiór 16000 wyników obliczeń symulacyjnych. Aby ograniczyć wpływ zbyt małej liczby przykładów uczących na wyniki klasyfikacji zwarcia międzyzwojowych, otrzymane przebiegi w formie bitmap poddano augmentacji danych. Augmentacja danych to technika polegająca na generowaniu nowych danych treningowych przez modyfikację już istniejących. Uzyskanie nowych danych odbywa się przez transformacje, takie jak np. przesunięcie, obrót, czy dodawanie szumu do istniejącego obrazu. Ostatecznie, zbiory danych treningowych w postaci bitmap przedstawia tabela 5.23.

Tabela 5.23 Konfiguracje przykładów uczących: dane uczące – wizualizacja wyników w postaci bitmap

Typ danych	Moment obciążenia (T_L)	Liczba przykładów
Sygnał dyskretny przebiegów prądów fazowych prądów fazowych	$T_L = 0 \text{ Nm}$	73 230
	$T_L = T_N = 19.56 \text{ Nm}$	73 230
Transformata Fouriera	$T_L = 0 \text{ Nm}$	146 460
	$T_L = T_N = 19.56 \text{ Nm}$	146 460
Przekształcenie falkowe	$T_L = 0 \text{ Nm}$	548 567
	$T_L = T_N = 19.56 \text{ Nm}$	548 567

Stratę oraz dokładność w funkcji epok treningu konwolucyjnej sieci neuronowej uczonej na danych wejściowych w postaci bitmap prądów fazowych przedstawia rysunek 5.25.



Rys. 5.25 Dokładność i strata w funkcji epok – dane wejściowe: bitmapy ilustrujące przebiegi prądów fazowych silnika indukcyjnego

Na rysunku 5.25 przedstawiono krzywe dokładności i straty na zbiorze treningowym i walidacyjnym modelu konwolucyjnej sieci neuronowej uczonej. Model uczony był na danych wejściowych w postaci bitmap wizualizujących przebieg prądów fazowych silnika indukcyjnego. Krzywa dokładności dla danych treningowych wzrasta od wartości początkowej bliskiej 0, osiągając wartość maksymalną 0.816 w 61 epoce. Krzywa dokładności dla danych walidacyjnych również wzrasta od wartości początkowej bliskiej 0, osiągając wartość maksymalną równą 0.797 w 56 epoce. Kształt krzywych dokładności jest prawidłowy i zgodny z zakładanym dla procesu trenowania modelu konwolucyjnej sieci neuronowej.

Krzywe strat dla zbioru treningowego i walidacyjnego również charakteryzują się kształtem zgodnym ze spodziewanym dla minimalizacji funkcji straty podczas trenowania sztucznej sieci neuronowej. Wartości początkowe straty (dla pierwszej epoki uczenia) osiągają wartość powyżej 4.5 dla zbioru walidacyjnego i powyżej 4.2 dla zbioru treningowego, ale wraz z postępem w procesie trenowania modelu maleją. Minimalna wartość funkcji straty dla zbioru treningowego wynosi 0.851 natomiast dla zbioru walidacyjnego 0.899. Mimo, że krzywe dokładności i strat dla obu zbiorów (treningowego i walidacyjnego) są stosunkowo gładkie i stabilne, to niższa maksymalna wartość dokładności i wyższa minimalna wartość straty niż te dla modelu uczonego na

podstawie sygnału dyskretnego przebiegów prądu fazowego, wskazują na pogorszenie jakości klasyfikacji modelu konwolucyjnej sieci neuronowej.

Porównując wyniki dla wspomnianego modelu, uczonego na podstawie danych wyjściowych w postaci sygnału dyskretnego przebiegów prądu fazowego maszyny, oraz obrazy ilustrujące te przebiegi, można zauważyć, że model uczone na podstawie sygnału dyskretnego wykazuje wyższą dokładność dla danych walidacyjnych oraz charakteryzuje się stabilniejszym procesem uczenia, co można wywnioskować na podstawie kształtu krzywych, zarówno dla dokładności, jak i straty modelu. A to z kolei może mieć wpływ na lepszą generalizację i potwierdza skuteczność procesu treningowego.

Metryki dla modelu uczonego na podstawie danych, w postaci bitmap ilustrujących przebiegi prądów fazowych maszyny, przedstawiono w tabelach 5.24, 5.25, 5.26 oraz 5.27.

W tabeli 5.24 przedstawiono średnie wartości metryk oceny modelu uczonego na danych wejściowych w postaci bitmap przebiegów prądów fazowych. Metryki te obejmują precyzję, czułość oraz F1-Score, zarówno w ujęciu średniej makro, jak i średniej ważonej. Średnia makro obliczana jest jako średnia arytmetyczna metryk dla każdej klasy, traktując każdą klasę równorzędnie, niezależnie od jej liczebności. Dla tej średniej, precyzja wynosi 0.785, czułość 0.780, a F1-Score 0.782. Z kolei średnia ważona uwzględnia liczebność każdej klasy, dając większą wagę klasom o większej liczbie próbek, co pozwala na bardziej reprezentatywną ocenę modelu dla nierównomiernie rozłożonych danych. Dla średniej ważonej, precyzja wynosi 0.780, czułość 0.775, a F1-Score 0.777. Porównując wartości średniej makro i średniej ważonej pomiędzy tym modelem a modelami przedstawionymi powyżej, można zauważyć, że charakteryzuje się on najniższymi wartościami dla wspomnianych metryk.

Tabela 5.24 Średnie wartości metryk – dane wejściowe: bitmapy ilustrujące przebiegi prądów fazowych

Rodzaj Średniej	Precyzja	Czułość	F1-Score
Średnia Makro	0.785	0.780	0.782
Średnia Wazona	0.780	0.775	0.777

W tabeli 5.25 zaprezentowano metryki precyzji, czułości oraz F1-Score dla pięciu najskuteczniej sklasyfikowanych konfiguracji zwarć międzyzwojowych. Model trenowany był na podstawie bitmap przebiegów prądu fazowego. Wysokie wartości przedstawionych metryk, tak jak w przypadku modeli przedstawionych powyżej,

wskazują na skuteczną klasyfikację konfiguracji zwarć międzyzwojowych, w których zwarceniu uległa większa liczba zwartych zwojów uzwojenia stojana. Niemniej jednak, w przypadku tego modelu sztucznej sieci neuronowej, wartości te są najniższe, w porównaniu z wynikami wszystkich modeli zaprezentowanych powyżej.

Tabela 5.25 Metryki dla pięciu klas o najlepszej skuteczności klasyfikacji – dane wejściowe: bitmapy ilustrujące przebiegi prądów fazowych

Klasa (konfiguracja)	Precyzja	Czułość	F1-Score
596 (3 9 10)	0.950	0.890	0.919
945 (6 7 9)	0.940	0.910	0.925
1044 (7 5 9)	0.945	0.925	0.935
1194 (8 8 5)	0.955	0.920	0.937
1289 (9 6 10)	0.970	0.900	0.934

W tabeli 5.26 przedstawiono metryki dla pięciu najmniej skutecznie sklasyfikowanych konfiguracji zwarć międzyzwojowych. Model trenowany był na podstawie bitmap przebiegów prądu fazowego. Wartość precyzji dla prezentowanego modelu w przypadku najmniej skutecznie sklasyfikowanych konfiguracji, zmienia się w zakresie od 0.295 do 0.460, wartość czułości od 0.260 do 0.370 a wartość metryki F1-Score od 0.310 do 0.384. Niższe wartości metryk dla przedstawionych konfiguracji wskazują na trudności modelu w dokonywaniu prawidłowej klasyfikacji tych specyficznych konfiguracji przebiegów prądów fazowych, co może sugerować potrzebę dalszej optymalizacji modelu dla tych przypadków.

Tabela 5.26 Metryki dla pięciu klas o najgorszej skuteczności klasyfikacji – dane wejściowe: bitmapy ilustrujące przebiegi prądów fazowych

Klasa	Precyzja	Czułość	F1-Score
498 (3 1 2)	0.400	0.370	0.384
617 (4 1 1)	0.460	0.260	0.333
729 (5 0 2)	0.320	0.300	0.310
1002 (7 2 1)	0.435	0.270	0.333
1006 (7 2 4)	0.295	0.350	0.320


W tabeli 5.27 przedstawiono wartości kwantyli (25%, 50% i 75%) dla metryk precyzji, czułości oraz F1-Score, co pozwala na zrozumienie rozkładu wyników modelu na różnych klasach. Wartość precyzji dla kwantyla 25% wynosi 0.665, dla czułości 0.660, a dla F1-Score 0.665. Wartość precyzji kwantyla 50% (mediana) wynosi 0.800, dla czułości 0.785, a dla F1-Score 0.792. Wartość precyzji dla kwantyla 75% wynosi 0.925, dla czułości 0.930, a dla F1-Score 0.927. Wartości kwantyli wskazują na to, że większość klas konfiguracji zwarć międzyzwojowych jest klasyfikowana z wysoką

skutecznością, jednak istnieją również konfiguracje, które osiągają niższe wartości metryk, co jest widoczne w kwantylu 25%.


Tabela 5.27 Wartości kwantyli dla metryk – dane wejściowe: bitmapy ilustrujące przebiegi prądów fazowych

Kwantyl	Precyzja	Czułość	F1-Score
25% (Q1)	0.665	0.660	0.655
50% (Q2)	0.800	0.785	0.792
75% (Q3)	0.925	0.930	0.927

Kolejnym etapem było trenowanie modelu na bitmapach ilustrujących wyniki przekształcenia Fouriera oraz przekształcenia falkowego. Na rysunkach 5.26 oraz 5.27 przedstawiono przykładowe dane treningowe, odpowiednio dla przekształcenia Fouriera oraz przekształcenia falkowego.





Rys. 5.26. Dane treningowe w postaci bitmap prezentujących wyniki przekształcenia Fouriera



Rys. 5.27. Dane treningowe w postaci bitmap prezentujących wyniki przekształcenia falkowego

Stratę oraz dokładność w funkcji epok dla danych treningowych w postaci bitmap ilustrujących wyniki transformaty Fouriera oraz transformaty falkowej, przedstawiono odpowiednio na rysunkach 5.28 a) oraz b).





Rys. 5.28. Dokładność i strata w funkcji epok a) bitmapy ilustrujące wyniki transformaty Fouriera, b) bitmapy ilustrujące wyniki transformaty falkowej

Na rysunku 5.28 a), przedstawiono wyniki trenowania modelu sztucznej sieci neuronowej. Sieć trenowana była na podstawie danych wejściowych w postaci bitmap prezentujących wyniki transformaty Fouriera. Dla tego przypadku dokładność dla danych treningowych wzrasta od wartości bliskiej 0, osiągając wartość maksymalną równą 0.834 w 59 epoce. Dokładność na zbiorze walidacyjnym również wzrasta od wartości bliskiej 0, osiągając najwyższą wartość 0.814 w 55 epoce. Krzywe mają typowy wykładniczy wzrost, którego przyrost, w miarę upływu epok, jest coraz mniejszy, wskazując na stabilizację modelu. Strata na zbiorze treningowym maleje, osiągając wartość 0.823 w 59 epoce. Strata na zbiorze walidacyjnym osiąga wartość minimalną równą 0.852 w epoce 55.

Rysunek 5.28 b) przedstawia model trenowany na podstawie danych w postaci bitmap wyników transformaty falkowej. W tym przypadku, dokładność na zbiorze treningowym wzrasta od wartości bliskiej 0, osiągając wartość 0.824 w 57 epoce, natomiast dokładność na zbiorze walidacyjnym wzrasta do wartości 0.794 w epoce 53. Strata na zbiorze treningowym maleje, osiągając wartość minimalną równą 0.849 w epoce 58, a strata na zbiorze walidacyjnym osiąga wartość minimalną równą 0.902 w epoce 53. Krzywe dla tego modelu również wykazują wykładniczy kształt, ale osiągnięte wartości maksymalne dokładności na zbiorze walidacyjnym wskazują na

mniejszą skuteczność klasyfikacji, w porównaniu do modelu uczonego na danych poddanych transformacie Fouriera.

Analiza porównawcza modeli konwolucyjnych sieci neuronowych wykazuje, że model uczony na podstawie danych w postaci bitmap wyników transformaty Fouriera (rysunek 5.28 a)), osiąga wyższą dokładność walidacyjną (0.814), co wskazuje na jego lepszą zdolność do generalizacji, w porównaniu z modelem uczonego na podstawie danych w postaci bitmap wyników transformaty falkowym (rysunek 5.28 b)), oraz z modelem uczonego na podstawie bitmap przebiegów prądów fazowych (rysunek 5.25). Ponadto, model uczony na podstawie danych w postaci bitmap wyników transformaty Fouriera wykazuje najniższą stratę na zbiorze walidacyjnym (0.852), co sugeruje jego lepsze dopasowanie do danych walidacyjnych. W związku z tym, transformata Fouriera wydaje się być korzystniejszym przekształceniem danych dla zadania klasyfikacji zwarć międzyzwojowych, w odniesieniu do opracowanego modelu konwolucyjnej sieci neuronowej.

Wybrane metryki modelu uczonego na podstawie danych w postaci bitmap wyników transformaty Fouriera przedstawiają tabele 5.28, 5.29, 5.30 oraz 5.31.

Metryki dla modelu trenowanego na podstawie danych w postaci bitmap wyników przekształcenia falkowego przedstawiono w tabelach 5.32, 5.33, 5.34 oraz 5.35.

W tabeli 5.28 przedstawiono średnie wartości metryk dla modelu sieci neuronowej, którego zadaniem jest klasyfikacja zwarć międzyzwojowych uzwojenia stojana na podstawie danych wejściowych w postaci bitmap wyników transformaty Fouriera. Wyższe wartości makro i ważonej precyzji, czułości i F1-Score, niż w przypadku poprzedniego modelu, wskazują na wyższą skuteczność konwolucyjnej sieci neuronowej w przetwarzaniu danych przekształconych tą metodą. Transformata Fouriera pozwala na ekstrakcję istotnych cech danych, poprzez dekompozycję sygnału na składowe częstotliwościowe. Dekompozycja sygnału, może ułatwić sieci neuronowej identyfikację wzorców. Konwolucyjne sieci neuronowe, z uwagi na występujące w ich strukturze warstwy konwolucyjne, są wyjątkowo dobrze przystosowana do analizowania takich cech na bitmapach. Prowadzić to może do wyższej niezawodności w klasyfikacji zwarć międzyzwojowych uzwojenia stojana silnika indukcyjnego w odniesieniu do modelu uczonego na danych w postaci bitmap przebiegów prądów fazowych.

Tabela 5.28 Średnie wartości metryk – dane wejściowe: bitmapy ilustrujące wyniki transformaty Fouriera

Rodzaj Średniej	Precyzja	Czułość	F1-Score
Średnia Makro	0.800	0.792	0.796
Średnia Ważona	0.794	0.787	0.791

W tabeli 5.29 zaprezentowano metryki dla pięciu najskuteczniej sklasyfikowanych klas. Wyniki dotyczą modelu trenowanego na podstawie bitmap wyników transformaty Fouriera. Tak jak w przypadku wyników przedstawionych wcześniej w tym rozdziale, ponownie do grupy najskuteczniej sklasyfikowanych przykładów należą konfiguracje z dużą liczbą zwartych zwojów. Model dla przedstawionych konfiguracji zwarć, osiągnął wartości metryk z zakresu: metryka precyzja od 0.950 do 0.978, metryka czułość od 0.902 do 0.932 i metryka F1-Score od 0.931 do 0.947. Wysokie wartości zaprezentowanych metryk dla wybranych klas, świadczą o wysokiej wydajności modelu, w przypadku klasyfikacji najbardziej reprezentatywnych klas. Może to wynikać z wyraźnych wzorców w obrazach przedstawiających wyniki transformaty Fouriera, które model jest w stanie skutecznie rozpoznawać.

Tabela 5.29 Metryki dla pięciu klas o najlepszej skuteczności klasyfikacji – dane wejściowe: bitmapy ilustrujące wyniki transformaty Fouriera

Klasa (konfiguracja)	Precyzja	Czułość	F1-Score
339 (10 7 8)	0.962	0.902	0.931
798 (5 5 5)	0.950	0.920	0.935
1055 (7 6 9)	0.954	0.932	0.943
1183 (8 7 5)	0.965	0.927	0.946
1317 (9 8 7)	0.978	0.911	0.943

W tabeli 5.30 zaprezentowano wartości metryk dla najmniej skutecznie sklasyfikowanych konfiguracji zwarć międzyzwojowych uzwojenia stojana. Wyniki dotyczą modelu trenowanego na podstawie bitmap wyników transformaty Fouriera. Wartości metryk dla przedstawionych konfiguracji mieszczą się odpowiednio w zakresach: (precyzja od 0.310 do 0.478, czułość od 0.274 do 0.382, F1-Score od 0.325 do 0.399). Jak można zauważyć, średnia metryk dla przedstawionych konfiguracji jest wyższa niż w przypadku modelu uczonego na podstawie bitmap przebiegów prądów fazowych. Przedstawione wyniki mimo, że są wyższe niż w przypadku poprzednio opisywanego modelu sztucznej sieci neuronowej, mogą sugerować, że pomimo dodatkowego przekształcenia danych w postaci obrazów ilustrujących wyniki przekształcenia Fouriera, prezentowany model konwolucyjnej sieci neuronowej może

nadal mieć trudności z rozpoznawaniem cech charakterystycznych sygnału wejściowego dla niewielkiej liczby zwartych zwojów.

Tabela 5.30 Metryki dla pięciu klas o najgorszej skuteczności klasyfikacji – dane wejściowe: bitmapy ilustrujące wyniki transformaty Fouriera

Klasa (konfiguracja)	Precyzja	Czułość	F1-Score
15 (0 1 3)	0.418	0.382	0.399
34 (0 2 1)	0.478	0.274	0.345
49 (0 3 4)	0.335	0.315	0.325
137 (1 1 4)	0.450	0.285	0.348
158 (1 2 3)	0.310	0.365	0.335

W tabeli 5.31 przedstawiono wartości kwantyli dla zastosowanych metryk. Wysokie wartości zaprezentowanych kwantyli wskazują na stabilność i niezawodność modelu CNN w klasyfikacji zwarć międzyzwojowych uzwojenia stojana na podstawie obrazów wyników transformaty Fouriera. Przedstawione wyniki pozwalają wnioskować, że pomimo tego, iż model wykazuje gorsze wyniki niż modele uczone na podstawie sygnałów dyskretnych, to większość próbek jest klasyfikowana z wysoką skutecznością.

Tabela 5.31 Wartości kwantyli dla metryk – dane wejściowe: dane wejściowe: bitmapy ilustrujące wyniki transformaty Fouriera

Kwantyl	Precyzja	Czułość	F1-Score
25%	0.670	0.665	0.660
50%	0.810	0.800	0.805
75%	0.938	0.941	0.939

W tabeli 5.32 zawarto wartości wybranych metryk dla modelu trenowanego na danych w postaci bitmap ilustrujących wyniki transformaty falkowej. Jak można zauważyć, wartości metryk są niższe niż w przypadku modelu uczonego na bitmapach ilustrujących wyniki transformaty Fouriera. Średnia makro i ważona metryk precyzji, czułości i F1-Score to odpowiednio 0.782, 0.775, 0.778 oraz 0.775, 0.768, 0.771. Wyniki przekształcenia falkowego, choć skuteczne w analizie sygnałów zmiennych w czasie, to w przypadku zastosowanego modelu konwolucyjnej sieci neuronowej, bitmapy ilustrujące wyniki transformaty falkowej mogą być bardziej złożone, co w przypadku prezentowanego modelu skutkuje pogorszeniem wyników klasyfikacji.

Tabela 5.32 Średnie wartości metryk - dane wejściowe: bitmapy ilustrujące wyniki przekształcenia falkowego

Rodzaj Średniej	Precyzja	Czułość	F1-Score
Średnia Makro	0.782	0.775	0.778
Średnia Ważona	0.775	0.768	0.771

W tabeli 5.33 przedstawiono wyniki dla najskuteczniej sklasyfikowanych konfiguracji zwarć międzyzwojowych silnika indukcyjnego, dla modelu trenowanego na danych w postaci bitmap ilustrujących wyniki przekształcenia falkowego. Jak można zauważyć, ponownie wysokie wartości metryk dotyczą konfiguracji z dużą liczbą zwartych zwojów. Wyniki dla przedstawionych najskuteczniej sklasyfikowanych konfiguracji osiągają najniższe wartości, w porównaniu z dotychczas przedstawionymi modelami.

Tabela 5.33 Metryki dla pięciu klas o najlepszej skuteczności klasyfikacji – dane wejściowe: bitmapy ilustrujące wyniki przekształcenia falkowego

Klasa (konfiguracja)	Precyzja	Czułość	F1-Score
844 (5 9 7)	0.948	0.885	0.916
1042 (7 5 7)	0.940	0.912	0.926
1064 (7 7 7)	0.944	0.928	0.936
1069 (7 8 10)	0.956	0.918	0.936
1173 (8 6 6)	0.970	0.902	0.935

W tabeli 5.34 zaprezentowano wyniki dla najmniej skutecznie sklasyfikowanych konfiguracji, dla modelu trenowanego na bitmapach ilustrujących wyniki przekształcenia falkowego. Jak można zauważyć, wyniki są zbliżone, ale nieznacznie gorsze od tych uzyskanych dla modelu trenowanego na bitmapach wyników transformaty Fouriera, z precyzją z zakresu od 0.303 do 0.465, czułością z zakresu od 0.266 do 0.378 oraz F1-Score od 0.316 do 0.393.

Tabela 5.34 Metryki dla pięciu klas o najgorszej skuteczności klasyfikacji – dane wejściowe: bitmapy ilustrujące wyniki przekształcenia falkowego

Klasa(konfiguracja)	Precyzja	Czułość	F1-Score
4 (0 0 3)	0.410	0.378	0.393
366 (2 0 2)	0.465	0.266	0.337
487 (3 0 2)	0.328	0.305	0.316
533 (3 3 4)	0.440	0.281	0.343
540 (3 4 1)	0.303	0.362	0.330

Wartości kwantyli przedstawione w tabeli 5.35 dla modelu trenowanego na bitmapach ilustrujących wyniki przekształcenia falkowego są nieco niższe niż dla modelu trenowanego na podstawie bitmap wyników transformaty Fouriera, szczególnie

w przypadku kwantylu 50%. Mniejsze wartości kwantyli wskazują na mniejszą skuteczność klasyfikacji modelu w odniesieniu do dystrybucji wyników z poziomu przewidzianych konfiguracji.

Tabela 5.35 Wartości kwantyli dla metryk – dane wejściowe: bitmapy ilustrujące wyniki przekształcenia falkowego

Kwantyl	Precyzja	Czułość	F1-Score
25% (Q1)	0.660	0.655	0.657
50% (Q2)	0.795	0.785	0.790
75% (Q3)	0.930	0.935	0.933

Na podstawie analizy porównawczej trzech przedstawionych powyżej modeli, dla których dane wejściowe były prezentowane w postaci bitmap, można zauważyć różną skuteczności modeli w odniesieniu do zastosowanych metod przetwarzania danych wejściowych. Model konwolucyjnej sieci neuronowej, który trenowany był z wykorzystaniem bitmap przebiegów prądów fazowych, osiągnął dokładność 0.797. Średnie wartości metryk dla tego modelu (precyzji, czułości i F1-score) były niższe, w porównaniu do modelu trenowanego na bitmapach ilustrujących wyniki przekształcenia falkowego. Otrzymane wyniki mogą wskazywać, że model, pomimo wysokiej skuteczności, mógłby wymagać dalszej optymalizacji w celu poprawy skuteczności klasyfikacji. Model, wykorzystujący bitmapy z wynikami przekształcenia Fouriera, wykazał się lepszą jakością klasyfikacji z dokładnością równą 0.814. Otrzymane wyniki mogą sugerować, że użycie danych wejściowych w postaci bitmap wyników transformaty Fouriera, prowadzi do wyższej skuteczności klasyfikacji zwarć międzyzwojowych modelu. Model uczący się na podstawie bitmap ilustrujących wyniki transformaty falkowej, osiągnął najniższe wyniki z dokładnością równą 0.794. Niższe wyniki mogą być związane z większą złożonością danych wejściowych lub z większą liczbą przykładów w zbiorze walidacyjnym, co mogło wpływać na spadek wydajności modelu. Na podstawie omówionych wyników, można stwierdzić, że model uczony na podstawie danych wejściowych w postaci bitmap ilustrujących wyniki transformaty Fouriera był najskuteczniejszy w klasyfikacji zwarć międzyzwojowych uzwojenia stojana silnika indukcyjnego, w odniesieniu do dwóch pozostałych modeli wykorzystujących bitmapy jako dane wejściowe do sztucznej sieci neuronowej.

Porównując obie grupy modeli, można zauważyć, że modele uczone na podstawie sygnałów dyskretnych, osiągnęły wyższe wartości dokładności i lepsze średnie wartości metryk precyzji, czułości i F1-score, niż modele uczone na podstawie danych

wejściowych w postaci bitmap. W obu grupach modeli, najlepsze wyniki osiągnęły modele uczone na podstawie wyników transformaty Fouriera, co sugeruje, że ten rodzaj danych wejściowych może być skuteczniejszy w klasyfikacji zwarć międzyzwojowych uzwojenia stojana silnika indukcyjnego. Niemniej, różnice między poszczególnymi modelami w obu grupach były stosunkowo niewielkie, co wskazuje na możliwość dalszej optymalizacji modeli, co w konsekwencji może skutkować poprawą jakości klasyfikacji zwarć międzyzwojowych uzwojenia stojana.

5.5.3 Strojenie hiperparametrów konwolucyjnej sieci neuronowej do klasyfikacji zwarć międzyzwojowych uzwojenia stojana silnika indukcyjnego

Biorąc pod uwagę wyniki otrzymane z modelu bazowego, dalsze badania dotyczyły danych w postaci wyników dyskretnej transformaty Fouriera. Przedstawione we wcześniejszym podrozdziale wyniki dotyczyły wstępnej struktury sieci neuronowej. Aby poprawić jakość klasyfikacji dokonano modyfikacji wybranych hiperparametrów modelu takich jak:

- optymalizator,
- współczynnik uczenia,
- współczynnik porzucenia,
- liczba filtrów w warstwach konwolucyjnych.

Ostateczną strukturę modelu jak i wartości wybranych hiperparametrów wytypowano na podstawie badań, w których wykorzystano dwie metody strojenia hiperparametrów sztucznych sieci neuronowych:

- losowe przeszukiwanie hiperparametrów (ang. *random search*) to metoda optymalizacji używana w uczeniu maszynowym, służąca do wytypowania najbardziej dopasowanego zestawu hiperparametrów dla opracowywanego modelu sztucznych sieci neuronowych. Metoda ta polega na losowym wyborze wartości hiperparametrów z określonego zakresu lub rozkładu, a następnie ocenie wyników modelu dla tych wartości, w celu znalezienia optymalnej konfiguracji. Zaletą tej metody jest mniejszy koszt obliczeniowy w odniesieniu do siatkowego przeszukiwania hiperparametrów. Wadą tej metody jest to, że podczas określonej liczby powtórzeń nie zostanie wylosowana konfiguracja hiperparametrów zapewniająca najlepsze możliwe dopasowanie;


- siatkowe przeszukiwanie hiperparametrów (ang. *grid search*), tak jak metoda losowego przeszukiwania hiperparametrów, służy do wytypowania najbardziej dopasowanego zestawu hiperparametrów dla modelu sztucznej sieci neuronowej. W odróżnieniu od losowego przeszukiwania hiperparametrów, w metodzie siatkowego przeszukiwania ustala się dolny i górny limit wartości dla poszczególnych hiperparametrów, a następnie sprawdza się każdą z możliwych konfiguracji. Zaletą tej metody jest przeszukiwanie wszystkich możliwych konfiguracji z zadanego zakresu, co pozwala na wytypowanie najlepszego z możliwych (w ramach założonych granic) zestawu hiperparametrów dla modelu sztucznej sieci neuronowej. Wadą tego rozwiązania jest większy koszt obliczeniowy w odniesieniu do metody losowego przeszukiwania hiperparametrów [183].

W tabeli 5.36 zestawiono hiperparametry modelu podlegające dostrajaniu.

Tabela 5.36. Hiperparametry modelu podlegające strojeniu

Hiperparametr	Wartości
Optymalizator	Adaptive Momentum Estimation (<i>Adam</i>), Stochastic Gradient Descent (<i>SGD</i>), Root Mean Square Propagation (<i>RMSProp</i>)
Współczynnik uczenia	0.0001, 0.001, 0.01
Współczynnik porzucenia	0.3, 0.2, 0.4, 0.5
Liczba filtrów w trzech pierwszych warstwach konwolucyjnych	64, 32, 256, 512
Liczba filtrów w trzech ostatnich warstwach konwolucyjnych	64, 128, 512, 1024

Na podstawie wartości hiperparametrów przedstawionych w tabeli 5.36 utworzono 576 konfiguracje hiperparametrów dla modeli. Przedstawienie straty oraz dokładności dla wszystkich konfiguracji w sposób graficzny, sprawia, że rysunek staje się nieczytelny. Z tego powodu, na rysunkach 5.29 oraz 5.30 przedstawiono wartości dokładności oraz funkcji straty w funkcji epok, tylko dla pięciu najlepszych konfiguracji, z wykorzystaniem metody *random search* natomiast na rysunkach 5.31 oraz 5.32 przedstawiono te same wartości dla pięciu najlepszych konfiguracji z wykorzystaniem metody *grid search*. W przypadku metody *random search* przeszukano 144 losowe konfiguracje.



Rys. 5.29. Dokładność w funkcji epok dla metody *random search*

Dane przedstawione w legendzie na rysunkach od 5.29 do 5.32, dla których wartości są zawarte w tabeli 5.36, należy interpretować następująco:


- wartość pierwsza to informacja o zbiorze danych,
- wartość druga to informacja o zastosowanym optymalizatorze,
- wartość trzecia to informacja o wartości współczynnika uczenia,
- wartość czwarta to informacja o wartości współczynnika porzucenia,
- wartość piąta to informacja o liczbie kerneli w trzech pierwszych warstwach konwolucyjnych,
- wartość szоста to informacja o liczbie kerneli w trzech ostatnich warstwach konwolucyjnych.

Na podstawie wyników przedstawionych na rysunku 5.29, prezentujących wartości dokładności na zbiorach treningowym i walidacyjnym, można zauważyć, że najlepszy wynik na zbiorze walidacyjnym osiągnął model trenowany z wykorzystaniem optymalizatora *Adam*, przy wartości współczynnika uczenia 0.001, współczynnika porzucenia 0.2, liczbie kerneli w trzech pierwszych warstwach sieci konwolucyjnych równej 512 oraz liczbie kerneli w trzech ostatnich warstwach konwolucyjnych równej 1024. Model trenowany z tą konfiguracją hiperparametrów osiągnął najwyższą maksymalną dokładność na zbiorze walidacyjnym, wynoszącą 0.862 w epoce 70.

Porównując zaprezentowane konfiguracje, można zauważyć, iż model trenowany z wykorzystaniem optymalizatora *Adam*, wykazał się nie tylko najlepszą ogólną jakością klasyfikacji zwarć uzwojenia stojana silnika indukcyjnego na zbiorze walidacyjnym, ale również na zbiorze treningowym. Model wykorzystujący optymalizator *Adam* osiągnął najwyższą wartości dokładności dla danych ze zbioru treningowego, równą 0.905. Wyniki otrzymane przez ten model mogą wskazywać na dopasowanie modelu zarówno do danych treningowych jak i walidacyjnych.

Modele trenowane z wykorzystaniem optymalizatora *SGD* zostały wytypowane trzykrotnie w konfiguracjach: (*SGD*, 0.01, 0.2, 512, 512), (*SGD*, 0.0001, 0.4, 64, 512) oraz (*SGD*, 0.0001, 0.4, 256, 1024). Jeden z modeli, który był trenowany z wykorzystaniem optymalizatora *SGD* (*SGD*, 0.01, 0.2, 512, 512) osiągnął drugą dokładność na zbiorze walidacyjnym wynoszącą 0.848 w 123 epoce. Niemniej, różnica wartości dokładności między wynikami na zbiorze walidacyjnym dla konfiguracji modelu wykorzystującego najlepszą konfigurację z optymalizatorem *SGD*, a modelu z optymalizatorem *Adam*, wskazuje, że model trenowany z wykorzystaniem optymalizatora *Adam* wykazuje się lepszą jakością klasyfikacji w kontekście klasyfikacji zwarć międzyzwojowych uzwojenia stojana na zbiorze walidacyjnym niż model trenowany z wykorzystaniem optymalizatora *SGD*. Ponadto, jak wynika z przedstawionego rysunku 5.29, model uczony z zastosowaniem konfiguracji wykorzystującej optymalizator *Adam*, oprócz najwyższej wartości dokładności na zbiorze walidacyjnym i treningowym, cechuje się dużo krótszym czasem konwergencji niż model wykorzystujący optymalizator *SGD*, który osiągnął drugi wynik w zestawieniu.

Analiza otrzymanych wyników dokładności wskazuje, że dobór odpowiednich hiperparametrów na etapie trenowania modelu, może mieć znaczenie dla uzyskania wysokiej dokładności klasyfikacji zwarć międzyzwojowych przez modele. Podczas poszukiwania hiperparametrów metodą losowego przeszukania, model wykorzystujący optymalizator *Adam*, z odpowiednio dobranymi parametrami, wykazał najlepsze wyniki w kontekście szybkości konwergencji i końcowej dokładności.



Rys. 5.30. Strata w funkcji epok dla metody *random search*


Na podstawie wartości strat na zbiorach treningowych i walidacyjnych przedstawionych na rysunku 5.30, można zauważyć, że model trenowany z użyciem optymalizatora *Adam* osiągnął najniższą wartość straty na zbiorze walidacyjnym. Wartości hiperparametrów dla tego modelu, wynosiły: współczynnik uczenia (0.001), współczynnik porzucenia (0.2), liczba kerneli w pierwszych trzech warstwach konwolucyjnych (512) oraz liczba kerneli w ostatnich trzech warstwach konwolucyjnych (1024). Minimalna strata osiągnięta przez ten model na zbiorze walidacyjnym wynosiła 0.677, w epoce 70.

Można zauważyć, że mimo tego, iż model z optymalizatorem *Adam* uzyskał najlepsze wyniki na zbiorze walidacyjnym, to nie uzyskał najniższej wartości straty na zbiorze treningowym. Najniższą wartość straty na zbiorze treningowym osiągnął model trenowany z użyciem optymalizatora *RMSProp*, uzyskując stratę równą 0.645 w epoce 59, co może sugerować nadmierne dopasowanie modelu do danych ze zbioru treningowego.

Analizując trzy wytypowane modele trenowane z użyciem optymalizatora *SGD*, w konfiguracjach: (*SGD*, 0.01, 0.2, 512, 512), (*SGD*, 0.0001, 0.4, 64, 512) oraz (*SGD*, 0.0001, 0.4, 256, 1024) można zaobserwować, że model z konfiguracją (*SGD*, 0.0001, 0.4, 64, 512) uzyskał drugą, co do minimalnej wartości, stratę na zbiorze walidacyjnym,

wynoszącą 0.725 w epoce 76. Pomimo niewielkiej różnicy w wartościach strat między modelem z optymalizatorem *SGD*, a modelem z optymalizatorem *Adam*, to model trenowany z użyciem optymalizatora *Adam* wykazuje większą od pozostałych modeli skuteczność w klasyfikacji zwarć międzyzwojowych uzwojenia stojana.

Ponadto, liczba epok niezbędna do osiągnięcia konwergencji na zbiorze walidacyjnym dla modelu wykorzystującego optymalizator *Adam* jest mniejsza niż ta, potrzebna do osiągnięcia konwergencji dla modeli trenowanych z użyciem optymalizatora *SGD*.




Rys. 5.31. Dokładność w funkcji epok dla metody *grid search*.

Jak wspomniano, drugą z zastosowanych metod strojenia hiperparametrów modeli sieci neuronowych wykorzystaną w badaniach była metoda siatkowego przeszukiwania hiperparametrów. Wyniki prezentujące wartości dokładności w funkcji epok przedstawiono na rysunku 5.31. Dzięki temu, że metoda przeszukiwania siatkowego sprawdza wszystkie możliwe kombinacje hiperparametrów z określonej w tabeli 5.36 puli, wytypowane zostały modele wykorzystujące odmienne konfiguracje hiperparametrów w odniesieniu do metody losowego przeszukiwania hiperparametrów. W przypadku metody *grid search* najwyższy wynik metryki dla zbioru walidacyjnego równy 0.888, w epoce 139, uzyskał model sztucznej sieci neuronowej z następującą konfiguracją hiperparametrów: optymalizator (*SGD*), współczynnik uczenia (0.0001),

współczynnik porzucenia (0.4), liczba kerneli w trzech pierwszych warstwach konwolucyjnych (512), liczba kerneli w trzech ostatnich warstwach konwolucyjnych (1024). Dodatkowo można zauważyć, że wszystkie wytypowane modele wykorzystujące konfiguracje z użyciem optymalizatora *SGD* wymagają większej liczby epok do osiągnięcia konwergencji, niż dwa pozostałe modele, dla których w procesie trenowania wykorzystany został optymalizator *Adam*.

Analiza wyników przedstawionych na rysunku 5.31 może sugerować, że model z niższym współczynnikiem uczenia (0.0001), w przypadku modeli wykorzystujących optymalizator *SGD*, osiąga wyższą maksymalną wartość dokładności, a zatem mniejszy współczynnik uczenia pozwala na bardziej precyzyjne dostrajanie wag dla opracowanego modelu. Ponadto, analizując wyniki dokładności, można zauważyć, że na wczesnym etapie trenowania, modele wykorzystujące optymalizator *Adam*, charakteryzują się znaczącym wzrostem dokładności. Podczas gdy modele wykorzystujące optymalizator *SGD*, do osiągnięcia podobnych wartości dokładności potrzebują więcej epok treningowych.

Porównując wyniki dokładności dla najlepszych modeli strojonych z wykorzystaniem metody losowego i siatkowego przeszukiwania hiperparametrów, można zauważyć, że lepsze rezultaty zostały uzyskane z wykorzystaniem modelu trenowanego z optymalizatorem *SGD*, przy niewielkiej wartości współczynnika uczenia. Niemniej jednak, trenowanie modelu z wykorzystaniem optymalizatora *SGD*, wymaga większej mocy obliczeniowej, z uwagi na większą liczbę epok treningowych niezbędną do uzyskania konwergencji.



Rys. 5.32. Strata w funkcji epoki dla metody *grid search*

Na podstawie danych z prezentujących na rysunku 5.32 wartości strat na zbiorach treningowych i walidacyjnych, dla modeli wytypowanych z wykorzystaniem metody *grid search*, można zauważyć, że model trenowany z użyciem optymalizatora *SGD* (*SGD*, 0.0001, 0.4, 512, 1024) osiągnął najniższą wartość straty na zbiorze walidacyjnym. Wartość straty dla tego modelu wynosiła 0.671 w epoce 139. Wspomniany model z optymalizatorem *SGD* uzyskał nie tylko najlepszy wynik dla maksymalnej dokładności na zbiorze walidacyjnym, ale również na tym samym zbiorze uzyskał najniższą wartość straty równą 0.654 w 142 epoce.

Finalne struktury sieci, wytypowane z wykorzystaniem metod *random search* oraz *grid search*, w przypadku danych treningowych w postaci sygnału dyskretnego wyników przekształcenia Fouriera, przedstawiono w tabeli 5.37.

Tabela 5.37 Konfiguracje z najwyższą wartością metryki dokładność na zbiorze walidacyjnym

Typ danych	Optymalizator	Współczynnik uczenia	Współczynnik porzucenia	Liczba filtrów w trzech pierwszych warstwach konwolucyjnych	Liczba filtrów w trzech ostatnich warstwach konwolucyjnych	Dokładność na zbiorze walidacyjnym
Przeszukiwanie losowe	<i>ADAM</i>	0.001	0.2	512	1024	0.862
Przeszukiwanie siatkowe	<i>SGD</i>	0.0001	0.4	512	1024	0.888

Na podstawie przedstawionych wyników badań wybrano model (zaznaczony kolorem zielonym w tabeli 5.37), charakteryzujący się największą wartością

dokładności na danych walidacyjnych. Wytypowany model został przetestowany na zbiorze testowym. Baza danych testowych składała się z 25600 przykładów uczących. Przykłady ze zbioru testowego nie były stosowane w procesie trenowania konwolucyjnej sieci neuronowej. Wyniki prezentujące wartości wybranych metryk dla modelu charakteryzującego się największą dokładnością na zbiorze walidacyjnym przedstawiono w tabelach od 5.38 do 5.41.

W tabeli 5.38 przedstawiono metryki dla modelu, który osiągnął najwyższą wartość dokładności na zbiorze walidacyjnym, po procesie strojenia hiperparametrów. Średnie makro i średnie ważone metryk dla zbioru walidacyjnego, osiągnęły najwyższe wartości spośród dotychczas prezentowanych modeli sztucznych sieci neuronowych (średnia makro: precyzja 0.870, czułość 0.865, F1-score 0.867), (średnia ważona: precyzja 0.865, czułość 0.860, F1-score 0.862). Wyniki dla zbioru testowego są niższe (średnia makro: precyzja 0.802, czułość 0.795, F1-score 0.798), (średnia ważona: precyzja 0.795, czułość 0.789, F1-score 0.792). Z uwagi na to, że zbiór danych testowych pochodził z zupełnie innego źródła, niższa średnia wartość metryk precyzji, czułości, F1-Score i dokładności była spodziewana.

Tabela 5.38 Średnie wartości metryk

Baza danych	Rodzaj Średniej	Precyzja	Czułość	F1-Score	Dokładność
Zbiór walidacyjny	Średnia Makro	0.870	0.865	0.867	0.880
	Średnia Wazona	0.865	0.860	0.862	0.875
Zbiór testowy	Średnia Makro	0.802	0.795	0.798	0.810
	Średnia Wazona	0.795	0.789	0.792	0.812

W tabeli 5.39 przedstawiono metryki dla pięciu najskuteczniej klasyfikowanych konfiguracji zwarć międzyzwojowych. Wyniki dotyczą modelu, który osiągnął najwyższą wartość dokładności na zbiorze walidacyjnym, po procesie strojenia hiperparametrów (*SGD*, 0.0001, 0.4, 512, 1024). Wyniki dla zbioru walidacyjnego (precyzja od 0.966 do 0.982, czułość od 0.930 do 0.954, F1-Score od 0.948 do 0.968 oraz dokładność od 0.952 do 0.975) pokazują dużą skuteczność modelu do klasyfikacji przedstawionych konfiguracji zwarć. W przypadku zbioru testowego wartości te są niższe, co jak wspomniano jest zachowaniem spodziewanym, z uwagi na charakterystykę zbioru testowego. Niemniej, wysokie wartości metryk dla powyższych konfiguracji zwarć potwierdzają, że opracowany model wykazuje lepszą zdolność do klasyfikacji zwarć, w których występuje większa liczba zwartych zwojów.

Tabela 5.39 Metryki dla pięciu klas o najlepszej skuteczności klasyfikacji

Baza danych	Klasa (konfiguracja)	Precyzja	Czułość	F1-Score	Dokładność
Zbiór walidacyjny	360 (10 9 7)	0.982	0.954	0.968	0.975
	1075 (7 8 7)	0.977	0.947	0.962	0.972
	1205 (8 9 5)	0.969	0.948	0.958	0.967
	1206 (8 9 6)	0.968	0.935	0.951	0.963
	1295 (9 6 7)	0.966	0.930	0.948	0.952
Zbiór testowy	367 (10 9 9)	0.946	0.905	0.925	0.941
	1151 (8 4 6)	0.943	0.901	0.922	0.936
	1205 (8 9 5)	0.935	0.894	0.914	0.932
	1206 (8 9 6)	0.933	0.895	0.914	0.926
	1295 (9 6 7)	0.928	0.884	0.905	0.923

W tabeli 5.40 przedstawiono metryki dla pięciu najmniej skutecznie sklasyfikowanych konfiguracji zwarć międzyzwojowych. Wyniki dotyczą modelu, który osiągnął najwyższą wartość dokładności na zbiorze walidacyjnym, po procesie strojenia hiperparametrów (*SGD*, 0.0001, 0.4, 512, 1024). Wyniki dla zbioru walidacyjnego (precyzja od 0.325 do 0.485, czułość od 0.298 do 0.409, F1-Score od 0.337 do 0.420 oraz dokładność od 0.363 do 0.455) mogą wynikać z mniejszego wpływu zwarć międzyzwojowych, na wczesnym etapie ich występowania (niewiele zwartych zwojów), na wartości prądów fazowych maszyny, co w konsekwencji przekłada się na podobieństwo przykładów w obrębie poszczególnych klas utrudniając skuteczne rozróżnianie wzorców między klasami.

Tabela 5.40 Metryki dla pięciu klas o najmniejszej dokładności klasyfikacji

Baza danych	Klasa (konfiguracja)	Precyzja	Czułość	F1-Score	Dokładność
Zbiór walidacyjny	6 (0 0 5)	0.432	0.409	0.420	0.441
	12 (0 1 1)	0.485	0.298	0.369	0.455
	59 (0 4 3)	0.351	0.324	0.337	0.363
	63 (0 4 7)	0.460	0.304	0.366	0.427
	209 (1 7 3)	0.325	0.379	0.350	0.399
Zbiór testowy	3 (0 0 2)	0.400	0.376	0.388	0.422
	12 (0 1 1)	0.464	0.282	0.351	0.451
	59 (0 4 3)	0.320	0.297	0.308	0.337
	63 (0 4 7)	0.435	0.289	0.347	0.383
	207 (1 7 1)	0.310	0.367	0.336	0.370

W tabeli 5.41 przedstawiono metryki dla kwantyli modelu, który osiągnął najwyższą wartość dokładności na zbiorze walidacyjnym, po procesie strojenia hiperparametrów. Wartości metryk dla zbioru walidacyjnego prezentują się następująco: (kwantyl 25% (Q1): precyzja 0.721, czułość 0.717, F1-score 0.717, dokładność 0.724), (kwantyl 50% (Q2): precyzja 0.853, czułość 0.844, F1-score 0.847, dokładność 0.855),

(kwantyl 75% (Q3): precyzja 0.960, czułość 0.968, F1-score 0.963, dokładność 0.977). Natomiast metryki dla zbioru treningowego: (kwantyl 25% (Q1): precyzja 0.666, czułość 0.661, F1-score 0.662, dokładność 0.669), (kwantyl 50% (Q2): precyzja 0.795, czułość 0.790, F1-score 0.792, dokładność 0.799), (kwantyl 75% (Q3): precyzja 0.902, czułość 0.905, F1-score 0.902, dokładność 0.913). Wysokie wartości kwantyli Q3, wskazują na ogólną wysoką wydajność modelu. Metryki dla kwantyli Q1, Q2 i Q3 dla zbioru testowego są niższe, niż te dla zbioru walidacyjnego, co ukazuje ogólną tendencję modelu sieci neuronowej do pogorszenia jakości klasyfikacji zwarć zwojowych uzwojenia stojana silnika klatkowego na zupełnie nowym zbiorze danych. Niemniej, zaprezentowane wartości pozostają na wysokim poziomie, co potwierdza skuteczność klasyfikacji modelu dla wielu konfiguracji. Otrzymane wyniki są zgodne z teorią konwolucyjnych sieci neuronowych, która podkreśla znaczenie stosowania dużych i zróżnicowanych zbiorów treningowych, metod strojenia hiperparametrów oraz technik regularyzacyjnych, w celu poprawy zdolności modelu do generalizacji.


Tabela 5.41 Wartości kwantyli dla metryk



Baza danych	Kwantyl	Precyzja	Czułość	F1-Score	Dokładność
Zbiór walidacyjny	25% (Q1)	0.721	0.717	0.717	0.724
	50% (Q2)	0.853	0.844	0.847	0.855
	75% (Q3)	0.960	0.968	0.963	0.977
Zbiór testowy	25% (Q1)	0.666	0.661	0.662	0.669
	50% (Q2)	0.795	0.790	0.792	0.799
	75% (Q3)	0.902	0.905	0.902	0.913


Podsumowując wyniki trenowania wszystkich przedstawionych modeli, można zauważyć, że wykazują się one zróżnicowaną skutecznością, w zależności od typu danych wejściowych. Najwyższe wyniki osiągnięte podczas trenowania otrzymano dla modeli uczonych na wynikach transformaty Fouriera (zarówno w postaci dyskretnej, jak i bitmapy). Najlepsze wyniki osiągnął model poddany procesowi strojenia metodą siatkowego przeszukiwania hiperparametrów, z danymi wejściowymi w postaci wyników transformaty Fouriera. Pozostałe modele także wykazały wysoką skuteczność, choć w niektórych przypadkach jakość ich klasyfikacji była niższa (wyniki transformaty falkowej), co może wynikać z mniejszej reprezentatywności przetworzonych danych wejściowych lub z większej złożoności wzorców w analizowanych przykładach. Dodatkowo, można zauważyć, że wszystkie zaprezentowane w rozprawie modele konwolucyjnych sieci neuronowych do zadania klasyfikacji zwarć międzyzwojowych

uzwojenia stojana trójfazowego silnika indukcyjnego, radziły sobie lepiej z konfiguracjami zwarć, w których występowała większa liczba zwartych zwojów.

Aby lepiej przestawić rozkład metryk, dla przykładów ze zbioru treningowego oraz zbioru walidacyjnego, na rysunkach 5.33 oraz 5.34 przedstawiono histogramy prezentujące rozkład metryk dla każdego z przykładu, odpowiednio ze zbioru walidacyjnego i treningowego.









Rys. 5.33 Histogramy dla metryk a) precyzja, b) czułość c) F1-score d) dokładność - dane wejściowe: zbiór walidacyjny


Na rysunku 5.33 przedstawiono wyniki dla zbioru walidacyjnego. Analiza danych histogramu precyzji dla zbioru walidacyjnego pozwala zauważyć, że większość wartości dla metryki precyzji mieści się w zakresie od 0.721 do 0.960. Rozkład metryki dla modelu jest stosunkowo równomierny, z wyraźnym skupieniem wokół wyższych wartości, co sugeruje, że dla większości danych wchodzących w skład zbioru walidacyjnego, opracowany model poprawnie identyfikuje rzeczywiste przypadki konfiguracji zwarć międzyzwojowych silnika indukcyjnego.

Histogram czułości dla zbioru walidacyjnego wskazuje, że wartości czułości są rozłożone od 0.717 do 0.968. Widoczna jest tendencja do wyższych wartości, co oznacza, że model skutecznie wykrywa większość przypadków zwarć międzyzwojowych. Czułość, będąca miarą zdolności modelu do identyfikacji wszystkich przypadków zwarć, jest kluczowa w kontekście diagnostyki przemysłowej, gdzie wykrycie każdego przypadku zwarcia jest krytyczne dla zapobiegania awariom i minimalizacji przestojów w procesie technologicznym.

Histogram F1-Score pokazuje rozkład wartości od 0.717 do 0.963, z koncentracją w wyższym zakresie. F1-Score, jako metryka równoważąca precyzję i czułość, sugeruje, że model osiąga dobre wyniki w obu tych aspektach, co jest kluczowe w sytuacjach, gdzie zarówno fałszywe wykrycia, jak i pominięte przypadki mają poważne konsekwencje dla działania systemu.

Histogram dokładności dla zbioru walidacyjnego wskazuje, że większość wartości dokładności mieści się w zakresie od 0.724 do 0.977. Wysoka dokładność wskazuje na skuteczność modelu w przewidywaniu poprawnych konfiguracji zwarć międzyzwojowych uzwojenia stojana.





Rys. 5.34 Histogramy dla metryk a) precyzja, b) czułość c) F1-score d) dokładność - dane wejściowe: zbiór testowy

Analiza histogramów precyzji dla zbioru testowego (rysunek 5.34 a)) wskazuje na rozkład wartości od 0.666 do 0.902. Widać wyraźne skupienie wokół wyższych wartości, co sugeruje, że model utrzymuje dobrą precyzję, także na zbiorze testowym.

Histogram czułości (rysunek 5.34 b)) dla zbioru testowego pokazuje, że wartości czułości rozciągają się od 0.661 do 0.905, z tendencją do wyższych wartości. Wskazuje to na skuteczność modelu w wykrywaniu przypadków zwarć międzyzwojowych również na zbiorze testowym.

Histogram F1-Score (rysunek 5.34 c)) dla zbioru testowego ukazuje wartości od 0.662 do 0.902. Rozkład ten odzwierciedla równowagę między precyzją a czułością, podobnie jak w zbiorze walidacyjnym, co potwierdza ogólną skuteczność modelu.

Histogram dokładności (rysunek 5.34 d)) dla zbioru testowego przedstawia wartości od 0.669 do 0.913. Podobnie jak w przypadku zbioru walidacyjnego, wartości te wskazują na wysoką ogólną dokładność modelu.

Analiza histogramów dla metryk na zbiorze walidacyjnym i testowym wskazuje, że model uczenia maszynowego wykorzystujący warstwy konwolucyjne wykazuje zadowalające wyniki w zakresie precyzji, czułości, F1-Score oraz dokładności na obu zbiorach danych. Widoczna tendencja do wyższych wartości metryk sugeruje, że model jest skuteczny zarówno w identyfikacji przypadków zwarć międzyzwojowych, jak i w minimalizacji błędów klasyfikacji. Wyniki te potwierdzają, że model zachowuje wysoką jakość klasyfikacji, nie tylko na zbiorze walidacyjnym, ale także na zbiorze testowym, co świadczy o jego dobrej generalizacji. Te obserwacje podkreślają skuteczność konwolucyjnych sieci neuronowych w zadaniach klasyfikacji zwarć międzyzwojowych uzwojenia stojana.

6 Wnioski i uwagi końcowe

W przedłożonej rozprawie przedstawiono skuteczną metodę diagnostyki uzwojenia stojana maszyny indukcyjnej z wykorzystaniem polowego modelu zjawisk elektromagnetycznych oraz metod uczenia maszynowego. Podczas realizacji badań autor rozprawy opracował i zastosował polowy model silnika indukcyjnego do obliczenia przebiegów prądów fazowych z uwzględnieniem uszkodzeń uzwojenia stojana. Zbudowaną bazę danych przebiegów prądów wykorzystano do opracowania modeli konwolucyjnych sztucznych sieci neuronowych. Zadaniem opracowanej sieci neuronowej była klasyfikacja uszkodzeń uzwojenia stojana silników indukcyjnych. Opracowana metoda może zostać wykorzystana do poprawy niezawodności pracy elektrycznych układów napędowych z silnikami klatkowymi.

Do istotnych osiągnięć uzyskanych podczas prowadzonych badań można zaliczyć:

- Analiza aktualnego stanu wiedzy w zakresie diagnostyki silników indukcyjnych na podstawie przeglądu dostępnej literatury.
- Przegląd aktualnie wykorzystywanych metod diagnostycznych oraz metod przetwarzania sygnału w diagnostyce silników elektrycznych.
- Przedstawienie, analiza oraz omówienie zagadnień związanych z matematycznym modelowaniem silników indukcyjnych zarówno w ujęciu obwodowym jak i polowym.
- Omówienie i analiza matematycznego modelowania uszkodzeń uzwojenia stojana trójfazowych silników indukcyjnych.
- Opracowanie modeli obwodowych oraz polowych trójfazowego silnika indukcyjnego z uwzględnieniem uszkodzenia we wszystkich fazach uzwojenia stojana.
- Obliczenia symulacyjne przebiegów prądów fazowych silnika z uwzględnieniem zwarć międzyzwojowych we wszystkich fazach uzwojenia stojana w wybranych stanach pracy z zastosowaniem opracowanego modelu uszkodzonego silnika.
- Przeprowadzenie analizy wyników badań symulacyjnych z zastosowaniem transformaty Fouriera oraz transformaty falkowej.
- Opracowanie bazy danych treningowych i walidacyjnych na podstawie wyników analizy badań symulacyjnych.

- Przeprowadzenie weryfikacji eksperymentalnej modelu polowego trójfazowego silnika indukcyjnego.
- Analiza aktualnego stanu wiedzy w obszarze metod uczenia maszynowego ze szczególnym uwzględnieniem wykorzystania sztucznych sieci neuronowych w zagadnieniach związanych z diagnostyką silników elektrycznych.
- Przedstawienie oraz omówienie struktury wybranych klasycznych, jak i głębokich modeli sztucznych sieci neuronowych.
- Przedstawienie oraz analiza metod oceny zarówno binarnych jak i wieloklasowych klasyfikatorów neuronowych.
- Opracowanie oprogramowania własnego do: wizualizacji struktury, treningu, strojenia parametrów z wykorzystaniem metod losowego i siatkowego przeszukiwania hiperparametrów oraz wizualizacji i analizy wyników konwolucyjnych sieci neuronowych.
- Opracowanie i analiza modeli konwolucyjnych sztucznych sieci neuronowych umożliwiających klasyfikację zwarć międzyzwojowych w trzech fazach trójfazowego silnika indukcyjnego.
- Analiza wpływu rodzaju danych treningowych na wyniki klasyfikacji konfiguracji zwarć międzyzwojowych w trzech fazach trójfazowego silnika indukcyjnego.
- Analiza wpływu hiperparametrów konwolucyjnej sieci neuronowej na wyniki klasyfikacji zwarć międzyzwojowych uzwojenia stojana.
- Analiza porównawcza metryk modeli konwolucyjnych sieci neuronowych w zagadnieniach klasyfikacji zwarć międzyzwojowych uzwojenia stojana.

Na podstawie przeprowadzonych badań nad zastosowaniem polowego modelu zjawisk elektromagnetycznych oraz metod sztucznej inteligencji w diagnostyce uzwojenia stojana można sformułować następujące wnioski:

- Zastosowanie dokładnych modeli polowych trójfazowych silników indukcyjnych, które pozwalają na uwzględnienie uszkodzeń obwodu stojana umożliwia odwzorowanie, analizę wpływu zwarć międzyzwojowych na przebiegi prądów fazowych.

- Polowe modele silników indukcyjnych mogą z powodzeniem zostać wykorzystane do tworzenia baz treningowych dla głębokich sieci neuronowych.
- Implementacja głębokich modeli sztucznych sieci neuronowych takich jak konwolucyjne sieci neuronowe umożliwia opracowanie skutecznego klasyfikatora zwarć międzyzwojowych uzwojenia stojana trójfazowego silnika indukcyjnego.
- Zastosowanie sygnału wejściowego dla opracowanych konwolucyjnych struktur sieci neuronowych w postaci sygnału dyskretnego zapewnia wysoką i zadowalającą skuteczność detekcji i klasyfikacji zwarć międzyzwojowych uzwojenia stojana.
- Zastosowanie metod przetwarzania sygnału wejściowego konwolucyjnej sieci neuronowej może poprawić ale też pogorszyć jakość klasyfikacji zwarć międzyzwojowych uzwojenia stojana silnika indukcyjnego.
- Strojenie hiperparametrów konwolucyjnych modeli sztucznych sieci neuronowych na potrzeby diagnostyki uzwojenia stojana z wykorzystaniem deterministycznych i stochastycznych metod doboru hiperparametrów modelu może wpłynąć na poprawę jakości detekcji i klasyfikacji zwarć międzyzwojowych uzwojenia stojana.
- Opracowane modele konwolucyjnych sieci neuronowych skutecznie klasyfikowały konfiguracje zwarć międzyzwojowych ze znaczną liczbą zwartych zwojów.
- Pomimo trudnych do jednoznacznego określenia zależności między strukturą, wartościami początkowymi procesu trenowania i hiperparametrami konwolucyjnych sieci neuronowych przedstawione w rozprawie wyniki mogą być pomocne w projektowaniu modeli głębokich sieci neuronowych na potrzeby diagnostyki wielofazowych zwarć międzyzwojowych uzwojenia stojana.
- Zastosowanie dokładnych polowych modeli silników indukcyjnych oraz zaawansowanych modeli głębokich sieci neuronowych może z powodzeniem zostać wykorzystane przy opracowywaniu systemu diagnostycznego do diagnostyki obwodu uzwojenia stojana trójfazowych silników indukcyjnych.

Literatura

- [1] Orłowska-Kowalska T. and Dybkowski M., 'Industrial drive systems. current state and development trends', *Power Electron. Drives*, vol. 1, no. 1, pp. 5–25, Jun. 2016, doi: 10.5277/PED160101.
- [2] A. Kampker, H. H. Heimes, B. Dorn, and F. Brans, 'Framework for Integration and Substitution of Process Technologies in Existing Production Systems Under Consideration of Limited Technology Experiences', in *2022 12th International Electric Drives Production Conference (EDPC)*, Nov. 2022, pp. 1–7. doi: 10.1109/EDPC56367.2022.10019739.
- [3] C. Mutize and R.-J. Wang, 'Performanse comparison of an induction machine and line-start PM motor for cooling fan applications', Jan. 2013, pp. 122–126. doi: 10.13140/RG.2.1.2542.1922.
- [4] V. Goman, S. Oshurbekov, V. Kazakbaev, V. Prakht, and V. Dmitrievskii, 'Energy Efficiency Analysis of Fixed-Speed Pump Drives with Various Types of Motors', *Appl. Sci.*, vol. 9, no. 24, Art. no. 24, Jan. 2019, doi: 10.3390/app9245295.
- [5] W. Fei, P. Luk, J. Ma, J. Shen, and G. Yang, 'A High-Performance Line-Start Permanent Magnet Synchronous Motor Amended From a Small Industrial Three-Phase Induction Motor', *Magn. IEEE Trans. On*, vol. 45, pp. 4724–4727, Nov. 2009, doi: 10.1109/TMAG.2009.2022179.
- [6] T. Xiangjie, L. Xiaopeng, and C. Yongyuan, 'Reliability Study of Electric Vehicle Drive Motor Control System', *Int. J. New Dev. Eng. Soc.*, vol. 7, no. 3, May 2023, doi: 10.25236/IJNDES.2023.070306.
- [7] P. Li, X. Xu, Z. Wei, and X. Jiang, 'Research on High Reliability PMSM System and Fault-Tolerant Control for Industrial Robots', in *The Proceedings of the 17th Annual Conference of China Electrotechnical Society*, J. Li, K. Xie, J. Hu, and Q. Yang, Eds., Singapore: Springer Nature, 2023, pp. 1257–1264. doi: 10.1007/978-981-99-0451-8_126.
- [8] O. I. Osipov, Y. M. Safonov, D. A. Blagodarov, and N. N. Fedortsov, 'The Improving Reliability of the Electric Drive and the Productivity of the Technological Process are Due to More Complete Use of the Thermal Resource of the Electric Motor', in *2022 International Conference on Industrial Engineering, Applications and Manufacturing (ICIEAM)*, May 2022, pp. 435–439. doi: 10.1109/ICIEAM54945.2022.9787142.
- [9] M. Ojaghi, M. Sabouri, and J. Faiz, 'Performance Analysis of Squirrel-Cage Induction Motors Under Broken Rotor Bar and Stator Inter-Turn Fault Conditions Using Analytical Modeling', *IEEE Trans. Magn.*, vol. 54, no. 11, pp. 1–5, Nov. 2018, doi: 10.1109/TMAG.2018.2842240.
- [10] J. J. Saucedo-Dorantes, M. Delgado-Prieto, R. A. Osornio-Rios, and R. de Jesus Romero-Troncoso, 'Multifault Diagnosis Method Applied to an Electric Machine Based on High-Dimensional Feature Reduction', *IEEE Trans. Ind. Appl.*, vol. 53, no. 3, pp. 3086–3097, May 2017, doi: 10.1109/TIA.2016.2637307.
- [11] T. Yang, H. Pen, Z. Wang, and C. S. Chang, 'Feature Knowledge Based Fault Detection of Induction Motors Through the Analysis of Stator Current Data', *IEEE Trans. Instrum. Meas.*, vol. 65, no. 3, pp. 549–558, Mar. 2016, doi: 10.1109/TIM.2015.2498978.

- [12] M. Ojaghi, R. Aghmasheh, and M. Sabouri, 'Model-based exact technique to identify type and degree of eccentricity faults in induction motors', *IET Electr. Power Appl.*, vol. 10, no. 8, pp. 706–713, 2016, doi: 10.1049/iet-epa.2016.0026.
- [13] A. H. Boudinar, N. Benouzza, A. Bendiabdellah, and M.-E.-A. Khodja, 'Induction Motor Bearing Fault Analysis Using a Root-MUSIC Method', *IEEE Trans. Ind. Appl.*, vol. 52, no. 5, pp. 3851–3860, Sep. 2016, doi: 10.1109/TIA.2016.2581143.
- [14] S. Rajput, E. Bender, and M. Averbukh, 'Simplified algorithm for assessment equivalent circuit parameters of induction motors', *IET Electr. Power Appl.*, vol. 14, no. 3, pp. 426–432, 2020, doi: 10.1049/iet-epa.2019.0822.
- [15] S. Morsalin, K. Mahmud, H. Mohiuddin, Md. R. Halim, and P. Saha, 'Induction motor inter-turn fault detection using heuristic noninvasive approach by artificial neural network with Levenberg Marquardt algorithm', in *2014 International Conference on Informatics, Electronics & Vision (ICIEV)*, Dhaka: IEEE, May 2014, pp. 1–6. doi: 10.1109/ICIEV.2014.7136002.
- [16] V. K. Giri and R. K. Patel, 'Condition monitoring of induction motor bearing based on bearing damage index', *Arch. Electr. Eng. 2017 Vol 66 No 1 March*, 2017, Accessed: Nov. 14, 2022. [Online]. Available: <https://journals.pan.pl/dlibra/publication/120100/edition/104521>
- [17] P. Sobański and T. Orłowska-Kowalska, 'Detection of single and multiple IGBTs open-circuit faults in a field-oriented controlled induction motor drive', *Arch. Electr. Eng. 2017 Vol 66 No 1 March*, 2017, Accessed: Nov. 14, 2022. [Online]. Available: <https://www.czasopisma.pan.pl/dlibra/publication/120101/edition/104522>
- [18] M. Wolkiewicz, G. Tarchala, T. Orłowska-Kowalska, and C. Kowalski, 'Stator fault monitoring based on internal signals of vector controlled induction motor drives', in *IECON 2016 - 42nd Annual Conference of the IEEE Industrial Electronics Society*, Florence, Italy: IEEE, Oct. 2016, pp. 2651–2656. doi: 10.1109/IECON.2016.7793055.
- [19] Javvadi.Shiva, K. Pavani, B. P. Naidu, J. Visweswarao, S. R. Kumar Joga, and S. Priyadarshini, 'Implementation of Speed and Torque Control of Induction Motor Drive using Space Vector pulse width modulation for Electric Vehicle Applications', in *2023 4th International Conference for Emerging Technology (INCET)*, May 2023, pp. 1–7. doi: 10.1109/INCET57972.2023.10170609.
- [20] C. P. Gor and V. A. Shah, 'Drive Cycle based Analysis and Control of Five Phase Induction Motor Drive for Electric Vehicle', in *2023 IEEE IAS Global Conference on Emerging Technologies (GlobConET)*, May 2023, pp. 1–6. doi: 10.1109/GlobConET56651.2023.10150189.
- [21] Y. Chen, X. Zhao, Y. Yang, and Y. Shi, 'Online Diagnosis of Inter-turn Short Circuit for Dual-Redundancy Permanent Magnet Synchronous Motor Based on Reactive Power Difference', *Energies*, vol. 12, no. 3, Art. no. 3, Jan. 2019, doi: 10.3390/en12030510.
- [22] Y. He, M.-Q. Ke, G.-J. Tang, H.-C. Jiang, and X.-H. Yuan, 'Analysis and Simulation on the Effect of Rotor Interturn Short Circuit on Magnetic Flux Density of Turbo-Generator', *J. Electr. Eng.*, vol. 67, Sep. 2016, doi: 10.1515/jee-2016-0047.
- [23] W. Yucai and L. Yonggang, 'Diagnosis of Rotor Winding Interturn Short-Circuit in Turbine Generators Using Virtual Power', *IEEE Trans. Energy Convers.*, vol. 30, no. 1, pp. 183–188, Mar. 2015, doi: 10.1109/TEC.2014.2339300.

- [24] P. J. Broniera, W. S. Gongora, A. Goedel, and W. F. Godoy, 'Diagnosis of stator winding inter-turn short circuit in three-phase induction motors by using artificial neural networks', in *2013 9th IEEE International Symposium on Diagnostics for Electric Machines, Power Electronics and Drives (SDEMPED)*, VALENCIA, Spain: IEEE, Aug. 2013, pp. 281–287. doi: 10.1109/DEMPEP.2013.6645729.
- [25] W. Pietrowski and K. Górny, 'Detection of inter-turn short-circuit at start-up of induction machine based on torque analysis', *Open Phys.*, vol. 15, no. 1, pp. 851–856, Jan. 2017, doi: 10.1515/phys-2017-0101.
- [26] W. Pietrowski and K. Gorny, 'Wavelet analysis of torque at startup of an induction machine under inter-turn short-circuit', in *2017 International Symposium on Electrical Machines (SME)*, Naleczow, Poland: IEEE, Jun. 2017, pp. 1–4. doi: 10.1109/ISEM.2017.7993562.
- [27] H. Abdallah and K. Benatman, 'Stator winding inter-turn short-circuit detection in induction motors by parameter identification', *IET Electr. Power Appl.*, vol. 11, no. 2, pp. 272–288, 2017, doi: 10.1049/iet-epa.2016.0432.
- [28] G. N. Surya, Z. J. Khan, M. S. Ballal, and H. M. Suryawanshi, 'A Simplified Frequency-Domain Detection of Stator Turn Fault in Squirrel-Cage Induction Motors Using an Observer Coil Technique', *IEEE Trans. Ind. Electron.*, vol. 64, no. 2, pp. 1495–1506, Feb. 2017, doi: 10.1109/TIE.2016.2611585.
- [29] R. A. K. Aswad and B. M. H. Jassim, 'Open-circuit fault diagnosis in three-phase induction motor using model-based technique', *Arch. Electr. Eng. 2020 Vol 69 No 4 815-827*, 2020, Accessed: Nov. 14, 2022. [Online]. Available: <https://journals.pan.pl/dlibra/publication/134632/edition/117665>
- [30] M. Wolkiewicz, G. Tarchala, T. Orłowska-Kowalska, and C. T. Kowalski, 'Online Stator Interturn Short Circuits Monitoring in the DFOC Induction-Motor Drive', *IEEE Trans. Ind. Electron.*, vol. 63, no. 4, pp. 2517–2528, Apr. 2016, doi: 10.1109/TIE.2016.2520902.
- [31] B. Huang *et al.*, 'A Performance Evaluation of Two Bispectrum Analysis Methods Applied to Electrical Current Signals for Monitoring Induction Motor-Driven Systems', *Energies*, vol. 12, no. 8, Art. no. 8, Jan. 2019, doi: 10.3390/en12081438.
- [32] S. S. Dhamal and M. V. Bhatkar, 'Modelling and Simulation of Three-Phase Induction Motor to Diagnose the Performance on Inter-Turn Short Circuit Fault in Stator Winding', in *2018 International Conference on Computing, Power and Communication Technologies (GUCON)*, Sep. 2018, pp. 1166–1172. doi: 10.1109/GUCON.2018.8674900.
- [33] A. Berzoy, A. A. S. Mohamed, and O. Mohammed, 'Impact of Inter-Turn Short-Circuit Location on Induction Machines Parameters Through FE Computations', *IEEE Trans. Magn.*, vol. 53, no. 6, pp. 1–4, Jun. 2017, doi: 10.1109/TMAG.2017.2665639.
- [34] C. Zoeller, Th. M. Wolbank, and M. A. Vogelsberger, 'Influence of voltage excitation and current sensors on monitoring of stator winding insulation based on transient current step response', in *2015 IEEE Energy Conversion Congress and Exposition (ECCE)*, Montreal, QC, Canada: IEEE, Sep. 2015, pp. 2854–2861. doi: 10.1109/ECCE.2015.7310060.
- [35] M. B. K. Bouzid and G. Champenois, 'Neural network based method for the automatic detection of the stator faults of the induction motor', in *2013 International Conference on Electrical Engineering and Software Applications*,

- Hammamet, Tunisia: IEEE, Mar. 2013, pp. 1–7. doi: 10.1109/ICEESA.2013.6578393.
- [36] ‘Report of Large Motor Reliability Survey of Industrial and Commercial Installations, Part I’, *IEEE Trans. Ind. Appl.*, vol. IA-21, no. 4, pp. 853–864, Jul. 1985, doi: 10.1109/TIA.1985.349532.
- [37] M. Wolkiewicz and C. T. Kowalski, ‘Incipient stator fault detector based on neural networks end symmetrical components analysis for induction motor drives’, in *2016 13th Selected Issues of Electrical Engineering and Electronics (WZEE)*, Rzeszow, Poland: IEEE, May 2016, pp. 1–7. doi: 10.1109/WZEE.2016.7800214.
- [38] T. Sellami, H. Berriri, S. Jelassi, A. M. Darcherif, and M. F. Mimouni, ‘Short-Circuit Fault Tolerant Control of a Wind Turbine Driven Induction Generator Based on Sliding Mode Observers’, *Energies*, vol. 10, no. 10, Art. no. 10, Oct. 2017, doi: 10.3390/en10101611.
- [39] M. Sulowicz, R. Mielnik, and M. Tomczyk, ‘The Detection of Inter-Turn Shorting in Induction Motor by Means of Using Algorithm of Decision Tree’, in *2021 11th IEEE International Conference on Intelligent Data Acquisition and Advanced Computing Systems: Technology and Applications (IDAACS)*, Cracow, Poland: IEEE, Sep. 2021, pp. 818–823. doi: 10.1109/IDAACS53288.2021.9661035.
- [40] S. E. Zouzou, M. Sahraoui, A. Ghoggal, and S. Guedidi, ‘Detection of inter-turn short-circuit and broken rotor bars in induction motors using the Partial Relative Indexes: Application on the MCSA’, in *The XIX International Conference on Electrical Machines - ICEM 2010*, Sep. 2010, pp. 1–6. doi: 10.1109/ICELMACH.2010.5607874.
- [41] M. Ojaghi and M. Mohammadi, ‘Unified Modeling Technique for Axially Uniform and Nonuniform Eccentricity Faults in Three-Phase Squirrel Cage Induction Motors’, *IEEE Trans. Ind. Electron.*, vol. 65, no. 7, pp. 5292–5301, Jul. 2018, doi: 10.1109/TIE.2017.2760280.
- [42] A. Berzoy, A. A. S. Mohamed, and O. Mohammed, ‘Complex-Vector Model of Interturn Failure in Induction Machines for Fault Detection and Identification’, *IEEE Trans. Ind. Appl.*, vol. 53, no. 3, pp. 2667–2678, May 2017, doi: 10.1109/TIA.2016.2632068.
- [43] W. Pietrowski and K. Górny, ‘Analysis of Torque Ripples of an Induction Motor Taking into Account a Inter-Turn Short-Circuit in a Stator Winding’, *Energies*, vol. 13, no. 14, Art. no. 14, Jan. 2020, doi: 10.3390/en13143626.
- [44] Kowalski Czesław T., ‘Diagnostyka układów napędowych z silnikiem indukcyjnym z zastosowaniem metod sztucznej inteligencji – Oficyna Wydawnicza Politechniki Wrocławskiej’. Accessed: Nov. 14, 2022. [Online]. Available: <http://www.oficyna.pwr.edu.pl/ksiazki/diagnostyka-ukladow-napedowych-z-silnikiem-indukcyjnym-z-zastosowaniem-metod-sztucznej-inteligencji/>
- [45] C. Kowalski, M. Wolkiewicz, and P. Ewert, ‘Analiza zwarć zwojowych stojana silnika indukcyjnego zasilanego z sieci i przemiennika częstotliwości’, *Przegląd Elektrotechniczny*, vol. R. 84, nr 12, pp. 64–67, 2008.
- [46] C. Zoeller, Th. M. Wolbank, and M. A. Vogelsberger, ‘Online insulation condition monitoring of traction machines using inverter induced voltage injection’, in *IECON 2015 - 41st Annual Conference of the IEEE Industrial*

- Electronics Society*, Yokohama: IEEE, Nov. 2015, pp. 002456–002462. doi: 10.1109/IECON.2015.7392471.
- [47] S. J. Williamson, R. Wrobel, J. Yon, J. D. Booker, and P. H. Mellor, ‘Investigation of equivalent stator-winding thermal resistance during insulation system ageing’, in *2017 IEEE 11th International Symposium on Diagnostics for Electrical Machines, Power Electronics and Drives (SDEMPED)*, Tinos, Greece: IEEE, Aug. 2017, pp. 550–556. doi: 10.1109/DEMPED.2017.8062409.
- [48] D. G. Dorrell and K. Makhoba, ‘Detection of Inter-Turn Stator Faults in Induction Motors Using Short-Term Averaging of Forward and Backward Rotating Stator Current Phasors for Fast Prognostics’, *IEEE Trans. Magn.*, vol. 53, no. 11, pp. 1–7, Nov. 2017, doi: 10.1109/TMAG.2017.2710181.
- [49] C. Zoeller, M. A. Vogelsberger, R. Fasching, W. Grubelnik, and T. M. Wolbank, ‘Evaluation and Current-Response-Based Identification of Insulation Degradation for High Utilized Electrical Machines in Railway Application’, *IEEE Trans. Ind. Appl.*, vol. 53, no. 3, pp. 2679–2689, May 2017, doi: 10.1109/TIA.2017.2661718.
- [50] M. F. Cabanas *et al.*, ‘Detection of stator winding insulation failures: On-line and off-line tests’, in *2013 IEEE Workshop on Electrical Machines Design, Control and Diagnosis (WEMDCD)*, Paris: IEEE, Mar. 2013, pp. 210–219. doi: 10.1109/WEMDCD.2013.6525181.
- [51] V. C. M. N. Leite *et al.*, ‘Detection of Localized Bearing Faults in Induction Machines by Spectral Kurtosis and Envelope Analysis of Stator Current’, *IEEE Trans. Ind. Electron.*, vol. 62, no. 3, pp. 1855–1865, Mar. 2015, doi: 10.1109/TIE.2014.2345330.
- [52] Z. F. Khan *et al.*, ‘Fault Diagnosis of Three Phase Induction Motor Using Current Signal, MSAF-Ratio15 and Selected Classifiers’, *Arch. Metall. Mater. 2017 Vol 62 No 4*, 2017, Accessed: Nov. 14, 2022. [Online]. Available: <https://www.czasopisma.pan.pl/dlibra/publication/120917/edition/105324>
- [53] J. Rangel-Magdaleno, H. Peregrina-Barreto, J. Ramirez-Cortes, R. Morales-Caporal, and I. Cruz-Vega, ‘Vibration Analysis of Partially Damaged Rotor Bar in Induction Motor under Different Load Condition Using DWT’, *Shock Vib.*, vol. 2016, p. e3530464, Feb. 2016, doi: 10.1155/2016/3530464.
- [54] E. Elbouchikhi, Y. Amirat, G. Feld, and M. Benbouzid, ‘Generalized Likelihood Ratio Test Based Approach for Stator-Fault Detection in a PWM Inverter-Fed Induction Motor Drive’, *IEEE Trans. Ind. Electron.*, vol. 66, no. 8, pp. 6343–6353, Aug. 2019, doi: 10.1109/TIE.2018.2875665.
- [55] C. Bouchareb and M. S. Nait-Said, ‘PMSM Model with Phase-to-Phase Short-Circuit and Diagnosis by ESA and EPVA’, *Adv. Electr. Electron. Eng.*, vol. 14, no. 5, Art. no. 5, Dec. 2016, doi: 10.15598/aeec.v14i5.1928.
- [56] A. M. da Silva, Povinelli, and Demerdash, ‘Rotor Bar Fault Monitoring Method Based on Analysis of Air-Gap Torques of Induction Motors’, *IEEE Trans. Ind. Inform.*, vol. 9, no. 4, pp. 2274–2283, Nov. 2013, doi: 10.1109/TII.2013.2242084.
- [57] K. N. Gyftakis and A. J. Marques-Cardoso, ‘Reliable Detection of Very Low Severity Level Stator Inter-Turn Faults in Induction Motors’, in *IECON 2019 - 45th Annual Conference of the IEEE Industrial Electronics Society*, Lisbon, Portugal: IEEE, Oct. 2019, pp. 1290–1295. doi: 10.1109/IECON.2019.8926928.
- [58] V. Fireteanu, ‘Detection of the Short-Circuit Faults in the Stator Winding of Induction Motors based on Harmonics of the Neighboring Magnetic Field’, *J.*

- Phys. Conf. Ser.*, vol. 450, no. 1, p. 012021, Jun. 2013, doi: 10.1088/1742-6596/450/1/012021.
- [59] B. Wang, J. Wang, A. Griffo, and B. Sen, ‘Stator Turn Fault Detection by Second Harmonic in Instantaneous Power for a Triple-Redundant Fault-Tolerant PM Drive’, *IEEE Trans. Ind. Electron.*, vol. 65, no. 9, pp. 7279–7289, Sep. 2018, doi: 10.1109/TIE.2018.2793188.
- [60] M. Skowron, M. Wolkiewicz, T. Orłowska-Kowalska, and C. T. Kowalski, ‘Effectiveness of Selected Neural Network Structures Based on Axial Flux Analysis in Stator and Rotor Winding Incipient Fault Detection of Inverter-fed Induction Motors’, *Energies*, vol. 12, no. 12, Art. no. 12, Jan. 2019, doi: 10.3390/en12122392.
- [61] R. N. Dash and B. Subudhi, ‘Stator inter-turn fault detection of an induction motor using neuro-fuzzy techniques’, *Arch. Control Sci.*, vol. Vol. 20, no. 3, pp. 363–376, 2010.
- [62] A. Mohammed, J. I. Melecio, and S. Djurovic, ‘Stator Winding Fault Thermal Signature Monitoring and Analysis by *In Situ* FBG Sensors’, *IEEE Trans. Ind. Electron.*, vol. 66, no. 10, pp. 8082–8092, Oct. 2019, doi: 10.1109/TIE.2018.2883260.
- [63] M. Baranski, ‘FE analysis of coupled electromagnetic-thermal phenomena in the squirrel cage motor working at high ambient temperature’, *COMPEL - Int. J. Comput. Math. Electr. Electron. Eng.*, vol. 38, no. 4, pp. 1120–1132, Jan. 2019, doi: 10.1108/COMPEL-10-2018-0384.
- [64] M. Skowron, T. Orłowska-Kowalska, M. Wolkiewicz, and C. T. Kowalski, ‘Convolutional Neural Network-Based Stator Current Data-Driven Incipient Stator Fault Diagnosis of Inverter-Fed Induction Motor’, *Energies*, vol. 13, no. 6, Art. no. 6, Jan. 2020, doi: 10.3390/en13061475.
- [65] H. Nakamura and Y. Mizuno, ‘Method for Diagnosing a Short-Circuit Fault in the Stator Winding of a Motor Based on Parameter Identification of Features and a Support Vector Machine’, *Energies*, vol. 13, no. 9, Art. no. 9, Jan. 2020, doi: 10.3390/en13092272.
- [66] L. Maraaba, Z. Al-Hamouz, and M. Abido, ‘An Efficient Stator Inter-Turn Fault Diagnosis Tool for Induction Motors’, *Energies*, vol. 11, no. 3, Art. no. 3, Mar. 2018, doi: 10.3390/en11030653.
- [67] J. Tulicki, T. J. Sobczyk, and M. Sulowicz, ‘Diagnostics of a double-cage induction motor under steady state with the rotor asymmetry’, in *2023 IEEE 14th International Symposium on Diagnostics for Electrical Machines, Power Electronics and Drives (SDEMPED)*, Chania, Greece: IEEE, Aug. 2023, pp. 251–257. doi: 10.1109/SDEMPED54949.2023.10271416.
- [68] T. J. Sobczyk, J. Tulicki, K. Weinreb, R. Mielnik, and M. Sulowicz, ‘Characteristic Features of Rotor Bar Current Frequency Spectrum in Cage Induction Machine with Inner Faults’, in *2019 IEEE 12th International Symposium on Diagnostics for Electrical Machines, Power Electronics and Drives (SDEMPED)*, Toulouse, France: IEEE, Aug. 2019, pp. 115–120. doi: 10.1109/DEMPED.2019.8864907.
- [69] J. Tulicki, T. J. Sobczyk, and M. Sulowicz, ‘Simplified Methodology for Analysis of Electromechanical Interactions in AC Machines at Steady-State Performances’, in *2021 IEEE 13th International Symposium on Diagnostics for Electrical Machines, Power Electronics and Drives (SDEMPED)*, Dallas, TX,

- USA: IEEE, Aug. 2021, pp. 167–172. doi: 10.1109/SDEMPED51010.2021.9605528.
- [70] S. Kumar *et al.*, ‘A Comprehensive Review of Condition Based Prognostic Maintenance (CBPM) for Induction Motor’, *IEEE Access*, vol. 7, pp. 90690–90704, Jul. 2019.
- [71] C. Pezzani, P. Donolo, G. Bossio, M. Donolo, and A. Guzman, ‘Detecting Broken Rotor Bars With Zero-Setting Protection’, *Ind. Appl. IEEE Trans. On*, vol. 50, pp. 1–12, May 2014, doi: 10.1109/ICPS.2012.6229616.
- [72] Skowron M., *Diagnostyka uszkodzeń silników indukcyjnych i synchronicznych z magnesami trwałymi przy wykorzystaniu sieci neuronowych z głębokim uczeniem*, Rozprawa Doktorska. Politechnika Wrocławska.
- [73] R. A. Martis, B. Varaticeanu, F. A. Pop Piglesan, M. Sulowicz, and C. S. Martis, ‘Permanent Magnet Assisted Synchronous Reluctance Machine validation for NDEC standard assesment’, in *2022 ELEKTRO (ELEKTRO)*, Krakow, Poland: IEEE, May 2022, pp. 1–5. doi: 10.1109/ELEKTRO53996.2022.9803327.
- [74] P. Waide and C. Brunner, ‘Energy-Efficiency Policy Opportunities for Electric Motor-Driven Systems’, Jan. 2011.
- [75] B. Xu, K. Yang, F. Jiang, S. Sun, and Y. Luo, ‘D-Q Axis Inductance Analytical Calculation for Fractional-Slot Distributed Winding IPM Motor Based on Big-Small Pole Space Method’, *IEEE Trans. Ind. Electron.*, vol. 71, no. 2, pp. 1341–1354, Feb. 2024, doi: 10.1109/TIE.2023.3247779.
- [76] H. R. P. Antunes, D. S. B. Fonseca, and A. J. Marques Cardoso, ‘The Use of The Line Impedance Symmetrical Components for Stator Faults Detection and Location in Symmetrical Six-Phase Induction Motors’, in *2023 IEEE 14th International Symposium on Diagnostics for Electrical Machines, Power Electronics and Drives (SDEMPED)*, Aug. 2023, pp. 279–284. doi: 10.1109/SDEMPED54949.2023.10271476.
- [77] Y. Wang, T. Hou, M. Cui, and X. Ma, ‘Orthogonal Stationary Component Analysis for Nonstationary Process Monitoring’, *IEEE Trans. Instrum. Meas.*, vol. 72, pp. 1–9, 2023, doi: 10.1109/TIM.2023.3306541.
- [78] A. Demenko, ‘Movement simulation in finite element analysis of electric machine dynamics’, *IEEE Trans. Magn.*, vol. 32, no. 3, pp. 1553–1556, May 1996, doi: 10.1109/20.497547.
- [79] W. Hudy and K. Jaracz, ‘Przegląd modeli matematycznych maszyny indukcyjnej’, *Wydaw. Nauk. Akad. Pedagog.*, vol. 32, Kraków 2006.
- [80] M. Jagiela, T. Garbiec, J. Gwozdz, and J. Kolodziej, ‘Fast Steady-State Field-Circuit Model for SMPM-BLdc Motors Driven From 120° and 180° Quasi-Square Wave Inverters’, *IEEE Trans. Magn.*, vol. 52, no. 3, pp. 1–4, Mar. 2016, doi: 10.1109/TMAG.2015.2482986.
- [81] N. F. Oyman Serteller, ‘Electromagnetic Wave Propagation Equations in 2D by Finite Difference Method: Mathematical Case’, in *2019 3rd International Symposium on Multidisciplinary Studies and Innovative Technologies (ISMSIT)*, Oct. 2019, pp. 1–5. doi: 10.1109/ISMSIT.2019.8932851.
- [82] Z. Luo, ‘Finite Difference Method Based on Node Set Vector for Numerical Computation of Poisson Equation’, in *2022 5th International Conference on Intelligent Robotics and Control Engineering (IRCE)*, Sep. 2022, pp. 71–75. doi: 10.1109/IRCE55557.2022.9963071.
- [83] A. Demenko and J. K. Sykulski, ‘Analogies Between Finite-Difference and Finite-Element Methods for Scalar and Vector Potential Formulations in

- Magnetic Field Calculations’, *IEEE Trans. Magn.*, vol. 52, no. 6, pp. 1–6, Jun. 2016, doi: 10.1109/TMAG.2016.2521345.
- [84] B. Yan, X. Li, X. Wang, Y. Yang, and D. Chen, ‘Magnetic Field Prediction for Line-Start Permanent Magnet Synchronous Motor via Incorporating Geometry Approximation and Finite Difference Method Into Subdomain Model’, *IEEE Trans. Ind. Electron.*, vol. 70, no. 3, pp. 2843–2854, Mar. 2023, doi: 10.1109/TIE.2022.3170621.
- [85] S. Bimurzaev, Z. Sautbekova, and A. Trubitsyn, ‘Boundary and Current Elements for Simulation of Electromagnetic Fields’, in *2021 IEEE International Conference on Smart Information Systems and Technologies (SIST)*, Apr. 2021, pp. 1–5. doi: 10.1109/SIST50301.2021.9465941.
- [86] M. Liebsch, S. Russenschuck, and S. Kurz, ‘Boundary-Element Methods for Field Reconstruction in Accelerator Magnets’, *IEEE Trans. Magn.*, vol. 56, no. 3, pp. 1–4, Mar. 2020, doi: 10.1109/TMAG.2019.2952092.
- [87] M. Aliahmadi, H. Tahanian, M. Moallem, and R. Nasiri-Zarandi, ‘On the Use of Boundary Element Method for the Study of Low Frequency Electromagnetic Devices’, in *2018 International Symposium on Power Electronics, Electrical Drives, Automation and Motion (SPEEDAM)*, Jun. 2018, pp. 1113–1118. doi: 10.1109/SPEEDAM.2018.8445409.
- [88] S. Yin, L. D. Rienzo, X. Ma, and Y. Huangfu, ‘Boundary Element Formulation Enforcing High-Order Surface Impedance Boundary Conditions for Axisymmetric Eddy Current Problems’, *IEEE Trans. Magn.*, vol. 57, no. 8, pp. 1–9, Aug. 2021, doi: 10.1109/TMAG.2021.3090248.
- [89] F. Mujaahid and M. Y. Mustar, ‘Iron Losses Quick Prediction of Permanent Magnet Synchronous Motor Based on FEM Analysis’, in *2022 2nd International Conference on Electronic and Electrical Engineering and Intelligent System (ICE3IS)*, Nov. 2022, pp. 94–98. doi: 10.1109/ICE3IS56585.2022.10010133.
- [90] S. Sarkar, D. Roy, and M. Sengupta, ‘Design and FEM validation of Double Sided Axial Flux Switched Reluctance Motor’, in *2018 IEEE International Conference on Power Electronics, Drives and Energy Systems (PEDES)*, Dec. 2018, pp. 1–6. doi: 10.1109/PEDES.2018.8707525.
- [91] S. Das, D. Roy, and M. Sengupta, ‘Detailed FEM-based Analysis of Vibration in a 3-phase Switched Reluctance Motor and its Experimental Validation’, in *2022 IEEE International Conference on Signal Processing, Informatics, Communication and Energy Systems (SPICES)*, Mar. 2022, pp. 525–530. doi: 10.1109/SPICES52834.2022.9774166.
- [92] P. Pečínka, S. Kocman, and V. Pečínková, ‘Use of FEM modeling to optimize the design of induction motor’, in *2022 ELEKTRO (ELEKTRO)*, May 2022, pp. 1–6. doi: 10.1109/ELEKTRO53996.2022.9803602.
- [93] D. Zhang, L. Bu, C. He, R. An, and T. Wu, ‘A modified 2-D multislice FEM for computing the airgap flux density of induction motor with skewed slots’, in *2017 IEEE International Electric Machines and Drives Conference (IEMDC)*, May 2017, pp. 1–8. doi: 10.1109/IEMDC.2017.8002097.
- [94] L. Livadaru, A. Bobu, A. Munteanu, B. Vîrlan, and A. Simion, ‘FEM-based analysis on the operation of three-phase induction motor connected to six-phase supply system: Part 1 — Operation under healthy conditions’, in *2017 International Conference on Electromechanical and Power Systems (SIELMEN)*, Oct. 2017, pp. 119–124. doi: 10.1109/SIELMEN.2017.8123310.

- [95] D. Roy, Sk. Mainuddin, and M. Sengupta, ‘Design, analysis, FEM validation and fabrication of a switched reluctance motor’, in *2017 National Power Electronics Conference (NPEC)*, Dec. 2017, pp. 160–165. doi: 10.1109/NPEC.2017.8310452.
- [96] A. R. Maulidi and A. Purwadi, ‘Modeling and analysis of cooling system permanent magnet synchronous motor 30 kW for city EV with FEM’, in *2017 4th International Conference on Electric Vehicular Technology (ICEVT)*, Oct. 2017, pp. 36–41. doi: 10.1109/ICEVT.2017.8323530.
- [97] Z. Haisen, W. Yilong, W. Yuhan, Z. Yang, and X. Guorui, ‘Loss and Air-gap Force Analysis of Cage Induction Motors With Non-skewed Asymmetrical Rotor Bars Based on FEM’, *IEEE Trans. Magn.*, vol. 53, no. 6, pp. 1–4, Jun. 2017, doi: 10.1109/TMAG.2017.2660762.
- [98] J. B. Padilha, P. Kuo-Peng, N. Sadowski, and N. J. Batistela, ‘Vector Hysteresis Model Associated to FEM in a Hysteresis Motor Modeling’, *IEEE Trans. Magn.*, vol. 53, no. 6, pp. 1–4, Jun. 2017, doi: 10.1109/TMAG.2017.2664582.
- [99] L. Livadaru, A. Bobu, A. Munteanu, B. Vîrlan, and A. Simion, ‘FEM-based analysis on the operation of three-phase induction motor connected to six-phase supply system: Part 2 — Study on fault-tolerance capability’, in *2017 International Conference on Electromechanical and Power Systems (SIELMEN)*, Oct. 2017, pp. 125–130. doi: 10.1109/SIELMEN.2017.8123311.
- [100] T. Garbiec, M. Jagiela, and M. Kulik, ‘Application of Nonlinear Complex Polyharmonic Finite-Element Models of High-Speed Solid-Rotor Induction Motors’, *IEEE Trans. Magn.*, vol. 56, no. 4, pp. 1–4, Apr. 2020, doi: 10.1109/TMAG.2019.2953987.
- [101] M. Jagiela and M. Kulik, ‘Analytical Model of a Nonlinear Vibration Energy Harvester’, in *2018 International Symposium on Electrical Machines (SME)*, Jun. 2018, pp. 1–5. doi: 10.1109/ISEM.2018.8442605.
- [102] Zienkiewicz O. and Taylor T., *The Finite Element Method*, vol. 1–2. McGraw-Hill Book Company, 1989.
- [103] Wojciechowski R., *Numeryczna analiza prądów indukowanych w jednoczłonowych i wieloczłonowych obszarach przewodzących*, Rozprawa doktorska. Politechnika Poznańska, 2010.
- [104] Kurzawa M., *Obwodowo – polowa analiza i synteza układów uzwojeń w systemach bezprzewodowej transmisji energii elektrycznej*, Rozprawa Doktorska. Politechnika Poznańska, 2023.
- [105] Zufeng Wang and Pu Zhao, ‘Fault location recognition in transmission lines based on Support Vector Machines’, in *2009 2nd IEEE International Conference on Computer Science and Information Technology*, Beijing, China: IEEE, 2009, pp. 401–404. doi: 10.1109/ICCSIT.2009.5234528.
- [106] I. Aydin, M. Karakose, and E. Akin, ‘Artificial immune based support vector machine algorithm for fault diagnosis of induction motors’, in *2007 International Aegean Conference on Electrical Machines and Power Electronics*, Bodrum, Turkey: IEEE, Sep. 2007, pp. 217–221. doi: 10.1109/ACEMP.2007.4510505.
- [107] H. Guo and M.-K. Liu, ‘Induction motor faults diagnosis using support vector machine to the motor current signature’, in *2018 IEEE Industrial Cyber-Physical Systems (ICPS)*, St. Petersburg: IEEE, May 2018, pp. 417–421. doi: 10.1109/ICPHYS.2018.8390701.
- [108] G. Jagadanand and F. L. Dias, ‘ARM based induction motor fault detection using wavelet and support vector machine’, in *2015 IEEE International Conference on*

- Signal Processing, Informatics, Communication and Energy Systems (SPICES)*, Kozhikode, India: IEEE, Feb. 2015, pp. 1–4. doi: 10.1109/SPICES.2015.7091503.
- [109] Ngoc-Tu Nguyen, Jeong-Min Kwon, and Hong-Hee Lee, ‘Fault diagnosis of induction motor using decision tree with an optimal feature selection’, in *2007 7th International Conference on Power Electronics*, Daegu, South Korea: IEEE, Oct. 2007, pp. 729–732. doi: 10.1109/ICPE.2007.4692484.
- [110] L. Zhi, J. Yuanliang, and X. Zhongheng, ‘Anti-noise motor fault diagnosis method based on decision tree and the feature extraction methods in the time domain and frequency domain’, in *2021 International Conference on Communications, Information System and Computer Engineering (CISCE)*, Beijing, China: IEEE, May 2021, pp. 71–75. doi: 10.1109/CISCE52179.2021.9446018.
- [111] E. Irgat, A. Unsal, and H. T. Canseven, ‘Detection of Eccentricity Faults of Induction Motors Based on Decision Trees’, in *2021 13th International Conference on Electrical and Electronics Engineering (ELECO)*, Bursa, Turkey: IEEE, Nov. 2021, pp. 435–439. doi: 10.23919/ELECO54474.2021.9677809.
- [112] K. V. Surti and C. A. Naik, ‘Bearing Condition Monitoring of Induction Motor Based on Discrete Wavelet Transform & K-nearest Neighbor’, in *2018 3rd International Conference for Convergence in Technology (I2CT)*, Pune: IEEE, Apr. 2018, pp. 1–5. doi: 10.1109/I2CT.2018.8529687.
- [113] C. A. Borja, K. J. Tisado, and C. Ostia, ‘Fault Diagnosis of a Brushless DC Motor Using K-Nearest Neighbor Classification Technique with Discrete Wavelet Transform Feature Extraction’, in *2022 14th International Conference on Computer and Automation Engineering (ICCAE)*, Brisbane, Australia: IEEE, Mar. 2022, pp. 122–126. doi: 10.1109/ICCAE55086.2022.9762425.
- [114] A. Sharma, R. Jigyasu, L. Mathew, and S. Chatterji, ‘Bearing Fault Diagnosis Using Weighted K-Nearest Neighbor’, in *2018 2nd International Conference on Trends in Electronics and Informatics (ICOEI)*, Tirunelveli: IEEE, May 2018, pp. 1132–1137. doi: 10.1109/ICOEI.2018.8553800.
- [115] Włodzisław Duch, Józef Korbicz, Leszek Rutkowski, and Ryszard Tadeusiewicz, *Biocybernetyka i inżynieria biomedyczna 2000 Tom 6 Sztuczne sieci neuronowe*, vol. 6. Warszawa: Akademicka Oficyna Wydawnicza EXIT, 2000.
- [116] M. T. Hagan and M. B. Menhaj, ‘Training feedforward networks with the Marquardt algorithm’, *IEEE Trans. Neural Netw.*, vol. 5, no. 6, pp. 989–993, Nov. 1994, doi: 10.1109/72.329697.
- [117] A. Rusiecki, ‘Algorytmy uczenia sieci neuronowych odporne na błędy w danych’. Accessed: Nov. 14, 2022. [Online]. Available: https://www.dbc.wroc.pl/Content/1908/Rusiecki_Algoritmy_PhD.pdf
- [118] W. Jiao and Y. Chang, ‘ICA-MLP classifier for fault diagnosis of rotor system’, in *2009 IEEE International Conference on Automation and Logistics*, Shenyang, China: IEEE, Aug. 2009, pp. 997–1001. doi: 10.1109/ICAL.2009.5262565.
- [119] W. Jiao and Y. Chang, ‘Fault diagnosis of rotor systems using ICA based feature extraction’, in *2009 IEEE International Conference on Robotics and Biomimetics (ROBIO)*, Guilin, China: IEEE, Dec. 2009, pp. 1286–1291. doi: 10.1109/ROBIO.2009.5420827.
- [120] Zhongming Ye and Bin Wu, ‘Online rotor bar breakage detection of three phase induction motors by wavelet packet decomposition and artificial neural network’, in *2001 IEEE 32nd Annual Power Electronics Specialists Conference (IEEE Cat.*

- No.01CH37230), Vancouver, BC, Canada: IEEE, 2001, pp. 2209–2216. doi: 10.1109/PESC.2001.954448.
- [121] U. Dongare, B. Umre, M. Ballal, and V. Dongare, ‘Design of Optimal MLP-Neural Network-based Induction Motor Fault Classifier’, in *2022 IEEE International Conference on Power Electronics, Smart Grid, and Renewable Energy (PESGRE)*, Trivandrum, India: IEEE, Jan. 2022, pp. 1–6. doi: 10.1109/PESGRE52268.2022.9715874.
- [122] R. N. Dash, B. Subudhi, and S. Das, ‘A comparison between MLP NN and RBF NN techniques for the detection of stator inter-turn fault of an induction motor’, in *2010 International Conference on Industrial Electronics, Control and Robotics*, Orissa: IEEE, Dec. 2010, pp. 251–256. doi: 10.1109/IECR.2010.5720163.
- [123] R. H. C. Palacios, I. N. da Silva, A. Goedel, W. F. Godoy, and T. D. Lopes, ‘Diagnosis of Stator Faults Severity in Induction Motors Using Two Intelligent Approaches’, *IEEE Trans. Ind. Inform.*, vol. 13, no. 4, pp. 1681–1691, Aug. 2017, doi: 10.1109/TII.2017.2696978.
- [124] W. Pietrowski and K. Gorny, ‘Wavelet torque analysis and neural network in detection of induction motor inter-turn short-circuit’, in *2017 18th International Symposium on Electromagnetic Fields in Mechatronics, Electrical and Electronic Engineering (ISEF) Book of Abstracts*, Lodz: IEEE, Sep. 2017, pp. 1–2. doi: 10.1109/ISEF.2017.8090751.
- [125] D. N. Coelho, G. A. Barreto, C. M. S. Medeiros, and J. D. A. Santos, ‘Performance comparison of classifiers in the detection of short circuit incipient fault in a three-phase induction motor’, in *2014 IEEE Symposium on Computational Intelligence for Engineering Solutions (CIES)*, Orlando, FL, USA: IEEE, Dec. 2014, pp. 42–48. doi: 10.1109/CIES.2014.7011829.
- [126] A. Aljohani, ‘Centralized Fault Detection and Classification for Motor Power Distribution Centers Utilizing MLP-NN and Stockwell Transform’, in *2020 IEEE PES Innovative Smart Grid Technologies Europe (ISGT-Europe)*, The Hague, Netherlands: IEEE, Oct. 2020, pp. 222–226. doi: 10.1109/ISGT-Europe47291.2020.9248886.
- [127] O. Rahmani, M. Iltarabian, and S. A. Sadrossadat, ‘Modeling and Simulation of Speed and Efficiency of BLDC Motor as A Starter Motor Based on Multilayer Perceptron (MLP) Neural Network’, in *2018 IEEE Transportation Electrification Conference and Expo, Asia-Pacific (ITEC Asia-Pacific)*, Bangkok: IEEE, Jun. 2018, pp. 1–5. doi: 10.1109/ITEC-AP.2018.8433299.
- [128] V. Tipsuwanporn, C. Tarasantisuk, A. Numsumran, and W. Sawaengsinkasikit, ‘Motor speed identification using multilayer feedforward neural networks’, in *4th IEEE International Conference on Power Electronics and Drive Systems. IEEE PEDS 2001 - Indonesia. Proceedings (Cat. No.01TH8594)*, Denpasar, Indonesia: IEEE, 2001, pp. 62–65. doi: 10.1109/PEDS.2001.975285.
- [129] E. Germen, M. Başaran, and M. Fidan, ‘Sound based induction motor fault diagnosis using Kohonen self-organizing map’, *Mech. Syst. Signal Process.*, vol. 46, no. 1, pp. 45–58, May 2014, doi: 10.1016/j.ymsp.2013.12.002.
- [130] T. Kato, K. Inoue, T. Takahashi, and Y. Kono, ‘Automatic Fault Diagnosis Method of Electrical Machinery and Apparatus by Using Kohonen’s Self-Organizing Map’, in *2007 Power Conversion Conference - Nagoya*, Nagoya, Japan: IEEE, Apr. 2007, pp. 1224–1229. doi: 10.1109/PCCON.2007.373122.

- [131] M. Wolkiewicz, M. Skowron, and C. T. Kowalski, 'Electrical Fault Diagnostic System Based on the Kohonen Neural Network Classifier', in *2018 International Symposium on Electrical Machines (SME)*, Andrychów: IEEE, Jun. 2018, pp. 1–5. doi: 10.1109/ISEM.2018.8442673.
- [132] S. Jacobs and F. Rios-Gutierrez, 'Self organizing maps for monitoring parameter deterioration of DC and AC motors', in *2013 Proceedings of IEEE Southeastcon*, Jacksonville, FL, USA: IEEE, Apr. 2013, pp. 1–6. doi: 10.1109/SECON.2013.6567494.
- [133] Fei Zhong, Tiejun Shi, and Tao He, 'Fault diagnosis of motor bearing using self-organizing maps', in *2005 International Conference on Electrical Machines and Systems*, Nanjing, China: IEEE, 2005, pp. 2411-2414 Vol. 3. doi: 10.1109/ICEMS.2005.203004.
- [134] D. N. Coelho, G. A. Barreto, and C. M. S. Medeiros, 'Detection of short circuit faults in 3-phase converter-fed induction motors using kernel SOMs', in *2017 12th International Workshop on Self-Organizing Maps and Learning Vector Quantization, Clustering and Data Visualization (WSOM)*, Nancy, France: IEEE, Jun. 2017, pp. 1–7. doi: 10.1109/WSOM.2017.8020016.
- [135] J. M. Bossio, C. H. De Angelo, G. R. Bossio, and G. O. Garcia, 'Fault diagnosis on induction motors using Self-Organizing Maps', in *2010 9th IEEE/IAS International Conference on Industry Applications - INDUSCON 2010*, Sao Paulo, Brazil: IEEE, Nov. 2010, pp. 1–6. doi: 10.1109/INDUSCON.2010.5739943.
- [136] N. Khalfaoui, M. S. Salhi, and H. Amiri, 'The SOM tool in mechanical fault detection over an electric asynchronous drive', in *2016 4th International Conference on Control Engineering & Information Technology (CEIT)*, Hammamet, Tunisia: IEEE, Dec. 2016, pp. 1–6. doi: 10.1109/CEIT.2016.7929086.
- [137] O. Sid, M. Mena, S. Hamdani, O. Touhami, and R. Ibtouen, 'Self-organizing map approach for classification of electricals rotor faults in induction motors', in *2011 2nd International Conference on Electric Power and Energy Conversion Systems (EPECS)*, Sharjah, United Arab Emirates: IEEE, Nov. 2011, pp. 1–6. doi: 10.1109/EPECS.2011.6126845.
- [138] S. Haroun, A. N. Seghir, and S. Touati, 'Self-Organizing Map and feature selection for of IM broken rotor bars faults detection and diagnosis', in *2018 International Conference on Electrical Sciences and Technologies in Maghreb (CISTEM)*, Algiers: IEEE, Oct. 2018, pp. 1–6. doi: 10.1109/CISTEM.2018.8613361.
- [139] D. C. Marcu and C. Grava, 'The Importance of Data Quality in Training a Deep Convolutional Neural Network', in *2023 17th International Conference on Engineering of Modern Electric Systems (EMES)*, Oradea, Romania: IEEE, Jun. 2023, pp. 1–4. doi: 10.1109/EMES58375.2023.10171785.
- [140] D. Fonseka and C. Chrysoulas, 'Data Augmentation to Improve the Performance of a Convolutional Neural Network on Image Classification', in *2020 International Conference on Decision Aid Sciences and Application (DASA)*, Sakheer, Bahrain: IEEE, Nov. 2020, pp. 515–518. doi: 10.1109/DASA51403.2020.9317249.
- [141] S. Wang, W. Liu, J. Wu, L. Cao, Q. Meng, and P. J. Kennedy, 'Training deep neural networks on imbalanced data sets', in *2016 International Joint Conference*

- on *Neural Networks (IJCNN)*, Vancouver, BC, Canada: IEEE, Jul. 2016, pp. 4368–4374. doi: 10.1109/IJCNN.2016.7727770.
- [142] Y. LeCun and Y. Bengio, ‘Convolutional networks for images, speech, and time series’, in *The handbook of brain theory and neural networks*, Cambridge, MA, USA: MIT Press, 1998, pp. 255–258.
- [143] Y. LeCun, Y. Bengio, and G. Hinton, ‘Deep learning’, *Nature*, vol. 521, no. 7553, Art. no. 7553, May 2015, doi: 10.1038/nature14539.
- [144] R. Xin, J. Zhang, and Y. Shao, ‘Complex network classification with convolutional neural network’, *Tsinghua Sci. Technol.*, vol. 25, no. 4, pp. 447–457, Aug. 2020, doi: 10.26599/TST.2019.9010055.
- [145] P. Samudre, P. Shende, and V. Jaiswal, ‘Optimizing Performance of Convolutional Neural Network Using Computing Technique’, in *2019 IEEE 5th International Conference for Convergence in Technology (I2CT)*, Bombay, India: IEEE, Mar. 2019, pp. 1–4. doi: 10.1109/I2CT45611.2019.9033876.
- [146] G. Lou and H. Shi, ‘Face image recognition based on convolutional neural network’, *China Commun.*, vol. 17, no. 2, pp. 117–124, Feb. 2020, doi: 10.23919/JCC.2020.02.010.
- [147] D. Arora, M. Garg, and M. Gupta, ‘Diving deep in Deep Convolutional Neural Network’, in *2020 2nd International Conference on Advances in Computing, Communication Control and Networking (ICACCCN)*, Greater Noida, India: IEEE, Dec. 2020, pp. 749–751. doi: 10.1109/ICACCCN51052.2020.9362907.
- [148] D.-J. Choi, J.-H. Han, S.-U. Park, and S.-K. Hong, ‘Comparative Study of CNN and RNN for Motor fault Diagnosis Using Deep Learning’, in *2020 IEEE 7th International Conference on Industrial Engineering and Applications (ICIEA)*, Bangkok, Thailand: IEEE, Apr. 2020, pp. 693–696. doi: 10.1109/ICIEA49774.2020.9102072.
- [149] T. Haj Mohamad, A. Abbasi, E. Kim, and C. Nataraj, ‘Application of Deep CNN-LSTM Network to Gear Fault Diagnostics’, in *2021 IEEE International Conference on Prognostics and Health Management (ICPHM)*, Detroit (Romulus), MI, USA: IEEE, Jun. 2021, pp. 1–6. doi: 10.1109/ICPHM51084.2021.9486591.
- [150] A. T. Bayrak, A. A. Aktas, O. Susuz, and O. Tunali, ‘Churn Prediction with Sequential Data Using Long Short Term Memory’, in *2020 4th International Symposium on Multidisciplinary Studies and Innovative Technologies (ISMSIT)*, Istanbul, Turkey: IEEE, Oct. 2020, pp. 1–4. doi: 10.1109/ISMSIT50672.2020.9254679.
- [151] A. Bhukya and C. Koley, ‘Bi-Long Short-Term Memory Networks for Radio Frequency Based Arrival Time Detection of Partial Discharge Signals’, *IEEE Trans. Power Deliv.*, vol. 37, no. 3, pp. 2024–2031, Jun. 2022, doi: 10.1109/TPWRD.2021.3102937.
- [152] P. Siagian and E. Fernando, ‘Long Short Term Memory Networks for Stroke Activity Recognition base on Smartphone’, in *2021 IEEE 5th International Conference on Information Technology, Information Systems and Electrical Engineering (ICITISEE)*, Purwokerto, Indonesia: IEEE, Nov. 2021, pp. 18–23. doi: 10.1109/ICITISEE53823.2021.9655817.
- [153] R. Akter, J.-M. Lee, and D.-S. Kim, ‘Analysis and Prediction of Hourly Energy Consumption Based on Long Short-Term Memory Neural Network’, in *2021 International Conference on Information Networking (ICOIN)*, Jeju Island, Korea

- (South): IEEE, Jan. 2021, pp. 732–734. doi: 10.1109/ICOIN50884.2021.9333968.
- [154] Y. Yasuda, X. Wang, and J. Yamagishi, ‘Effect of Choice of Probability Distribution, Randomness, and Search Methods for Alignment Modeling in Sequence-to-Sequence Text-to-Speech Synthesis Using Hard Alignment’, in *ICASSP 2020 - 2020 IEEE International Conference on Acoustics, Speech and Signal Processing (ICASSP)*, Barcelona, Spain: IEEE, May 2020, pp. 6724–6728. doi: 10.1109/ICASSP40776.2020.9053546.
- [155] M. Luo, S. Yang, S. Shan, and X. Chen, ‘Pseudo-Convolutional Policy Gradient for Sequence-to-Sequence Lip-Reading’, in *2020 15th IEEE International Conference on Automatic Face and Gesture Recognition (FG 2020)*, Buenos Aires, Argentina: IEEE, Nov. 2020, pp. 273–280. doi: 10.1109/FG47880.2020.00010.
- [156] M. Mimura, S. Ueno, H. Inaguma, S. Sakai, and T. Kawahara, ‘Leveraging Sequence-to-Sequence Speech Synthesis for Enhancing Acoustic-to-Word Speech Recognition’, in *2018 IEEE Spoken Language Technology Workshop (SLT)*, Athens, Greece: IEEE, Dec. 2018, pp. 477–484. doi: 10.1109/SLT.2018.8639589.
- [157] H. Jain and G. Harit, ‘An Unsupervised Sequence-to-Sequence Autoencoder Based Human Action Scoring Model’, in *2019 IEEE Global Conference on Signal and Information Processing (GlobalSIP)*, Ottawa, ON, Canada: IEEE, Nov. 2019, pp. 1–5. doi: 10.1109/GlobalSIP45357.2019.8969424.
- [158] S. Mootha, S. Sridhar, R. Seetharaman, and S. Chitrakala, ‘Stock Price Prediction using Bi-Directional LSTM based Sequence to Sequence Modeling and Multitask Learning’, in *2020 11th IEEE Annual Ubiquitous Computing, Electronics & Mobile Communication Conference (UEMCON)*, New York, NY, USA: IEEE, Oct. 2020, pp. 0078–0086. doi: 10.1109/UEMCON51285.2020.9298066.
- [159] R. C. M. C. Shekar, C. Belitz, and J. H. L. Hansen, ‘Development of CNN-Based Cochlear Implant and Normal Hearing Sound Recognition Models Using Natural and Auralized Environmental Audio’, in *2021 IEEE Spoken Language Technology Workshop (SLT)*, Shenzhen, China: IEEE, Jan. 2021, pp. 728–733. doi: 10.1109/SLT48900.2021.9383550.
- [160] M. Bubashait and N. Hewahi, ‘Urban Sound Classification Using DNN, CNN & LSTM a Comparative Approach’, in *2021 International Conference on Innovation and Intelligence for Informatics, Computing, and Technologies (3ICT)*, Zallaq, Bahrain: IEEE, Sep. 2021, pp. 46–50. doi: 10.1109/3ICT53449.2021.9581339.
- [161] S. Yoon *et al.*, ‘Efficient Protocol to Use FMCW Radar and CNN to Distinguish Micro-Doppler Signatures of Multiple Drones and Birds’, *IEEE Access*, vol. 10, pp. 26033–26044, 2022, doi: 10.1109/ACCESS.2022.3155776.
- [162] D. Kollias and S. Zafeiriou, ‘Exploiting Multi-CNN Features in CNN-RNN Based Dimensional Emotion Recognition on the OMG in-the-Wild Dataset’, *IEEE Trans. Affect. Comput.*, vol. 12, no. 3, pp. 595–606, Jul. 2021, doi: 10.1109/TAFFC.2020.3014171.
- [163] G. Shu, W. Liu, X. Zheng, and J. Li, ‘IF-CNN: Image-Aware Inference Framework for CNN With the Collaboration of Mobile Devices and Cloud’, *IEEE Access*, vol. 6, pp. 68621–68633, 2018, doi: 10.1109/ACCESS.2018.2880196.

- [164] L. Lu, Y. Yi, F. Huang, K. Wang, and Q. Wang, ‘Integrating Local CNN and Global CNN for Script Identification in Natural Scene Images’, *IEEE Access*, vol. 7, pp. 52669–52679, 2019, doi: 10.1109/ACCESS.2019.2911964.
- [165] V. Georgeanu, M.-L. Mamuleanu, and D. Selisteanu, ‘Convolutional Neural Networks for Automated Detection and Classification of Bone Tumors in Magnetic Resonance Imaging’, in *2021 IEEE International Conference on Artificial Intelligence, Robotics, and Communication (ICAIRC)*, Fuzhou, Fujian P.R, China: IEEE, Jun. 2021, pp. 5–7. doi: 10.1109/ICAIRC52191.2021.9545036.
- [166] N. S. Shadin, S. Sanjana, and N. J. Lisa, ‘COVID-19 Diagnosis from Chest X-ray Images Using Convolutional Neural Network(CNN) and InceptionV3’, in *2021 International Conference on Information Technology (ICIT)*, Amman, Jordan: IEEE, Jul. 2021, pp. 799–804. doi: 10.1109/ICIT52682.2021.9491752.
- [167] S. J. Sujit, R. E. Gabr, I. Coronado, M. Robinson, S. Datta, and P. A. Narayana, ‘Automated Image Quality Evaluation of Structural Brain Magnetic Resonance Images using Deep Convolutional Neural Networks’, p. 4.
- [168] A. Duan, L. Guo, H. Gao, X. Wu, and X. Dong, ‘Deep Focus Parallel Convolutional Neural Network for Imbalanced Classification of Machinery Fault Diagnostics’, *IEEE Trans. Instrum. Meas.*, vol. 69, no. 11, pp. 8680–8689, Nov. 2020, doi: 10.1109/TIM.2020.2998233.
- [169] A. Samore, M. Rusci, D. Lazzaro, P. Melpignano, L. Benini, and S. Morigi, ‘BrightNet: A Deep CNN for OLED-Based Point of Care Immunofluorescent Diagnostic Systems’, *IEEE Trans. Instrum. Meas.*, vol. 69, no. 9, pp. 6766–6775, Sep. 2020, doi: 10.1109/TIM.2020.2973913.
- [170] M. Skowron and C. T. Kowalski, ‘Permanent Magnet Synchronous Motor Fault Detection System Based on Transfer Learning Method’, in *IECON 2022 – 48th Annual Conference of the IEEE Industrial Electronics Society*, Brussels, Belgium: IEEE, Oct. 2022, pp. 1–6. doi: 10.1109/IECON49645.2022.9968867.
- [171] Y. Lei, F. Jia, J. Lin, S. Xing, and S. X. Ding, ‘An Intelligent Fault Diagnosis Method Using Unsupervised Feature Learning Towards Mechanical Big Data’, *IEEE Trans. Ind. Electron.*, vol. 63, no. 5, pp. 3137–3147, May 2016, doi: 10.1109/TIE.2016.2519325.
- [172] W. Sun, R. Zhao, R. Yan, S. Shao, and X. Chen, ‘Convolutional Discriminative Feature Learning for Induction Motor Fault Diagnosis’, *IEEE Trans. Ind. Inform.*, vol. 13, no. 3, pp. 1350–1359, Jun. 2017, doi: 10.1109/TII.2017.2672988.
- [173] T. Khan, P. Alekhya, and J. Seshadrinath, ‘Incipient Inter-turn Fault Diagnosis in Induction motors using CNN and LSTM based Methods’, in *2018 IEEE Industry Applications Society Annual Meeting (IAS)*, Portland, OR: IEEE, Sep. 2018, pp. 1–6. doi: 10.1109/IAS.2018.8544707.
- [174] K.-J. Shih, M.-F. Hsieh, B.-J. Chen, and S.-F. Huang, ‘Machine Learning for Inter-Turn Short-Circuit Fault Diagnosis in Permanent Magnet Synchronous Motors’, *IEEE Trans. Magn.*, vol. 58, no. 8, pp. 1–7, Aug. 2022, doi: 10.1109/TMAG.2022.3169173.
- [175] J.-H. Han, D.-J. Choi, S.-U. Park, and S.-K. Hong, ‘Diagnosis of motor aging through CNN model using signal correlation’, in *2020 20th International Conference on Control, Automation and Systems (ICCAS)*, Busan, Korea (South): IEEE, Oct. 2020, pp. 571–575. doi: 10.23919/ICCAS50221.2020.9268420.
- [176] S. Lu, G. Qian, Q. He, F. Liu, Y. Liu, and Q. Wang, ‘In Situ Motor Fault Diagnosis Using Enhanced Convolutional Neural Network in an Embedded

- System', *IEEE Sens. J.*, vol. 20, no. 15, pp. 8287–8296, Aug. 2020, doi: 10.1109/JSEN.2019.2911299.
- [177] J.-H. Han, D.-J. Choi, S.-U. Park, and S.-K. Hong, 'A Study on Motor Poor Maintenance Detection Based on DT-CNN', in *2019 19th International Conference on Control, Automation and Systems (ICCAS)*, Jeju, Korea (South): IEEE, Oct. 2019, pp. 1234–1237. doi: 10.23919/ICCAS47443.2019.8971682.
- [178] D.-J. Choi, J.-H. Han, S.-U. Park, and S.-K. Hong, 'Diagnosis of Electric Motor Using Acoustic noise Based on CNN', in *2019 22nd International Conference on Electrical Machines and Systems (ICEMS)*, Harbin, China: IEEE, Aug. 2019, pp. 1–4. doi: 10.1109/ICEMS.2019.8922130.
- [179] J.-H. Han, D.-J. Choi, S.-K. Hong, and H.-S. Kim, 'Motor Fault Diagnosis Using CNN Based Deep Learning Algorithm Considering Motor Rotating Speed', in *2019 IEEE 6th International Conference on Industrial Engineering and Applications (ICIEA)*, Tokyo, Japan: IEEE, Apr. 2019, pp. 440–445. doi: 10.1109/IEA.2019.8714900.
- [180] I.-H. Kao, W.-J. Wang, Y.-H. Lai, and J.-W. Perng, 'Analysis of Permanent Magnet Synchronous Motor Fault Diagnosis Based on Learning', *IEEE Trans. Instrum. Meas.*, vol. 68, no. 2, pp. 310–324, Feb. 2019, doi: 10.1109/TIM.2018.2847800.
- [181] R. Mukhopadhyay, P. S. Panigrahy, G. Misra, and P. Chattopadhyay, 'Quasi 1D CNN-based Fault Diagnosis of Induction Motor Drives', in *2018 5th International Conference on Electric Power and Energy Conversion Systems (EPECS)*, Kitakyushu, Japan: IEEE, Apr. 2018, pp. 1–5. doi: 10.1109/EPECS.2018.8443552.
- [182] S. Shao, R. Yan, Y. Lu, P. Wang, and R. X. Gao, 'DCNN-Based Multi-Signal Induction Motor Fault Diagnosis', *IEEE Trans. Instrum. Meas.*, vol. 69, no. 6, pp. 2658–2669, Jun. 2020, doi: 10.1109/TIM.2019.2925247.
- [183] W. Pietrowski and K. Górny, 'Enhancing the Efficiency of Failure Recognition in Induction Machines through the Application of Deep Neural Networks', *Energies*, vol. 17, no. 2, Art. no. 2, Jan. 2024, doi: 10.3390/en17020476.

ZAŁĄCZNIKI

Wykaz rysunków:

Rys. 2.1. Przyczyny powstawania uszkodzeń silników indukcyjnych.....	21
Rys. 2.2. Procentowy podział uszkodzeń poszczególnych elementów silników indukcyjnych a) EPRI b) IAS	21
Rys. 2.3. Uszkodzenia silników indukcyjnych.....	22
Rys. 2.4. Skutki uszkodzeń silników indukcyjnych	22
Rys. 2.5. Podział metod diagnostycznych silników elektrycznych	23
Rys. 3.1. Diagram przekształceń modeli matematycznych opisujących silnik indukcyjny [79].....	39
Rys. 3.2. Graficzna reprezentacja zwarć w trzech fazach silnika indukcyjnego	46
Rys. 4.1. Wybrane metody uczenia maszynowego w diagnostyce trójfazowych silników elektrycznych	58
Rys. 4.2. Model sztucznego neuronu McCullocha-Pittsa.....	61
Rys. 4.3. Przykładowa struktura sieci MLP.....	62
Rys. 4.4 Model neuronu z wykorzystaniem algorytmu wstecznej propagacji błędu	66
Rys. 4.5 Topologia łańcucha otwartego.....	71
Rys. 4.6 Topologia łańcucha zamkniętego	72
Rys. 4.7 Topologia siatki prostokątnej	72
Rys. 4.8 Topologia siatki heksagonalnej	73
Rys. 4.9. Podział uczenia maszynowego w odniesieniu do głębokich sieci neuronowych	75
Rys. 4.10. Przykładowa struktura konwolucyjnej sieci neuronowej	80
Rys. 4.11. Graficzna reprezentacja operacji konwolucji w <i>ConvNet</i>	81
Rys. 4.12. Przykład zastosowania wypełnienia	83
Rys. 4.13. Operacja konwolucji dla dwóch różnych wartości kroku a) krok równy 1 b) krok równy 2.....	84
Rys. 4.14. Reprezentacji idei operacji <i>max</i> w warstwie łączącej	86
Rys. 4.15. Graficzna interpretacja średniej (a) arytmetycznej b) harmonicznej.....	90
Rys. 4.16. Krzywe ROC w klasyfikacji wieloklasowej.....	93
Rys. 5.1. Uzwojenie stojana silnika trójfazowego.....	96

Rys. 5.2. Prezentacja uzwojenia fazowego stojana przyjęta w ANSYS Electronics Desktop 2021 R1	96
Rys. 5.3. Obwód uzwojenia stojana silnika trójfazowego.....	97
Rys. 5.4. Obwód uzwojenia stojana silnia trójfazowego z uwzględnieniem dodatkowych częstotliwości napięcia zasilającego	99
Rys. 5.5. Schemat uzwojenia stojana silnika 3SIE100L4B.....	100
Rys. 5.6. Geometria silnika w ujęciu dwuwymiarowym.....	101
Rys. 5.7. Geometria silnika w ujęciu trójwymiarowym	102
Rys. 5.8. Obwód uzwojenia stojana uwzględniający zwarcia międzyzwojowe uzwojenia stojana	103
Rys. 5.9. Modelowanie zwarcia międzyzwojowego uzwojenia stojana.....	107
Rys. 5.10. Modelowanie zwarcia międzyzwojowego uzwojenia stojana.....	108
Rys. 5.11. Geometria 3D cewki – zwarcia międzyzwojowe uzwojenia stojana	109
Rys. 5.12. Geometria modelu w ujęciu 3D – zwarcia międzyzwojowe uzwojenia stojana	110
Rys. 5.13. Geometria 3D – zwarcie międzyzwojowe w obszarze cewki fazy A.....	111
Rys. 5.14. Stanowisko pomiarowe.....	112
Rys. 5.15 Badany trójfazowy silnik elektryczny	112
Rys. 5.16. Przebieg prądów fazowych dla $T_L = 0$	113
Rys. 5.17 Przebieg prądów fazowych dla $T_L = T_N$	113
Rys. 5.18. Schemat układu pomiarowego.....	114
Rys. 5.19. Algorytm programu do akwizycji danych.....	117
Rys. 5.20. Interface użytkownika oprogramowania własnego	119
Rys. 5.21. Wizualizacja struktury sieci neuronowej.....	124
Rys. 5.22. Dokładność i strata w funkcji epok – dane wejściowe: sygnał dyskretny przebiegów prądów fazowych prądu fazowego silnika klatkowego	127
Rys. 5.23. Dokładność i strata w funkcji epok a) dane wejściowe – wyniki transformaty Fouriera, b) dane wejściowe – wyniki transformaty falkowej.....	131
Rys. 5.24. Przebiegi prądu fazowego - konfiguracja zwarc faza A- 9 zwartych zwojów, faza B - 1 zwarty zwój, faza C - 10 zwartych zwojów	137
Rys. 5.25 Dokładność i strata w funkcji epok – dane wejściowe: bitmapy ilustrujące przebiegi prądów fazowych silnika indukcyjnego.....	138

Rys. 5.26. Dane treningowe w postaci bitmap prezentujących wyniki przekształcenia Fouriera.....	141
Rys. 5.27. Dane treningowe w postaci bitmap prezentujących wyniki przekształcenia falkowego.....	142
Rys. 5.28. Dokładność i strata w funkcji epok a) bitmapy ilustrujące wyniki transformaty Fouriera, b) bitmapy ilustrujące wyniki transformaty falkowej.....	143
Rys. 5.29. Dokładność w funkcji epok dla metody <i>random search</i>	151
Rys. 5.30. Strata w funkcji epok dla metody <i>random search</i>	153
Rys. 5.31. Dokładność w funkcji epok dla metody <i>grid search</i>	154
Rys. 5.32. Strata w funkcji epok dla metody <i>greed search</i>	156
Rys. 5.33 Histogramy dla metryk a) precyzja, b) czułość c) F1-score d) dokładność - dane wejściowe: zbiór walidacyjny.....	162
Rys. 5.34 Histogramy dla metryk a) precyzja, b) czułość c) F1-score d) dokładność - dane wejściowe: zbiór testowy.....	164

Wykaz tabel:

Tabela 3.1 Równania pola elektrycznego i magnetycznego opisane z wykorzystaniem potencjału skalarnego	52
Tabela 3.2 Równania pola elektrycznego i magnetycznego opisane z wykorzystaniem potencjału wektorowego	52
Tabela 3.3 Metody wykorzystywane w analizie pól elektromagnetycznych	53
Tabela 4.1. Macierz pomyłek dla klasyfikatora binarnego.....	89
Tabela 5.1. Parametry znamionowe silnika	95
Tabela 5.2. Parametry siatki dyskretyzacyjnej modelu 2D	101
Tabela 5.3. Parametry siatki dyskretyzacyjnej dla modelu 3D.....	102
Tabela 5.4. Zmienne wykorzystane do parametryzacji obwodu stojana silnika elektrycznego	104
Tabela 5.5. Wartości rezystancji uzwojenia stojana	114
Tabela 5.6 Parametry znamionowe obciążenia.....	115
Tabela 5.7 Warstwy konwolucyjnej sieci neuronowej	119
Tabela 5.8 Struktura głębokiej sieci neuronowej - dane treningowe: sygnały w postaci dyskretnej w dziedzinie czasu i częstotliwości.....	122
Tabela 5.9. Dodatkowe parametry uczenia.....	125
Tabela 5.10 Konfiguracje przykładów uczących: dane uczące – sygnał dyskretny przebiegów prądów fazowych	126
Tabela 5.11 Średnie wartości metryk – sygnał dyskretny przebiegów prądów fazowych	129
Tabela 5.12 Metryki dla pięciu klas o najlepszej skuteczności klasyfikacji – sygnał dyskretny przebiegów prądów fazowych	129
Tabela 5.13 Metryki dla pięciu klas o najgorszej skuteczności klasyfikacji – sygnał dyskretny przebiegów prądów fazowych	130
Tabela 5.14 Wartości kwantyli dla metryk – sygnał dyskretny przebiegów prądów fazowych.....	130
Tabela 5.15 Średnie wartości metryk - dane wejściowe: wyniki transformaty Fouriera	133
Tabela 5.16 Metryki dla pięciu klas o najlepszej skuteczności klasyfikacji - dane wejściowe: wyniki transformaty Fouriera	133

Tabela 5.17 Metryki dla pięciu klas o najgorszej skuteczności klasyfikacji – dane wejściowe: wyniki transformaty Fouriera	134
Tabela 5.18 Wartości kwantyli dla metryk – dane wejściowe: wyniki transformaty Fouriera.....	134
Tabela 5.19 Średnie wartości metryk – dane wejściowe: wyniki przekształcenia falkowego.....	134
Tabela 5.20 Metryki dla pięciu klas o najlepszej skuteczności klasyfikacji – dane wejściowe: wyniki przekształcenia falkowego.....	135
Tabela 5.21 Metryki dla pięciu klas o najgorszej skuteczności klasyfikacji – dane wejściowe: wyniki przekształcenia falkowego.....	135
Tabela 5.22 Wartości kwantyli dla metryk – dane wejściowe: wyniki przekształcenia falkowego.....	135
Tabela 5.23 Konfiguracje przykładów uczących: dane uczące – wizualizacja wyników w postaci bitmap	137
Tabela 5.24 Średnie wartości metryk – dane wejściowe: bitmapy ilustrujące przebiegi prądów fazowych.....	139
Tabela 5.25 Metryki dla pięciu klas o najlepszej skuteczności klasyfikacji – dane wejściowe: bitmapy ilustrujące przebiegi prądów fazowych	140
Tabela 5.26 Metryki dla pięciu klas o najgorszej skuteczności klasyfikacji – dane wejściowe: bitmapy ilustrujące przebiegi prądów fazowych	140
Tabela 5.27 Wartości kwantyli dla metryk – dane wejściowe: bitmapy ilustrujące przebiegi prądów fazowych.....	141
Tabela 5.28 Średnie wartości metryk – dane wejściowe: bitmapy ilustrujące wyniki transformaty Fouriera	145
Tabela 5.29 Metryki dla pięciu klas o najlepszej skuteczności klasyfikacji – dane wejściowe: bitmapy ilustrujące wyniki transformaty Fouriera.....	145
Tabela 5.30 Metryki dla pięciu klas o najgorszej skuteczności klasyfikacji – dane wejściowe: bitmapy ilustrujące wyniki transformaty Fouriera.....	146
Tabela 5.31 Wartości kwantyli dla metryk – dane wejściowe: dane wejściowe: bitmapy ilustrujące wyniki transformaty Fouriera.....	146
Tabela 5.32 Średnie wartości metryk - dane wejściowe: bitmapy ilustrujące wyniki przekształcenia falkowego	147

Tabela 5.33 Metryki dla pięciu klas o najlepszej skuteczności klasyfikacji – dane wejściowe: bitmapy ilustrujące wyniki przekształcenia falkowego	147
Tabela 5.34 Metryki dla pięciu klas o najgorszej skuteczności klasyfikacji – dane wejściowe: bitmapy ilustrujące wyniki przekształcenia falkowego	147
Tabela 5.35 Wartości kwantyli dla metryk – dane wejściowe: bitmapy ilustrujące wyniki przekształcenia falkowego	148
Tabela 5.36. Hiperparametry modelu podlegające strojeniu	150
Tabela 5.37 Konfiguracje z najwyższą wartością metryki dokładność na zbiorze walidacyjnym.....	156
Tabela 5.38 Średnie wartości metryk	157
Tabela 5.39 Metryki dla pięciu klas o najlepszej skuteczności klasyfikacji	158
Tabela 5.40 Metryki dla pięciu klas o najmniejszej dokładności klasyfikacji	158
Tabela 5.41 Wartości kwantyli dla metryk.....	159