

Diagnostyka zwarcí międzyzwojowych uzwojenia stojana PMSM przy zastosowaniu analizy STFT składowych symetrycznych prądów stojana oraz uczenia maszynowego

Streszczenie. W artykule przedstawiono możliwość zastosowania krótkoczasowej transformaty Fouriera składowych symetrycznych prądów fazowych stojana i wybranych algorytmów uczenia maszynowego: K-najbliższych sąsiadów oraz perceptronu wielowarstwowego, do diagnostyki zwarcí międzyzwojowych uzwojenia stojana silnika synchronicznego o magnesach trwałych. Zaproponowana metoda umożliwia uzyskanie wysokiej skuteczności klasyfikacji oraz lokalizacji uszkodzenia we wczesnym stadium, co potwierdziły badania eksperymentalne przeprowadzone w różnych warunkach pracy układu napędowego.

Abstract. This paper presents the possibility of using the Short-Time Fourier Transform of stator phase currents symmetrical components and selected machine learning algorithms: K-Nearest Neighbors and MultiLayer Perceptron, for the diagnosis of interturn short-circuits in the stator winding of a permanent magnet synchronous motor. The proposed method provides high effectiveness of classification and localization of the fault at an early stage, which is confirmed by experimental tests that were carried out in various operating conditions of the drive system. (Interturn short circuit diagnosis of PMSM stator winding using the STFT analysis of stator phase currents symmetrical components and machine learning).

Słowa kluczowe: silnik synchroniczny o magnesach trwałych, zwarcia międzyzwojowe, uczenie maszynowe.

Keywords: permanent magnet synchronous motor, interturn short-circuits, machine learning, symmetrical components.

Wstęp

Układy napędowe wykorzystujące silniki synchroniczne o magnesach trwałych PMSM (ang. Permanent Magnet Synchronous Motors) są w ostatnich latach coraz częściej wykorzystywane w wielu gałęziach przemysłu. Znalazły one zastosowanie m.in. w lotnictwie, motoryzacji, sprzęcie AGD oraz HVAC [1]. PMSM cechują się bardzo dobrymi właściwościami, takimi jak wysoka sprawność, szeroki zakres regulacji prędkości oraz duża gęstość mocy [2]. Niemniej jednak, tak jak inne typy silników elektrycznych, są one narażone na różnego rodzaju uszkodzenia [3].

Według statystyk [4], uszkodzenia uzwojeń stojana stanowią od 21% do 40% wszystkich awarii, w zależności od typu oraz mocy silnika elektrycznego. Spośród wszystkich uszkodzeń PMSM, te związane z uzwojeniem stojana są najbardziej destrukcyjne. Zazwyczaj rozpoczynają się one od zwarcia międzyzwojowego spowodowanego uszkodzeniem izolacji uzwojenia stojana, a następnie w krótkim czasie mogą rozprzestrzenić się na całe uzwojenie, doprowadzając w konsekwencji do zwarcia międzyfazowego lub doziemnego. W przypadku, gdy tego typu uszkodzenie nie zostanie wykryte we wczesnym stadium, może ono doprowadzić do awaryjnego zatrzymania silnika [5]. Biorąc pod uwagę wysoki procentowy udział uszkodzeń uzwojeń stojana w najczęściej występujących uszkodzeniach silników elektrycznych oraz ich wysoce destrukcyjny charakter, skuteczna diagnostyka tego typu uszkodzeń jest jednym z ważniejszych problemów badawczych w ostatnich latach. Na przestrzeni lat opracowano szereg metod wykrywania uszkodzeń PMSM, w tym tych dotyczących uzwojeń stojana [6].

Większość metod diagnostyki uszkodzeń silników elektrycznych bazuje na przetworzonym sygnale. Do najczęściej stosowanych sygnałów zalicza się prąd fazowy stojana [7]. Wstępne przetworzenie sygnału diagnostycznego pozwala wyodrębnić symptomy, które są charakterystyczne dla danego typu uszkodzenia. Metody przetwarzania sygnału mogą zostać podzielone na realizujące analizę w dziedzinie czasu, częstotliwości oraz czasowo-częstotliwościowe. Metody bazujące na analizie w dziedzinie czasu bazują głównie na analizie statystycznej, wykorzystując parametry sygnału takie jak wartość szczytowa, wartość średnia, błąd średniokwadratowy, a także residuum lub składowe główne [8][9].

Najbardziej popularne w diagnostyce uszkodzeń PMSM są jednak metody realizujące analizę w dziedzinie częstotliwości, szczególnie podejście oparte na wykorzystaniu szybkiej transformaty Fouriera FFT (ang. Fast Fourier Transform) [10]. Niemniej jednak, wykorzystując aparaty matematyczne realizujące analizę w dziedzinie częstotliwości utracana jest informacja o czasie wystąpienia danego uszkodzenia. W przypadku diagnostyki uszkodzeń, wiedza na temat chwili wystąpienia awarii jest niezwykle istotna, ponieważ może pozwolić na ustalenie jej przyczyny poprzez analizę stanu przed jej wystąpieniem. Wady tej pozbawione są metody realizujące analizę czasowo-częstotliwościową, takie jak ciągła transformata falkowa [11], transformata Hilberta-Huanga [12] oraz krótkoczasowa transformata Fouriera STFT (ang. Short-Time Fourier Transform) [3]. W literaturze poruszającej tematykę diagnostyki uszkodzeń PMSM widoczny jest brak prac, w których szczegółowo omówiono zastosowanie analizy STFT w połączeniu z częścią systemu diagnostycznego, która pozwala na automatyczne

wnioskowanie o stanie silnika – detekcję, klasyfikację oraz lokalizację uszkodzenia.

Nowoczesny system diagnostyczny powinien zawierać podsystem, który realizuje automatyczne wnioskowanie o stanie silnika podczas pracy układu. W ostatnich latach funkcja ta w większości przypadków realizowana jest przy użyciu detektorów i klasyfikatorów uszkodzeń opartych na sztucznej inteligencji. Do grupy tych metod należą klasyczne algorytmy uczenia maszynowego ML (ang. Machine Learning), takie jak Maszyna Wektorów Nośnych SVM (ang. Support Vector Machine) [13] oraz K-Najbliższych Sąsiadów KNN (ang. K-Nearest Neighbors) [14]. Osobną podkategorią są algorytmy ML, których działaniem inspirowane jest działaniem ludzkiego mózgu – klasyczne sztuczne sieci neuronowe oraz sieci o głębokiej strukturze. Najczęściej wykorzystywany w diagnostyce uszkodzeń silników elektrycznych rodzaj sieci neuronowych o klasycznej strukturze to jednokierunkowy perceptron wielowarstwowy MLP (ang. MultiLayer Perceptron) [15]. Wśród sieci o głębokiej strukturze dominują natomiast konwulcyjne sieci neuronowe CNN (ang. Convolutional Neural Network) [16].

Należy podkreślić, że skuteczność klasyfikatorów uszkodzeń silników elektrycznych silnie uzależniona jest od wybranych symptomów uszkodzeniowych. Z tego powodu, niezwykle istotne staje się wybranie tych, które są najbardziej wrażliwe na awarię. Wciąż poszukuje się takich symptomów, które pozwolą na wykrycie uszkodzenia uzwojenia stojana we wczesnym stadium.

W niniejszym artykule jako metodę ekstrakcji symptomów zwarć międzyzwojowych wybrano analizę STFT składowych symetrycznych prądów stojana. Modele uczenia maszynowego, których skuteczność klasyfikacji uszkodzeń uzwojenia stojana PMSM porównano w ramach badań do KNN oraz MLP. Ze względu na fakt, że metoda automatycznego wnioskowania o stanie uzwojenia PMSM przy wykorzystaniu analizy STFT w połączeniu ze wspomnianymi algorytmami ML nie została do tej pory zaproponowana w literaturze, niniejsza praca stanowi nowy wkład w dziedzinę diagnostyki uszkodzeń PMSM. Co więcej, zaproponowano kaskadowe połączenie modeli ML umożliwiającego nie tylko detekcję i klasyfikację uszkodzenia, ale również jego lokalizację.

Artykuł został podzielony na 9 nienumerowanych rozdziałów. Kolejny rozdział przedstawia podstawy teoretyczne dotyczące składowych symetrycznych prądów fazowych stojana. W następnych rozdziałach omówiono analizę STFT oraz stanowisko do badań eksperymentalnych. W kolejnym rozdziale zamieszczono wyniki ekstrakcji symptomów zwarć międzyzwojowych stojana PMSM przy wykorzystaniu analizy STFT. Następnie opisano zastosowane modele klasyfikatorów uszkodzeń, proces ich uczenia oraz wyniki działania. W przedostatnim rozdziale zaproponowano metodę lokalizacji uszkodzonej fazy uzwojenia stojana. Na końcu artykułu zamieszczono podsumowanie.

Składowe symetryczne prądów fazowych stojana

Zwarcia międzyzwojowe w uzwojeniu stojana mogą spowodować zmiany w składowych symetrycznych prądów fazowych stojana. Jest tak, ponieważ tego typu uszkodzenie powoduje asymetrię uzwojenia. Chwilowe wartości składowych symetrycznych obliczono przy wykorzystaniu operatora przesunięcia fazowego o 90° w dziedzinie czasu zgodnie z poniższym równaniem [17]:

$$(1) \quad \begin{bmatrix} i_1 \\ i_2 \end{bmatrix} = \frac{1}{3} \begin{bmatrix} i_{sA} - \frac{1}{2}(i_{sB} + i_{sC}) + \frac{\sqrt{3}}{2} S_{90}(i_{sB} - i_{sC}) \\ i_{sA} - \frac{1}{2}(i_{sB} + i_{sC}) - \frac{\sqrt{3}}{2} S_{90}(i_{sB} - i_{sC}) \end{bmatrix},$$

gdzie: i_{sA} , i_{sB} , i_{sC} – odpowiednio chwilowe wartości prądów fazowych stojana w układzie współrzędnych $a-b-c$, i_1 , i_2 – odpowiednio chwilowe wartości składowej zgodnej oraz przeciwnej prądu stojana, S_{90} – operator przesunięcia fazowego o 90° w dziedzinie czasu.

Na rysunku 1 przedstawiono przebieg składowej zgodnej prądów stojana dla różnych poziomów momentu obciążenia T_L , znamionowej częstotliwości napięcia zasilającego $f_s = f_{sN} = 100$ Hz oraz chwilowym zwieraniu kolejno od 1 do 5 zwojów w fazie A uzwojenia stojana. Na podstawie analizy tego przebiegu można stwierdzić niewielki wzrost amplitudy tej składowej w wyniku zwarcia. Na wartość amplitudy widocznie większy wpływ ma poziom momentu obciążenia, co uniemożliwia wnioskowanie o stanie uzwojenia opierając się wyłącznie na analizie składowej zgodnej. Z kolei na rysunku 2 przedstawiono przebieg składowej przeciwnej prądów stojana dla takich samych warunków pracy oraz stanu uzwojenia silnika. W przypadku analizy tego przebiegu widoczny jest istotny wpływ zwarcia międzyzwojowego na wartość amplitudy składowej przeciwnej oraz jednocześnie znikomy wpływ momentu obciążenia. Wzrost amplitudy we wczesnym stadium uszkodzenia – dla 1 oraz 2 zwartych zwojów N_{sh} ($N_{sh}=1$, $N_{sh}=2$) jest niewielki, dlatego do ekstrakcji symptomów tego uszkodzenia zostanie zastosowane wstępne przetworzenie sygnału przy wykorzystaniu STFT.

Krótkoczasowa transformata Fouriera

STFT jest rozszerzeniem analizy częstotliwościowej realizowanej przez FFT do analizy czasowo-częstotliwościowej. Wynik STFT zawiera informację nie tylko o rozkładzie częstotliwości danego sygnału, ale również o chwili wystąpienia danej składowej. Dodatkowo, transformata ta jest odpowiednia do analizy sygnałów niestacjonarnych. W diagnostyce uszkodzeń silników elektrycznych niezwykle istotne jest posiadanie informacji o czasie wystąpienia uszkodzenia. Na podstawie tej informacji można określić źródło awarii, analizując inne parametry pracy układu napędowego z okresu przed awarią. Jest to szczególnie istotne w ostatnich latach, gdzie przechowywanie bardzo dużej liczby danych historycznych nie stanowi istotnego problemu.

Stosując STFT do wstępnego przetworzenia sygnału, na etapie projektowania systemu diagnostycznego, należy dokonać kompromisu między rozdzielczością w dziedzinie czasu, a częstotliwości, dobierając odpowiednią szerokość okna. Wąskie okno zapewnia dobrą rozdzielczość w dziedzinie czasu, kosztem gorszej rozdzielczości w dziedzinie częstotliwości.

STFT oblicza transformatę Fouriera funkcji $f(t)$ na symetrycznej i rzeczywistej funkcji okna $w(t)$, która jest następnie przesuwana w czasie t wzdłuż sygnału, a także modulowana z częstotliwością ω . Ciągłą postacią STFT można wyrazić następującym równaniem [18]:

$$(2) \quad S(t, \omega) = \int_{-\infty}^{\infty} f(t)w(\tau - t)e^{-j\omega\tau} d\tau$$

Wynik transformaty STFT przedstawiany jest zazwyczaj w formie spektrogramu, którego amplitudy będą analizowane podczas badań eksperymentalnych. Spektrogram jest trójwymiarowym wykresem funkcji gęstości widmowej przekształcenia Fouriera i opisany jest następującym równaniem:


$$(3) \quad \text{spectrogram}(t, \omega) = |S(t, \omega)|^2$$

Kluczowe parametry STFT, które należy zdefiniować celem przeprowadzenia poprawnej analizy sygnału, to między innymi częstotliwość próbkowania f_p , szerokość


(rozmiar) okna H oraz typ funkcji okna. W ramach niniejszych badań przyjęto $f_p = 8192$ Hz, $H = 2048$ oraz funkcję okna Hamminga. W przypadku diagnostyki uszkodzeń uzwojeń stojana PMSM czas detekcji powinien być tak krótki, jak to możliwe. Wybrana szerokość okna pozwala na uzyskanie rozdzielczości w dziedzinie czasu równej 0,25 s, przy jednoczesnym zachowaniu wystarczającej do prowadzenia skutecznej diagnostyki rozdzielczości w dziedzinie częstotliwości. Wpływ szerokości okna na wynik analizy STFT został przedstawiony przez autorów w [3]. Wybór okna Hamminga wynika z jego bardzo dobrych właściwości, takich jak wąski listek główny oraz duża dynamika. Dodatkowo, okno Hamminga charakteryzuje się prostotą implementacji, a jego zastosowanie wprowadza jedynie niewielkie zniekształcenie podczas przetwarzania sygnału [19].

Stanowisko do badań eksperymentalnych


Obiektem badań eksperymentalnych był PMSM o mocy znamionowej 2,5 kW. Silnik ten pracował w zamkniętej strukturze sterowania wektorowego FOC (ang. Field Oriented Control) i zasilany był z przemiennika częstotliwości firmy Lenze. Silnik ten był sprzęgnięty z drugim PMSM o mocy 4,7 kW, zapewniającym moment obciążenia. Parametry badanego silnika zgrupowano w tabeli 1. Stanowisko badawcze przedstawiono na rysunku 3. Konstrukcja stojana badanego PMSM została specjalnie przygotowana w taki sposób, aby umożliwić fizyczne przeprowadzenie kontrolowanych zwarc danej liczby zwojów w każdej z trzech faz uzwojenia stojana silnika. Podczas weryfikacji eksperymentalnej zwrano maksymalnie 5 zwojów, co stanowiło 2% wszystkich zwojów w fazie. Ograniczenie liczby zwojów do 5 wynika z realizacji badań bez dodatkowego rezystora ograniczającego prąd zwarcia w zwartym obwodzie.



Rys. 1. Przebieg składowej zgodnej prądów stojana dla różnych poziomów momentu obciążenia T_L , znamionowej częstotliwości napięcia zasilającego $f_s = f_{sN} = 100$ Hz oraz chwilowym zwieraniu kolejno od 1 do 5 zwojów w fazie A uzwojenia stojana PMSM

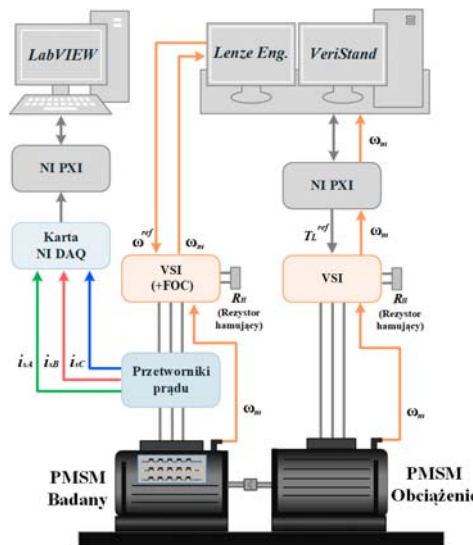


Rys. 2. Przebieg składowej przeciwnej prądów stojana dla różnych poziomów momentu obciążenia T_L , znamionowej częstotliwości napięcia zasilającego $f_s = f_{sN} = 100$ Hz oraz chwilowym zwieraniu kolejno od 1 do 5 zwojów w fazie A uzwojenia stojana PMSM



Rys. 3. Stanowisko do badań eksperymentalnych

Uproszczony schemat blokowy stanowiska eksperymentalnego przedstawiono na rysunku 4. Sygnały prądów fazowych stojana mierzone były przetwornikami prądu typu LEM LA 25-NP. Akwizycja danych odbywała się przy wykorzystaniu karty DAQ NI PX-4492 firmy National Instruments. Sterowanie prędkością silnika badanego oraz obciążeniem realizowane było przy wykorzystaniu środowiska Lenze Engineer oraz VeriStand.



Rys. 4. Schemat blokowy stanowiska badawczego

Tabela 1. Parametry znamionowe badanego silnika

Nazwa	Symbol	Wartość	
Moc	P_N	2500	[W]
Napięcie stojana	U_{sN}	325	[V]
Prąd stojana	I_{sN}	6,6	[A]
Częstotliwość	f_{sN}	100	[Hz]
Prędkość obrotowa	n_N	1500	[obr/min]
Moment	T_L	16	[Nm]
Liczba par biegunów	p_p	2	[-]
Liczba zwojów fazy stojana	N_{sh}	250 (2x125)	[-]

Wyniki ekstrakcji symptomów zwarc międzyzwojowych stojana PMSM przy wykorzystaniu analizy STFT

Wykorzystując specjalnie przygotowane stanowisko badawcze, które zostało opisane w poprzednim rozdziale, przeprowadzono badania możliwości zastosowania analizy STFT składowych symetrycznych prądów stojana PMSM do ekstrakcji symptomów zwarc międzyzwojowych. Analiza STFT została zrealizowana przy wykorzystaniu skryptu opracowanego w środowisku programistycznym MATLAB, wywoływanego podczas pracy online układu napędowego w aplikacji diagnostycznej przygotowanej w środowisku LabVIEW. Badania przeprowadzono dla różnych warunków pracy silnika oraz stanów uszkodzenia uzwojenia stojana – liczby zwartych zwojów. Prace badawcze dodatkowo zrealizowano dla uszkodzenia ciągłego (określona liczba zwartych zwojów przez 10 s) oraz zwarcia chwilowego (około 1-2 sekundowe). Spektrogramy STFT składowej zgodnej prądów fazowych stojana dla nieuszkodzonego silnika, przy zwarcu przez 10 s 3 zwojów w fazie A zwojenia stojana przedstawiono odpowiednio na rysunku 5a oraz 5b ($f_s = f_{sN} = 100$ Hz, $T_L = \text{var}$, $H = 2048$). Na spektrogramach widoczny jest znaczny wzrost wartości amplitudy częstotliwości odpowiadającej 1 harmonicznej ($f_s = 100$ Hz) wraz ze zwiększającym się momentem obciążenia oraz wzrost 3 harmonicznej ($3f_s = 300$ Hz) na skutek uszkodzenia. Na rysunku 6a oraz 6b przedstawiono spektrogramy STFT składowej przeciwnej prądów fazowych stojana dla odpowiednio uzwojenia nieuszkodzonego oraz przy 3 zwartych zwojach. Porównując spektrogramy można zaobserwować znaczny wzrost wartości amplitudy częstotliwości f_s w wyniku zwarcia.


Spektrogramy STFT składowej zgodnej prądów fazowych stojana przy chwilowym zwieraniu kolejno od 1 do 5 zwojów w fazie A uzwojenia przedstawiono na rysunku 7a, natomiast zmiany wyłącznie amplitudy składowej $3f_s$ na rysunku 7b. Na podstawie analizy tych wyników można stwierdzić wzrost amplitudy tej składowej na skutek zwarc międzyzwojowych. Niemniej jednak, różnica między poziomem dla silnika nieuszkodzonego, a przy uszkodzonym uzwojeniu znacząco maleje przy zwiększającym się poziomie obciążenia, co jest istotną wadą.

Spektrogram STFT oraz zmiany amplitudy f_s składowej przeciwnej prądów stojana, dla takich samych warunków testowych przedstawiono na rysunku 8. W tym przypadku widoczny jest znaczny wzrost poziomu tej amplitudy w wyniku zwarc międzyzwojowych już na wczesnym etapie uszkodzenia ($N_{sh}=1$) oraz znikomy wpływ momentu obciążenia na poziom amplitudy tej składowej. Można więc stwierdzić, że amplituda składowej f_s w spektrogramie STFT składowej przeciwnej jest znacznie lepszym wskaźnikiem uszkodzeniowym w porównaniu do amplitudy składowej $3f_s$ w spektrogramie składowej zgodnej.


W celu dokładnego oszacowania wpływu zwarcia na amplitudę danej składowej częstotliwości i porównania ich zmian na skutek uszkodzenia, analizowany jest wzrost amplitudy przy danej liczbie zwartych zwojów w stosunku do wartości dla silnika nieuszkodzonego, zgodnie z równaniem:

$$(4) \quad A_{DIFF}(f_c) = A_{Uszkodzony}(f_c) - A_{Nieuszkodzony}(f_c),$$

gdzie: f_c – charakterystyczna składowa uszkodzeniowa, $A_{Uszkodzony}$, $A_{Nieuszkodzony}$ – amplitudy składowej f_c odpowiednio dla uszkodzonego oraz nieuszkodzonego uzwojenia stojana.



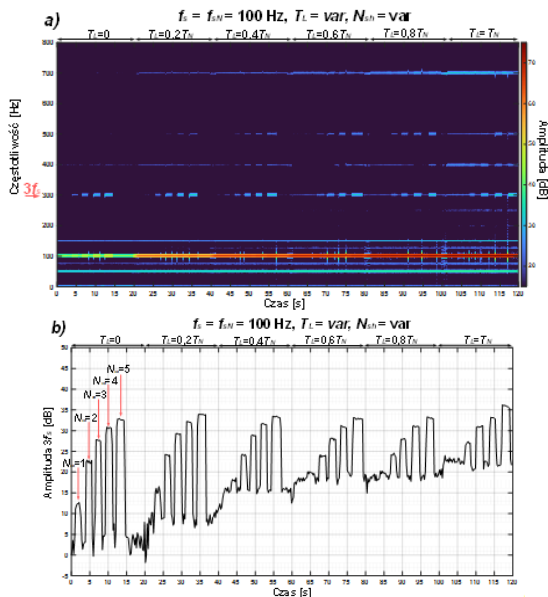
Rys.5. Spektrogramy STFT składowej zgodnej prądów fazowych stojana dla silnika nieuszkodzonego oraz przy 3 zwartych zwojach w uzwojeniu stojana ($f_s = f_{sN} = 100$ Hz, $T_L = \text{var}$, $H = 2048$)




Rys.6. Spektrogramy STFT składowej przeciwnej prądów fazowych stojana dla silnika nieuszkodzonego oraz przy 3 zwartych zwojach w uzwojeniu stojana ($f_s = f_{sN} = 100$ Hz, $T_L = \text{var}$, $H = 2048$)

Wpływ N_{sh} oraz T_L na wzrost amplitudy składowej $3f_s$ w spektrogramie STFT składowej zgodnej prądu fazowego stojana przedstawiono na rysunku 9a, natomiast wpływ zmiany wartości f_s na rysunku 9b. Na podstawie analizy wykresów słupkowych przedstawionych na tych rysunkach można stwierdzić, że wzrost amplitudy na skutek uszkodzenia znacząco maleje wraz ze zmniejszającą się częstotliwością napięcia zasilania, szczególnie w przypadku początkowego stadium uszkodzenia. Dodatkowo, widoczny jest istotny wpływ momentu obciążenia na wzrost tej składowej. Niemniej jednak, w przypadku składowej f_s w spektrogramie składowej przeciwnej, ograniczenie to nie


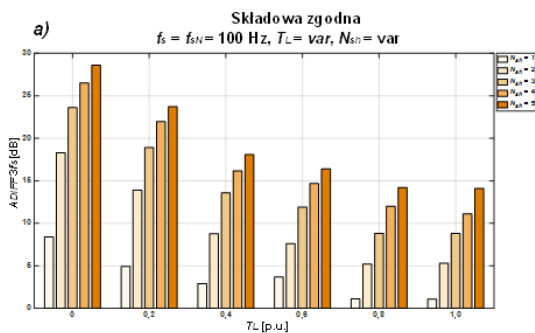
występuje. Z tego powodu wskaźnik ten zostanie wykorzystany w kolejnej części badań, która dotyczy automatyzacji procesu detekcji.





Rys.7. a) Spektrogram STFT składowej zgodnej prądów fazowych stojana przy chwilowym zwieraniu kolejno od 1 do 5 zwojów w fazie A uzwojenia stojana, b) zmiany amplitudy składowej $3f_s$ ($f_s = f_{sN} = 100$ Hz, $T_L = \text{var}$, $H = 2048$)



Rys.8. a) Spektrogram STFT składowej przeciwnej prądów fazowych stojana przy chwilowym zwieraniu kolejno od 1 do 5 zwojów w fazie A uzwojenia stojana, b) zmiany amplitudy składowej f_s ($f_s = f_{sN} = 100$ Hz, $T_L = \text{var}$, $H = 2048$)



Rys.9. Wpływ N_{sh} w uzwojeniu stojana PMSM oraz wartości (a) T_L , (b) f_s na wzrost amplitudy składowej częstotliwości $3f_s$ w spektrogramie składowej zgodnej prądów fazowych stojana.



Rys.10. Wpływ N_{sh} w uzwojeniu stojana PMSM oraz wartości (a) T_L , (b) f_s na wzrost amplitudy składowej częstotliwości f_s w spektrogramie składowej przeciwnej prądów fazowych stojana.

Wybrane algorytmy uczenia maszynowego

Algorytmy uczenia maszynowego, będące jednym z obszarów szerokiej dziedziny jaką jest AI, wykorzystywane są w podejściach opartych na wiedzy. W ostatnich latach są one sukcesywnie ulepszane oraz rozwijane. Znalazły swoje zastosowanie również w diagnostyce uszkodzeń silników indukcyjnych oraz PMSM. W ramach badań przedstawionych w niniejszym artykule zweryfikowano oraz porównano możliwość automatyzacji procesu klasyfikacji stanu uzwojenia stojana PMSM przy wykorzystaniu dwóch algorytmów uczenia maszynowego – prostego w implementacji algorytmu KNN oraz sieci neuronowej MLP.

KNN jest jednym z fundamentalnych algorytmów uczenia maszynowego, które wykorzystywane są w klasyfikacji danych. Charakteryzuje się prostotą implementacji oraz wysoką skutecznością w rozwiązywaniu wielu problemów klasyfikacyjnych [20]. W procesie przypisywania klasy dla nowych danych, które reprezentowane są przez wektor cech będący punktem w przestrzeni z-wymiarowej, algorytm KNN oblicza odległość między nowym punktem a punktami, które zostały wykorzystane w procesie treningu. Następnie klasyfikator przypisuje punkt do danej klasy na podstawie przynależności K najbliższych punktów, zwanych sąsiadami. K jest liczbą całkowitą i musi zostać zdefiniowana na etapie projektowania modelu. Model KNN został opracowany przy wykorzystaniu *Statistics and Machine Learning Toolbox* dostępnym w środowisku

programistycznym MATLAB. Opis poszczególnych kroków algorytmu został opisany przez autorów w [21].

Sieci MLP należą do jednych z najpopularniejszych i najczęściej używanych sieci neuronowych. Tego typu sieć zbudowana jest z warstwy wejściowej, jednej lub więcej warstw ukrytych oraz warstwy wyjściowej. Skuteczność sieci neuronowej zależy głównie od jej struktury oraz metody uczenia. Równanie (5) opisuje sygnał wyjściowy dwuwarstwowej perceptronowej sieci neuronowej [22]. Model sieci neuronowej został opracowany przy wykorzystaniu *Neural Network Toolbox* w środowisku MATLAB.

$$(5) \quad y_k = f^{(2)}\left(\sum_{m=1}^M w_{km}^{(2)} f^{(1)}\left(\sum_{n=1}^N w_{mn}^{(1)} x_n + w_{m0}^{(1)}\right) + w_{k0}^{(2)}\right),$$

gdzie: x_n – n – ta wartość wejściowa sieci, y_k – wartość wyjściowa k -tego neuronu, $f^{(1)}$ – funkcja aktywacji pierwszej warstwy ukrytej, $f^{(2)}$ – funkcja aktywacji drugiej warstwy ukrytej, w – waga neuronu w danej warstwie.

Proces treningu oraz wyniki działania wybranych algorytmów uczenia maszynowego

W procesie doboru najlepszego pod względem skuteczności dla danego zastosowania modelu uczenia maszynowego konieczne jest odpowiednie dobranie jego kluczowych parametrów. Dobór parametrów należy przeprowadzać badając dopasowanie modelu dla różnych ich wartości. Każdy z modeli charakteryzuje się innymi parametrami, które należy dobrać na etapie projektowania. Zgromadzony podczas badań eksperymentalnych zbiór danych wejściowych wykorzystanych podczas procesu treningu oraz testów offline modeli klasyfikatorów uszkodzeń składał się z 1000 wektorów o postaci: $[A_{fs_i}, A_{fs_e}, f_s]$, gdzie A_{fs_i} – amplituda składowej f_s w spektrogramie STFT składowej zgodnej, A_{fs_e} – amplituda składowej f_s w spektrogramie STFT składowej przeciwnej, f_s – wyznaczona częstotliwość napięcia zasilania.

Wektory wejściowe odpowiadają różnym stanom uzwojenia stojana ($N_{sh}=\{0;1;2;3;4;5\}$) oraz warunkom pracy układu napędowego ($T_L=\{0;0,2T_N;0,4T_N;0,6T_N;0,8T_N;T_N\}$, $f_s=\{80 \text{ Hz}, 90 \text{ Hz}, 100 \text{ Hz}\}$). W procesie treningu wykorzystano 70% (700) wektorów ze zbioru danych, natomiast pozostałe 30% (300) zastosowano do celów testowych (offline). Na rysunku 11 przedstawiono dopasowanie modelu dla różnych wartości K oraz Euklidesowej funkcji obliczania odległości. Na podstawie tego porównania można stwierdzić, że najwyższym dopasowaniem modelu (96,7%) charakteryzuje się model KNN o parametrze $K=3$.


Odpowiedź tego modelu na wektory wejściowe znajdujące się w zbiorze testowy, przedstawiono na rysunku 12. W tym przypadku, skuteczność klasyfikatora uszkodzeń uzwojeń stojana bazującego na modelu KNN wyniosła 98,3%. Na podstawie osiągniętych wyników można stwierdzić, że parametry modelu zostały dobrane poprawnie i zostanie on zweryfikowany w kolejnym etapie badań podczas testów online.

W przypadku sztucznych sieci neuronowych o klasycznej strukturze, kluczową kwestią na etapie projektowania modelu klasyfikatora jest odpowiedni dobór struktury sieci. W niniejszej pracy przy doborze struktury zastosowano podejście konstruktywistyczne – rozpoczęto od weryfikacji dopasowania modelu sieci o strukturze 5-7-1, stopniowo dodając neurony w warstwach ukrytych i porównując uzyskane dopasowanie modelu dla każdej ze struktur. Jako kryterium zakończenia procesu uczenia badanych sieci przyjęto maksymalną ilość epok równą 500.

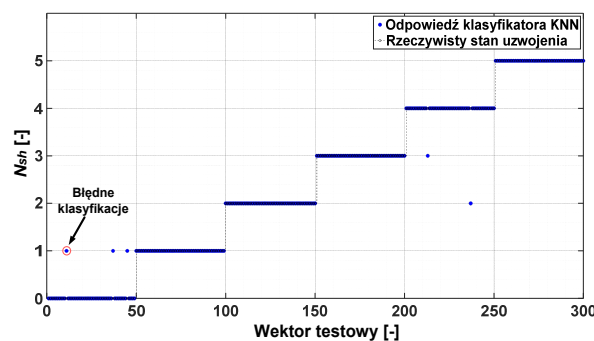
Na rysunku 13 przedstawiono dopasowanie modelu dla wybranych struktur sieci z tych, które zostały przetestowane. W warstwach ukrytych zastosowano funkcje

aktywacji: tangensa hiperbolicznego, natomiast metoda treningu to algorytm gradientowy Levenberga-Marquardta. Na podstawie tego porównania można stwierdzić, że najwyższe dopasowanie modelu, które wyniosło 99%, osiągnięte zostało dla sieci o dwóch różnych strukturach z dwoma warstwami ukrytymi zawierającymi kolejno 9 oraz 15 neuronów, a także 9 oraz 17 neuronów. Do dalszych badań przyjęto pierwszy z tych modeli, ze względu na fakt, że posiada on mniej skomplikowaną strukturę, jednocześnie zachowując wysokie dopasowanie.


Odpowiedź modelu MLP na wektory testowe przy uwzględnieniu zaokrąglenia wyjścia sieci do najbliższej liczby całkowitej przedstawiono na rysunku 14. Skuteczność klasyfikatora uszkodzeń uzwojeń stojana PMSM bazującego na modelu MLP dla tej weryfikacji wyniosła 97,8%. Celem finalnej oceny skuteczności klasyfikatorów, zweryfikowano ich skuteczność podczas pracy online układu napędowego.



Rys. 11. Dopasowanie modelu KNN dla różnych wartości K



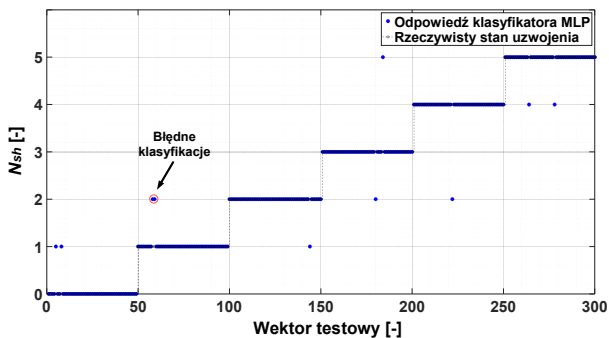
Rys. 12. Odpowiedź klasyfikatora KNN na wektory wejściowe zawarte w zbiorze testowym



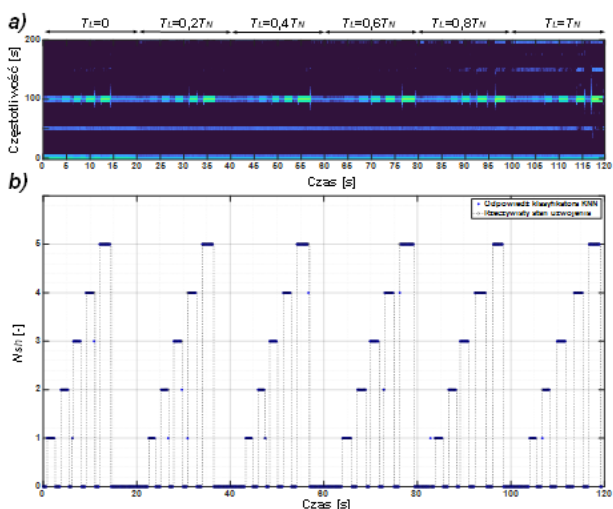
Rys. 13. Dopasowanie modelu MLP dla różnych struktur sieci

Weryfikację działania klasyfikatorów podczas pracy online przeprowadzono w ramach testu, podczas którego zwierano przez około 1-2 s kolejno od 1 do 5 zwojów w fazie A uzwojenia stojana, zwiększając stopniowo moment obciążenia z krokiem $0,2 T_L$, aż do wartości znamionowej. Ocenę skuteczności klasyfikatorów przeprowadzono porównując procentowy stosunek poprawnych klasyfikacji stanu uzwojenia, do całkowitej sumy odpowiedzi sieci. Fragmenty spektrogramu STFT składowej przeciwnej prądów przedstawiające zmiany składowej f_s , a także


odpowiedzi klasyfikatorów KNN i MLP przedstawiono odpowiednio na rysunku 15 oraz 16. Oba klasyfikatory osiągnęły bardzo wysoką skuteczność równą 98,2% w przypadku modelu KNN oraz 97,8% w przypadku modelu MLP.



Rys.14. Odpowiedź klasyfikatora MLP na wektory wejściowe zawarte w zbiorze testowym



Rys.15. a) Fragment spektrogramu STFT składowej przeciwnej prądów ($f_s=f_{sN}=100$ Hz, $T_L=var$, $H=2048$), odpowiedź klasyfikatora KNN



Rys.16. a) Fragment spektrogramu STFT składowej przeciwnej prądów ($f_s=f_{sN}=100$ Hz, $T_L=var$, $H=2048$), odpowiedź klasyfikatora MLP

Lokalizacja uszkodzonej fazy uzwojenia stojana

Rozszerzenie systemu diagnostycznego o możliwość lokalizacji uszkodzonej fazy uzwojenia stojana może znacząco pomóc przy próbie naprawy silnika, szczególnie

w sytuacji, gdy uszkodzenie zostało wykryte we wczesnym stadium. W ramach badań przedstawionych w niniejszym artykule zaproponowano kaskadowe połączenie klasyfikatorów opisanych w poprzedniej sekcji z lokalizatorami uszkodzeń, które również bazują na algorytmach uczenia maszynowego KNN oraz MLP. Jako nadrzędny klasyfikator uszkodzeń wybrano model KNN, ponieważ osiągnął on wyższą skuteczność podczas testów online. Wektor wejściowy lokalizatorów uszkodzenia składał się z 6 elementów: wartości RMS prądów w fazie A, B oraz C (i_{ARMS} , i_{BRMS} , i_{CRMS}) oraz ich wartości międzyszczytowych (i_{A-p} , i_{B-p} , i_{C-p}).

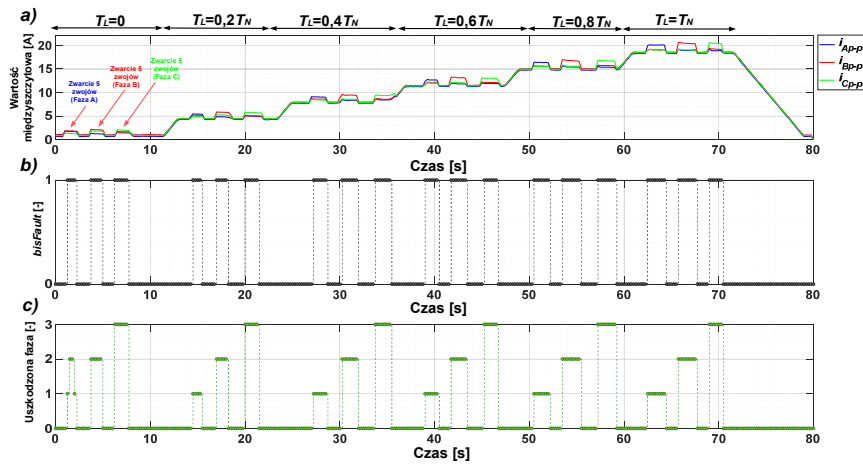
W procesie treningu wykorzystano 300 wektorów wejściowych dla różnych momentów obciążenia silnika, silnika nieuszkodzonego oraz przy 5 zwartych zwojach kolejno w fazie A, B oraz C. Najwyższe dopasowanie modelu KNN (98,3%), osiągnął model KNN o $K=3$. Dopasowanie równe 100% osiągnął model MLP z dwoma warstwami ukrytymi, które zawierały odpowiednio 7 i 13 neuronów, dlatego to właśnie ten model został wykorzystany do weryfikacji eksperymentalnej.

Na rysunku 17 przedstawiono przebieg wartości międzyszczytowych prądów fazowych stojana (rys. 17a), wartość zmiennej $blsFault$ typu boolowskiego, która przyjmuje wartość 0 w chwili, gdy na wyjściu nadrzędnego klasyfikatora KNN jest wartość $N_{sh}=0$ oraz 1, gdy $N_{sh} > 1$ (uszkodzone uzwojenie). Z kolei na rysunku 17c przedstawiono odpowiedź lokalizatora uszkodzenia przy cyklicznym zwieraniu 5 zwojów kolejno w fazie A, B oraz C oraz zmieniającym się momencie obciążenia. Wartości wyjściowe lokalizatora MLP (1, 2, 3) odpowiadają wykryciu uszkodzenia odpowiednio w fazie A, B oraz C. Opracowany model lokalizatora uzyskał wysoką skuteczność lokalizacji uszkodzenia równą 99,4%. Ze względu na bardzo obiecujące wyniki kaskadowego połączenia modelu KNN pracującego jako klasyfikatora uszkodzeń oraz sieci MLP jako lokalizatora uszkodzeń planowane są dalsze badania i testy w tym kierunku.

Podsumowanie

W artykule przedstawiono metodę diagnostyki uszkodzeń uzwojeń stojana PMSM we wczesnym stadium. Zaprezentowano i zweryfikowano eksperymentalnie możliwość zastosowania analizy STFT składowej zgodnej oraz przeciwnej prądów fazowych stojana do ekstrakcji symptomów zwarcia międzyszczytowych, a także algorytmów uczenia maszynowego do automatyzacji procesu klasyfikacji i lokalizacji tego typu awarii. Na podstawie przedstawionych w artykule wyników badań można stwierdzić, że wartość amplitudy składowej f_s w spektrogramie STFT składowej przeciwnej prądów fazowych stojana znacząco rośnie w wyniku uszkodzenia uzwojeń stojana. Dodatkowo w pracy szczegółowo przeanalizowano, które składowe częstotliwości w spektrogramie STFT składowych symetrycznych prądów stojana są najbardziej wrażliwe na uszkodzenie i odporne na zmiany warunków pracy silnika – momentu obciążenia oraz częstotliwości napięcia zasilającego.

Zaproponowane kaskadowe połączenie modeli KNN oraz MLP pozwoliło uzyskać bardzo wysoką skuteczność nie tylko klasyfikacji uszkodzenia we wczesnym stadium jego rozwoju, ale również lokalizacji uszkodzonej fazy, co jest niewątpliwą zaletą opracowanej metody. Dalsze badania będą koncentrować się na analizie skuteczności lokalizacji uszkodzonej fazy we wczesnym stadium uszkodzenia, a także implementacji proponowanej metody diagnostycznej na niskobudżetowym mikrokontrolerze.



Rys.17. a) Przebieg wartości międzyszczytowych prądów fazowych stojana, b) przebieg wartości zmiennej $blsFault$, c) odpowiedź lokalizatora uszkodzenia uzwojeń stojana

Badania zostały sfinansowane przez Narodowe Centrum Nauki (NCN) w ramach grantu nr 2017/27/B/ST7/00816.

Autorzy:

mgr inż. Przemysław Pietrzak, dr hab. inż. Marcin Wolkiewicz, prof. uczelni, Politechnika Wrocławska, Katedra Maszyn, Napędów i Pomiarów Elektrycznych, ul. Smoluchowskiego 19, 50-372 Wrocław, przemyslaw.pietrzak@pwr.edu.pl; marcin.wolkiewicz@pwr.edu.pl

LITERATURA

- [1] Zuo, Y., Zhu, X., Si, X., Lee, C. H. T. Fault-Tolerant Control for Multiple Open-Leg Faults in Open-End Winding Permanent Magnet Synchronous Motor System Based on Winding Reconnection, *IEEE Transactions on Power Electronics*, 36 (2021), nr 5, 6068-6078.
- [2] Knypiński, Ł., Krupiński, J. Application of the permanent magnet synchronous motors for tower cranes, *Przegląd Elektrotechniczny*, 96 (2020), nr 1, 27-30.
- [3] Pietrzak, P., Wolkiewicz, M. Stator Winding Fault Detection of Permanent Magnet Synchronous Motors Based on the Short-Time Fourier Transform, *Power Electronics and Drives*, 7 (2022), nr 42, 112-133.
- [4] Riera-Guasp, M., Antonino-Daviu, J. A., Capolino, G. Advances in Electrical Machine, Power Electronic, and Drive Condition Monitoring and Fault Detection: State of the Art. *IEEE Transactions on Industrial Electronics*, 62 (2015).
- [5] Wolkiewicz, M., Tarchała, G., Orłowska-Kowalska, T., Kowalski, C. T. Online Stator Interturn Short Circuits Monitoring in the DFOC Induction-Motor Drive, *IEEE Transactions on Industrial Electronics*, 63 (2016), nr 4, 2517-2528.
- [6] Orłowska-Kowalska, T. et al. Fault Diagnosis and Fault-Tolerant Control of PMSM Drives—State of the Art and Future Challenges *IEEE Access*, 10 (2022), 59979-60024.
- [7] Pietrzak, P., Wolkiewicz, M. Comparison of Selected Methods for the Stator Winding Condition Monitoring of a PMSM Using the Stator Phase Currents. *Energies*, 14 (2021), nr. 1630.
- [8] Leboeuf, N., Boileau, T., Nahid-Mobarakeh, B., Clerc, G., Meibody-Tabar, F. Real-Time Detection of Interturn Faults in PM Drives Using Back-EMF Estimation and Residual Analysis. *IEEE Transactions on Industrial Electronics*, 47 (2011), , 2402-2412.
- [9] Guefack, F. L. T., Kiselev, A., Kuznetsov, A. Improved Detection of Inter-turn Short Circuit Faults in PMSM Drives using Principal Component Analysis. W: *Proc. Int. Symp. Power Electronics, Electrical Drives, Aut. Motion (SPEEDAM)*, 2018, 154-159.
- [10] Chen, S. Liang, W. Li, H. Liang, C. Wang. Faults and Diagnosis Methods of Permanent Magnet Synchronous Motors: A Review. *Applied Sciences*, 9 (2019), nr 10, 2116.
- [11] Haje Obeid, N., Battiston, A., Boileau, T., Nahid-Mobarakeh, B. Early Intermittent Interturn Fault Detection and Localization for a Permanent Magnet Synchronous Motor of Electrical Vehicles Using Wavelet Transform. *IEEE Transactions on Transportation Electrification*, 3 (2017), nr 3, 694-702.
- [12] Urresty, J., Riba, J., Romeral, L., Rosero, J., Serna, J. Stator short circuits detection in PMSM by means of Hilbert-Huang transform and energy calculation. W: *IEEE International Symposium on Diagnostics for Electric Machines, Power Electronics and Drives*, 2009, 1-7.
- [13] Pietrzak, P., Wolkiewicz, M. Application of Support Vector Machine to stator winding fault detection and classification of permanent magnet synchronous motor. W: *IEEE 19th International Power Electronics and Motion Control Conference (PEMC)*, 2021, 880-887
- [14] Samanta, S., Bera, J.N.; Sarkar, G. KNN based fault diagnosis system for induction motor. W: *Proc. of the 2nd International Conference on Control, Instrumentation, Energy & Communication (CIEC)*, 2016, 304–308.
- [15] Ewert, P., Orłowska-Kowalska, T., Jankowska, K. Effectiveness Analysis of PMSM Motor Rolling Bearing Fault Detectors Based on Vibration Analysis and Shallow Neural Networks. *Energies*, 14 (2021), nr 712.
- [16] Pietrzak, P., Wolkiewicz, M., Orłowska-Kowalska, T. PMSM Stator Winding Fault Detection and Classification Based on Bispectrum Analysis and Convolutional Neural Network. *IEEE Transactions on Industrial Electronics*, 2022, Early Access, doi: 10.1109/TIE.2022.3189076.
- [17] Irvani, M.R., Karimi-Ghartemani, M. Online estimation of steady state and instantaneous symmetrical components. *IET Proc. Gener. Transm. Distrib.* 150 (2003), 616–622.
- [18] Satpathi, K., Yeap, Y. M., Ukil, A., Gedda, N. "Short-Time Fourier Transform Based Transient Analysis of VSC Interfaced Point-to-Point DC System," *IEEE Transactions on Industrial Electronics*, 65 (2018), nr 5, 4080-4091.
- [19] Pawlak, M. Zastosowanie funkcji okien czasowych w diagnostyce wirników silników indukcyjnych. *Prace Naukowe Instytutu Maszyn, Napędów i Pomiarów Elektrycznych Politechniki Wrocławskiej. Studia i Materiały* (2008), nr 28, s. 520-527
- [20] Xueli, W., Zhiyong, J., Dahai, Y. An Improved KNN Algorithm Based on Kernel Methods and Attribute Reduction. W: *Proceedings 2015 Fifth International Conference on Instrumentation and Measurement, Computer, Communication and Control (IMCCC)*, Qinhuaangdao, China, 2015, 567-570.
- [21] Pietrzak, P., Wolkiewicz, M. On-line Detection and Classification of PMSM Stator Winding Faults Based on Stator Current Symmetrical Components Analysis and the KNN Algorithm. *Electronics*, 10 (2021), nr 15, p. 1786.
- [22] Skowron, M., Wolkiewicz, M., Orłowska-Kowalska, T., Kowalski, C.T. 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*, 12 (2019), 2392