

Zastosowanie krótkoczasowej transformaty Fouriera oraz sztucznej inteligencji do wykrywania uszkodzeń uzwojeń stojana silnika synchronicznego o magnesach trwałych

Streszczenie. W artykule przedstawiono możliwość wykorzystania krótkoczasowej transformaty Fouriera sygnału prądu fazowego stojana oraz modułu wektora przestrzennego prądów stojana do ekstrakcji symptomów uszkodzeń uzwojeń stojana silnika synchronicznego o magnesach trwałych. Dodatkowo, zaproponowano możliwość automatyzacji procesu wnioskowania o stanie uzwojenia stojana przy zastosowaniu wybranych algorytmów bazujących na sztucznej inteligencji: maszyny wektorów nośnych oraz perceptronu wielowarstwowego. System diagnostyczny rozszerzono o możliwość lokalizacji uszkodzonej fazy. Badania eksperymentalne potwierdzają wysoką skuteczność opracowanego rozwiązania.

Abstract. This paper presents the possibility of using the short-time Fourier transform of the stator phase current and stator current space vector module in the process of permanent magnet synchronous motor stator winding fault symptoms extraction. Additionally, the automatization of the stator winding condition inference process which the use of selected artificial intelligence based algorithms: Support Vector Machine and MultiLayer Perceptron is proposed. The developed diagnostic system has been extended with the functionality of locating the damaged phase. Experimental studies confirmed the high effectiveness of the developed method. (**Application of the short-time Fourier transform and artificial intelligence to the permanent magnet synchronous motor stator winding fault detection**).

Słowa kluczowe: silnik synchroniczny o magnesach trwałych, zwarcia międzyzwojowe, krótkoczasowa transformata Fouriera.

Keywords: permanent magnet synchronous motor, interturn short-circuits, short-time Fourier transform, artificial intelligence.

Wstęp

Silniki synchroniczne o magnesach trwałych PMSMs (ang. Permanent Magnet Synchronous Motors) stanowią z roku na rok coraz większą część wśród wykorzystywanych w przemyśle układów napędowych. Ich rosnąca popularność wynika z bardzo dobrych parametrów, takich jak wysoka sprawność, wysoka wytrzymałość, duża gęstość mocy oraz dobre właściwości dynamiczne. Niemniej jednak, tak jak inne typy silników elektrycznych, są one narażone na różnego rodzaju uszkodzenia [1],[2].

Uszkodzenia uzwojeń stojana są to głównie zwarcia spowodowane uszkodzeniem izolacji uzwojenia. Stanowią one od 21% do 40% wszystkich awarii, w zależności od typu oraz mocy silnika elektrycznego [3]. Zwarcia można podzielić na: zwarcia międzyzwojowe, zwarcia między cewkami w jednej fazie, zwarcia międzyfazowe oraz zwarcia doziemne [4]. Niemniej jednak, najczęściej uszkodzenie uzwojenia stojana zaczyna się od zwarcia międzyzwojowego ITSC (ang. InterTurn Short-Circuit) i w krótkim czasie od zwarcia pojedynczego zwoju rozprzestrzenia 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 układu oraz całkowitego uszkodzenia silnika [5].

Istnieje wiele różnorodnych metod diagnostyki uszkodzeń oraz monitorowania stanu uzwojeń stojana PMSM. Niemniej jednak, wciąż poszukiwane są nowe metody, które umożliwią wykrycie uszkodzenia na wczesnym etapie jego rozwoju, a także umożliwią automatyzację procesu detekcji, klasyfikacji oraz lokalizacji uszkodzenia [6],[7]. Większość proponowanych metod diagnostyki uszkodzeń uzwojeń silników elektrycznych bazuje na analizie w dziedzinie częstotliwości opartej na szybkiej transformacie Fouriera FFT (ang. Fast Fourier Transform) i poszukiwaniu składowych częstotliwościowych charakterystycznych dla danego uszkodzenia. Do najczęściej stosowanych sygnałów stosowanych w tym obszarze zalicza się sygnał prądu fazowego stojana [8]. Niemniej jednak, w przypadku stosowania tego rozwiązania, brak jest informacji o czasie wystąpienia danej

składowej uszkodzeniowej. W diagnostyce uszkodzeń, informacja dotycząca chwili wystąpienia awarii jest bardzo istotna, ponieważ może pozwolić na ustalenie jej przyczyny poprzez analizę innych parametrów układu z okresu przed jej wystąpieniem.

Uzyskanie informacji o czasie wystąpienia uszkodzenia umożliwiają aparaty matematyczne realizujące analizę czasowo-częstotliwościową, takie jak ciągła transformata falkowa [9], transformata Hilberta-Huanga [10] oraz krótkoczasowa transformata Fouriera STFT (ang. Short-Time Fourier Transform) [11].

W ostatnich latach dąży się do pełnej automatyzacji procesu diagnostyki uszkodzeń silników elektrycznych. Celem ograniczenia roli eksperta-diagnosty i zapewnienia całkowitej automatyzacji, w diagnostyce stosowane są algorytmy sztucznej inteligencji AI (ang. Artificial Intelligence). Podstawą do opracowania detektorów i klasyfikatorów uszkodzeń silników elektrycznych bazujących na sztucznej inteligencji jest skuteczna ekstrakcja symptomów danego uszkodzenia. Algorytmy AI, w tym klasyczne algorytmy uczenia maszynowego, mają za zadanie ocenę stanu silnika na podstawie informacji wejściowej, którą najczęściej stanowi wynik analiz sygnałów diagnostycznych. Jest tak również w przypadku diagnostyki uszkodzeń uzwojeń stojana PMSM. Do grupy metod opartych na AI należą klasyczne algorytmy uczenia maszynowego, takie jak Maszyna Wektorów Nośnych SVM (ang. Support Vector Machine) [12] oraz K-Najbliższych Sąsiadów KNN (ang. K-Nearest Neighbors) [13]. Osobną podkategorią są sztuczne sieci neuronowe. Najczęściej wykorzystywany w diagnostyce uszkodzeń silników elektrycznych rodzaj sieci neuronowych o klasycznej strukturze to jednokierunkowy perceptron wielowarstwowy MLP (ang. MultiLayer Perceptron) [14]. Wśród sieci o strukturze głębokiej dominują natomiast konwolucyjne sieci neuronowe CNNs (ang. Convolutional Neural Networks) [15].

W niniejszym artykule jako metodę ekstrakcji symptomów zwarcia międzyzwojowych zaproponowano analizę STFT sygnału prądu fazowego stojana oraz modułu wektora przestrzennego prądów stojana. Porównano również skuteczność realizacji automatyzacji wnioskowania o stanie uzwojenia stojana PMSM przy zastosowaniu

modelu SVM oraz MLP. Do tej pory podejście to nie zostało przedstawione w literaturze. Dodatkowo, zaproponowano kaskadowe połączenie tych modeli umożliwiające nie tylko detekcję i klasyfikację uszkodzenia, ale również jego lokalizację.

Artykuł został podzielony na 9 nienumerowanych rozdziałów. Kolejny rozdział przedstawia wpływ ITSC w uzwojeniu PMSM na sygnały prądów fazowych stojana. Następnie omówiono podstawy teoretyczne dotyczące analizy STFT oraz stanowisko do badań eksperymentalnych. W kolejnym rozdziale zamieszczono wyniki ekstrakcji symptomów zwarc międzyzwojowych stojana PMSM przy wykorzystaniu analizy STFT. Następnie omówiono zastosowane modele klasyfikatorów uszkodzeń, proces ich uczenia oraz przeanalizowano wyniki działania. Kolejno zaproponowano metodę lokalizacji uszkodzonej fazy uzwojenia stojana. Całość została krótko podsumowana.

Wpływ zwarcia międzyzwojowego w uzwojeniu PMSM na sygnały prądów fazowych stojana

Uszkodzenie uzwojenia stojana PMSM powoduje zmiany amplitud prądów fazowych stojana, ich fluktuacje oraz asymetrię. Przebiegi prądów fazowych stojana dla różnych poziomów momentu obciążenia T_L , znamionowej częstotliwości napięcia zasilającego f_{sN} oraz chwilowym zwieraniu kolejno od 1 do 5 zwojów w fazie A uzwojenia przedstawiono na rysunku 1. Na podstawie analizy tych przebiegów można stwierdzić nieznaczny wzrost amplitudy prądu w uszkodzonej fazie na skutek zwarcia. Niemniej jednak, na wartość amplitudy prądów większy wpływ ma zmiana poziomu T_L , co znacząco utrudnia wnioskowanie o stanie uzwojenia opierając się wyłącznie na wartości amplitudy sygnału.

Kolejnym sygnałem diagnostycznym, który może zostać wykorzystany w celu poprawy skuteczności ekstrakcji symptomów uszkodzeń uzwojeń stojana, jest moduł wektora przestrzennego prądów stojana obliczony zgodnie z równaniem:

$$(1) \quad |i_s| = \sqrt{i_{s\alpha}^2 + i_{s\beta}^2},$$

gdzie: $i_{s\alpha}$, $i_{s\beta}$ – chwilowe wartości prądów fazowych stojana w układzie współrzędnych α - β , obliczone na podstawie równania:

$$(2) \quad i_{s\alpha} = \sqrt{\frac{2}{3}} \cdot (i_{sA} - \frac{1}{2} \cdot (i_{sB} + i_{sC})) \quad i_{s\beta} = \frac{1}{\sqrt{2}} (i_{sB} - i_{sC}),$$

gdzie: i_{sA} , i_{sB} , i_{sC} – chwilowe wartości prądów fazowych stojana w układzie współrzędnych a - b - c .

Przebieg modułu wektora przestrzennego prądów fazowych stojana dla takich samych warunków pracy jak w przypadku sygnału prądu stojana przedstawiono na rysunku 2. Na podstawie analizy tego przebiegu można stwierdzić, że wpływ ITSC na amplitudę $|i_s|$ jest nieznacznie większy w porównaniu do zmiany amplitudy sygnału prądu fazowego

stojana. Niemniej jednak, również w tym przypadku amplituda jest zależna od poziomu T_L . Celem skutecznego wykrywania symptomów ITSC, które są możliwie najmniej zależne od zmian warunków pracy silnika, stosuje się algorytmy wstępnego przetwarzania sygnału. W ramach niniejszego artykułu, zastosowano wstępne przetworzenie sygnału przy wykorzystaniu STFT.

Krótkoczasowa transformata Fouriera

STFT jest aparatem matematycznym realizującym analizę czasowo-częstotliwościową. Wynik STFT zawiera informację nie tylko o rozkładzie częstotliwości danego sygnału, ale również o chwili wystąpienia danej składowej. 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.

STFT oblicza transformatę Fouriera funkcji $f(t)$ na symetrycznej i rzeczywistej funkcji okna $w(t)$, która jest przesuwana w czasie t wzdłuż sygnału oraz modulowana z częstotliwością ω . Ciągłą postać STFT można wyrazić równaniem [16]:

$$(3) \quad S(t, \omega) = \int_{-\infty}^{\infty} f(\tau) w(\tau - t) e^{-j\omega\tau} d\tau.$$


Wynik transformaty STFT można przedstawić w formie spektrogramu. Spektrogram jest trójwymiarowym wykresem funkcji gęstości widmowej przekształcenia Fouriera i opisany jest następującym równaniem:

$$(4) \quad \text{spectrogram}(t, \omega) = |S(t, \omega)|^2.$$


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.

Stanowisko do badań eksperymentalnych

Badania eksperymentalne przeprowadzone zostały na stanowisku badawczym przedstawionym na rysunku 3. Składa się ono z dwóch silników: badanego PMSM o mocy znamionowej równej 2.5 kW, pracującego w zamkniętej strukturze sterowania wektorowego, zasilanego z przemiennika częstotliwości firmy Lenze oraz drugiego PMSM o mocy 4.7 kW, który zapewniał moment obciążenia. Konstrukcja uzwojenia stojana badanego PMSM została przygotowana w taki sposób, aby umożliwić fizyczne przeprowadzenie kontrolowanych zwarc danej liczby zwojów w każdej z trzech faz uzwojenia. Podczas weryfikacji eksperymentalnej zwierano maksymalnie 5 zwojów (2% wszystkich zwojów w fazie).



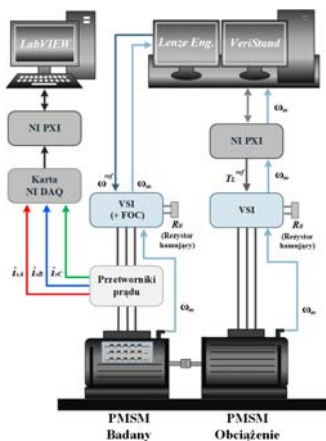
Rys. 1. Przebieg prądów fazowych stojana dla różnych poziomów T_L , znamionowej częstotliwości napięcia zasilającego $f_s=f_{sN}=100$ Hz oraz chwilowym zwieraniu kolejno od 1 do 5 zwojów w fazie A uzwojenia stojana PMSM, N_{sh} – liczba wartych zwojów



Rys.2. Przebieg modułu wektora przestrzennego prądów fazowych stojana dla różnych poziomów 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



Rys.4. Schemat blokowy stanowiska badawczego

Uproszczony schemat blokowy stanowiska eksperymentalnego przedstawiono na rysunku 4. Sygnały trzech 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.

Wyniki ekstrakcji symptomów zwarc międzyzwojowych stojana PMSM przy wykorzystaniu analizy STFT

Badania możliwości zastosowania analizy STFT sygnału prądu fazowego stojana oraz modułu wektora przestrzennego prądów stojana do ekstrakcji symptomów ITSCs przeprowadzono dla różnych warunków pracy silnika oraz stanów uzwojenia stojana – liczby zwartych zwojów N_{sh} (ang. Number of shorted turns). Badania eksperymentalne zostały podzielone na analizę zwarc danej liczby zwojów przez 10 s (zwarcia ciągłe, ustalone) oraz zwarcia 1-2 sekundowe (chwilowe).

Spektrogramy STFT prądu stojana dla nieuszkodzonego silnika, a także przy zwarcu przez okres 10s 3 zwojów w fazie A zwojenia stojana przedstawiono odpowiednio na rysunku 5a oraz 5b ($f_s=f_{sN}=100$ Hz, $T_L=var$, $H = 2048$). Na spektrogramach tych widać 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 6 przedstawiono spektrogramy STFT modułu wektora przestrzennego prądów fazowych stojana. Na spektrogramach tych widać wartości amplitudy podwójnej częstotliwości napięcia zasilającego $2f_s$ spowodowany ITSC.

W kolejnej części badań eksperymentalnych przeanalizowano wpływ chwilowych zwarc na spektrogramy STFT badanych sygnałów diagnostycznych. Na rysunku 7a przedstawiono spektrogram prądu fazowego stojana przy chwilowym zwieraniu kolejno od 1 do 5 zwojów w fazie A uzwojenia stojana, natomiast zmiany wyłącznie amplitudy składowej $3f_s$ na rysunku 7b. Na podstawie analizy tych rysunków można stwierdzić widoczny wzrost amplitudy tej składowej na skutek ITSC. Niemniej jednak, przy wyższym poziomie momentu obciążenia ($T_L=0.8T_N$, $T_L=T_N$), wzrost na wczesnym etapie uszkodzenia ($N_{sh}=1$) jest znikomy. Ze względu na to, że w przypadku tego typu uszkodzeń wykrycie uszkodzenia na jak najwcześniejszym etapie rozwoju jest ważne, jest to istotne ograniczenie.

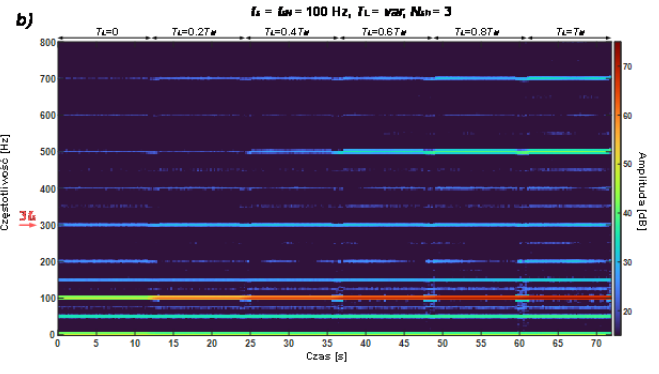
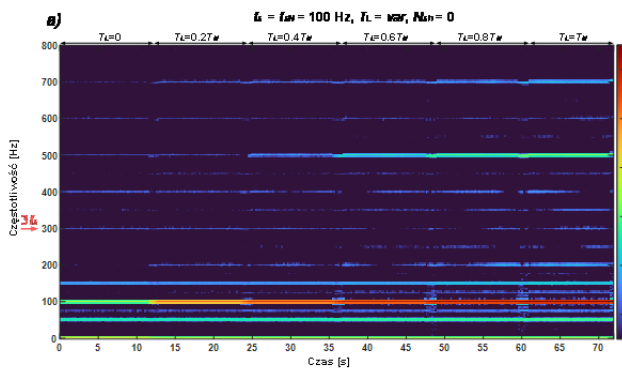
Spektrogram STFT modułu wektora przestrzennego prądów fazowych stojana oraz zmiany amplitudy składowej $2f_s$ dla takich samych warunków testowych przedstawiono na rysunku 8. W tym przypadku widoczny jest znaczny wzrost poziomu tej amplitudy w wyniku zwarc międzyzwojowych również przy zaledwie jednym zwartym zwoju oraz niewielki wpływ momentu obciążenia na poziom tej składowej.

W celu dokładnego oceny i porównania wpływu uszkodzenia uzwojenia stojana na wzrost amplitudy danej składowej, analizowany jest wzrost amplitudy przy danej liczbie zwartych zwojów w stosunku do wartości dla silnika nieuszkodzonego:

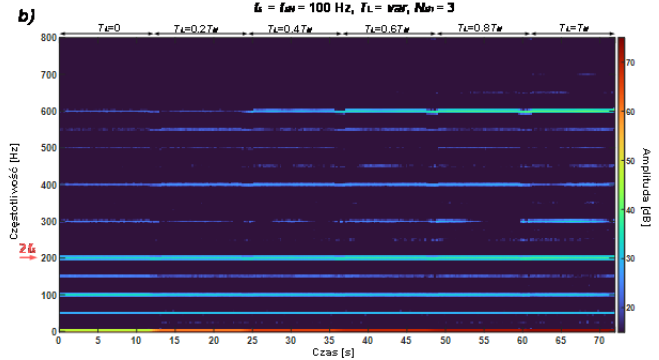

$$(4) \quad A_{DIFF}(f_c) = A_{Uszkodzony}(f_c) - A_{Nieuszkodzony}(f_c),$$

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

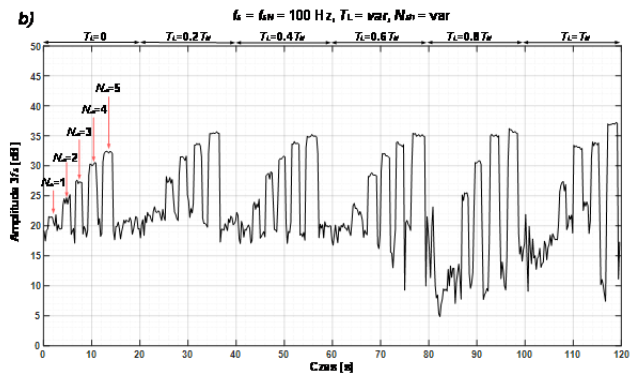
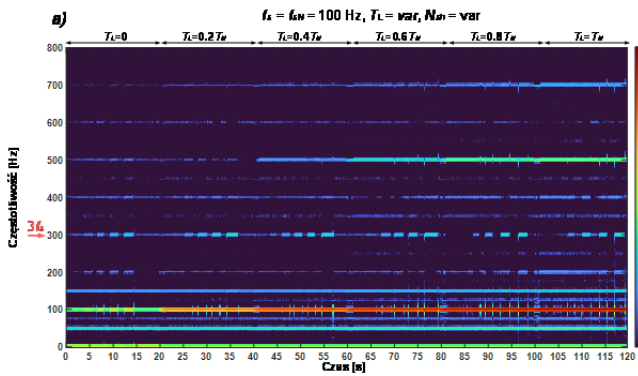
Wpływ N_{sh} oraz T_L na wzrost amplitudy składowej $3f_s$ w spektrogramie STFT prądu fazowego stojana przedstawiono na rysunku 9a, natomiast wpływ zmiany f_s na rysunku 9b. Na podstawie analizy przedstawionych wykresów słupkowych można wnioskować, że wzrost amplitudy na skutek uszkodzenia znacząco maleje wraz ze zmniejszającą się częstotliwością napięcia zasilania, szczególnie w przypadku początkowego stadium uszkodzenia. Niemniej jednak, w przypadku składowej $2f_s$ w spektrogramie modułu wektora przestrzennego, wzrosty na wczesnym stadium uszkodzenia są widocznie większe. Na podstawie analizy porównawczej zdecydowano, że wskaźnik ten zostanie wykorzystany w kolejnej części badań poświęconej automatyzacji procesu klasyfikacji stanu uzwojenia stojana.



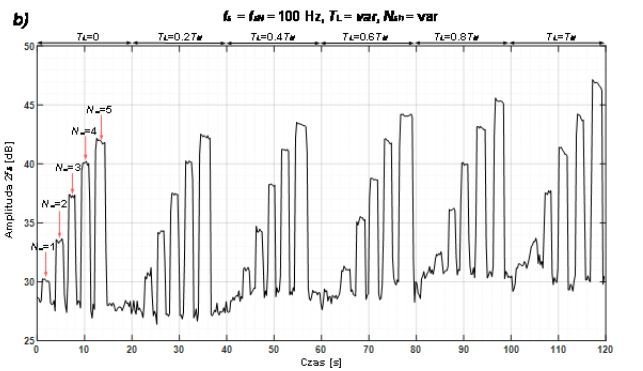

Rys.5. Spektrogramy STFT prądu fazowego stojana dla silnika nieuszkodzonego oraz przy 3 zwartych zwojach w fazie A uzwojenia stojana ($f_s = f_{SN} = 100$ Hz, $T_L = T_N$, $H = 2048$)



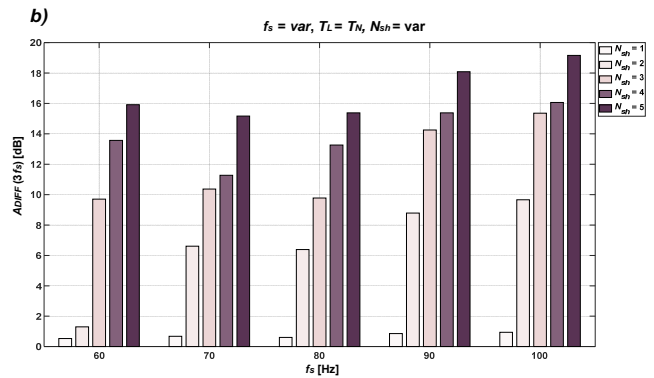
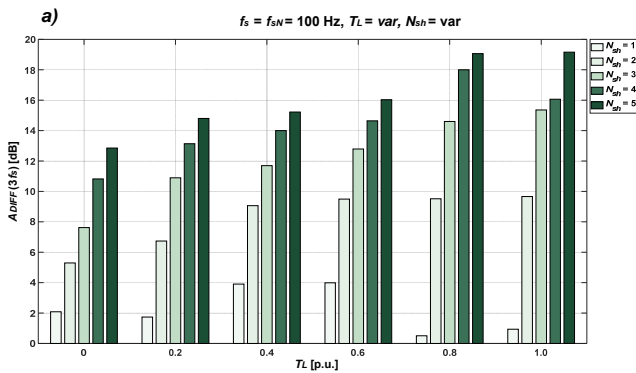
Rys.6. Spektrogramy STFT modułu wektora przestrzennego prądów fazowych stojana dla silnika nieuszkodzonego oraz przy 3 zwartych zwojach w uzwojeniu stojana ($f_s = f_{SN} = 100$ Hz, $T_L = T_N$, $H = 2048$)



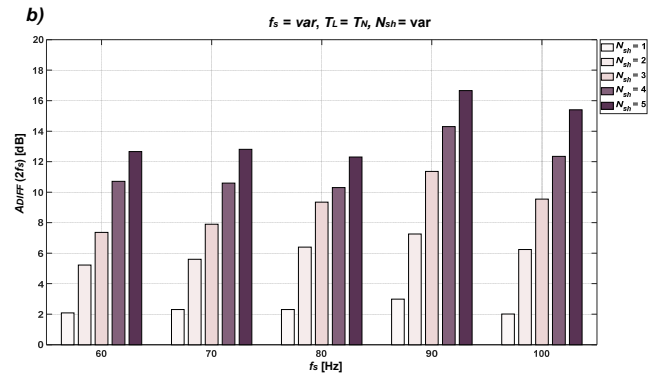
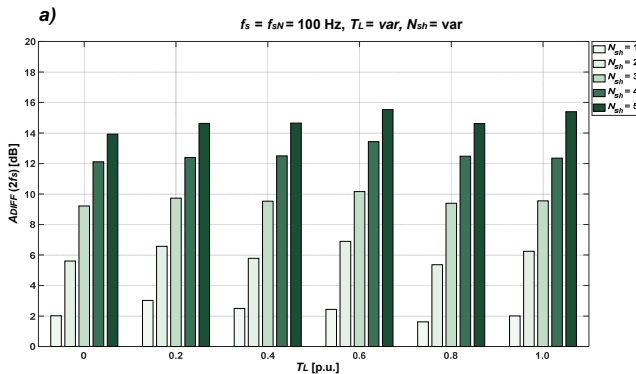
Rys.7. a) Spektrogram STFT prądu fazowego stojana przy chwilowym zwieraniu kolejno od 1 do 5 zwojów w fazie A uzwojenia stojana, b) zmiany amplitudy składowej $3f_s$ ($f_s = f_{SN} = 100$ Hz, $T_L = var$, $H = 2048$)



Rys.8. a) Spektrogram STFT modułu wektora przestrzennego prądów fazowych stojana przy chwilowym zwieraniu kolejno od 1 do 5 zwojów w fazie A uzwojenia stojana, b) zmiany amplitudy składowej $2f_s$ ($f_s = f_{SN} = 100$ Hz, $T_L = var$, $H = 2048$)



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 prądu fazowego stojana, faza A.



Rys.10. Wpływ N_{sh} w uzwojeniu stojana PMSM oraz wartości (a) T_L , (b) f_s na wzrost amplitudy składowej częstotliwości $2f_s$ w spektrogramie modułu wektora przestrzennego prądów fazowych stojana.

Wybrane algorytmy sztucznej inteligencji

Algorytmy bazujące na technikach sztucznej inteligencji są w ostatnich latach coraz częściej stosowane w diagnostyce uszkodzeń silników elektrycznych. W niniejszym artykule zweryfikowano oraz porównano możliwość automatyzacji procesu klasyfikacji stanu uzwojenia stojana PMSM przy zastosowaniu dwóch algorytmów bazujących na sztucznej inteligencji – modelu SVM oraz sieci neuronowej MLP.

SVM jest to algorytm AI zaliczający się do grupy klasycznych modeli uczenia maszynowego, który znalazł zastosowanie w rozwiązywaniu problemów związanych z klasyfikowaniem danych. Charakteryzuje się on dobrą generalizacją oraz możliwością rozwiązywania problemów klasyfikacji również w przypadku małej liczby próbek uczących [17]. Głównym celem algorytmu SVM jest znalezienie takiej hiperpłaszczyzny, która w jak największym stopniu oddziela punkty danych jednej klasy, od punktów innej klasy. Podstawy matematyczne tego algorytmu zostały szczegółowo opisane w [18]. Rodzaj modelu SVM zależy od wybranej funkcji jądra (ang. kernel function). W zależności od rodzaju problemu związanego z klasyfikacją danych, stosowane są różne funkcje jądra, a do najczęściej wykorzystywanych zalicza się liniową, wielomianową oraz Gaussa.

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 [19].

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

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.

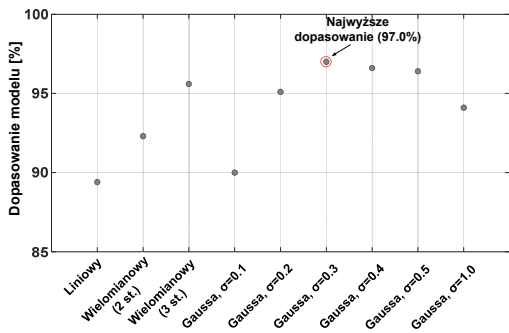
Proces treningu oraz wyniki działania wybranych modeli klasyfikatorów uszkodzeń uzwojeń stojana PMSM

Odpowiedni dobór kluczowych parametrów modeli klasyfikatorów uszkodzeń bazujących na algorytmach AI ma bezpośredni wpływ na skuteczność ich działania. Najczęściej proces ten przeprowadza się analizując dopasowanie modelu dla różnych ich wartości. Zgromadzony podczas badań eksperymentalnych zbiór danych wejściowych wykorzystanych podczas procesu treningu oraz testów offline modeli klasyfikatorów uszkodzeń składał się z 1000 wektorów o postaci: $[A_{f_{DC}}, A_{2f_s}, f_s]$, gdzie $A_{f_{DC}}$ – amplituda składowej f_{DC} w spektrogramie STFT modułu wektora przestrzennego prądów fazowych stojana, A_{2f_s} – amplituda składowej $2f_s$ w spektrogramie STFT modułu wektora przestrzennego prądów fazowych stojana, f_s – wyznaczona częstotliwość napięcia zasilania. Amplituda składowej f_{DC} została wykorzystana w wektorze wejściowym modeli ze względu na fakt, że jej wartość zmienia się wraz ze zmianą obciążenia silnika, dlatego niesie ona informację o jego poziomie.


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 rodzajów modeli SVM. Na podstawie tego porównania można wnioskować, że najwyższe dopasowanie modelu równe 97% zostało

osiągnięte dla funkcji jądra Gaussa o szerokości $\sigma = 0.3$.


Odpowiedź modelu SVM o tych parametrach na wektory wejściowe znajdujące się w zbiorze testowym przedstawiono na rysunku 12. W tym przypadku, skuteczność klasyfikatora uszkodzeń uzwojeń stojana bazującego wyniosła 98%. Model ten zostanie zweryfikowany w kolejnym etapie badań podczas testów online.




Rys. 11. Dopasowanie modelu dla różnych typów algorytmu SVM



Rys. 12. Odpowiedź klasyfikatora SVM na wektory testowe



Rys. 13. Dopasowanie modelu MLP dla różnych struktur sieci



Rys. 14. Odpowiedź klasyfikatora MLP na wektory testowe

W przypadku sztucznych sieci neuronowych MLP kluczowy jest dobór odpowiedniej struktury sieci. Na rysunku 13 przedstawiono dopasowanie modelu dla wybranych struktur sieci poddanych analizie. 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 98.7%, osiągnęła sieć o dwóch warstwach ukrytych zawierających kolejno 9 oraz 15

neuronów. Dalsze rozszerzenie struktury sieci nie poskutkowało osiągnięciem większego dopasowania.

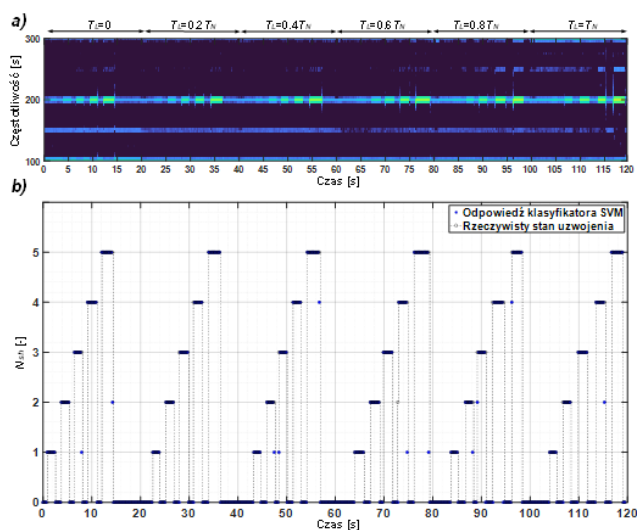
Odpowiedź modelu MLP na wektory testowe przy uwzględnieniu zaokrąglenia wyjścia sieci do najbliższej liczby całkowitej przedstawiono na rysunku 14. Skuteczność tego klasyfikatora wyniosła 97%. Celem finalnej oceny skuteczności klasyfikatorów, zweryfikowano ich skuteczność podczas pracy online układu napędowego.

Weryfikację działania klasyfikatorów podczas pracy online przeprowadzono zwierając 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. Ocena skuteczności klasyfikatorów przeprowadzono porównując procentowy stosunek poprawnych klasyfikacji stanu uzwojenia, do całkowitej sumy odpowiedzi sieci. Fragmenty spektrogramu STFT modułu wektora przestrzennego prądów stojana przedstawiające zmiany składowej $2f_s$, a także odpowiedzi klasyfikatorów SVM i MLP przedstawiono na rysunku 15 oraz 16. Oba klasyfikatory osiągnęły bardzo wysoką skuteczność równą 96.1% w przypadku modelu SVM. oraz 95.9% w przypadku modelu MLP.

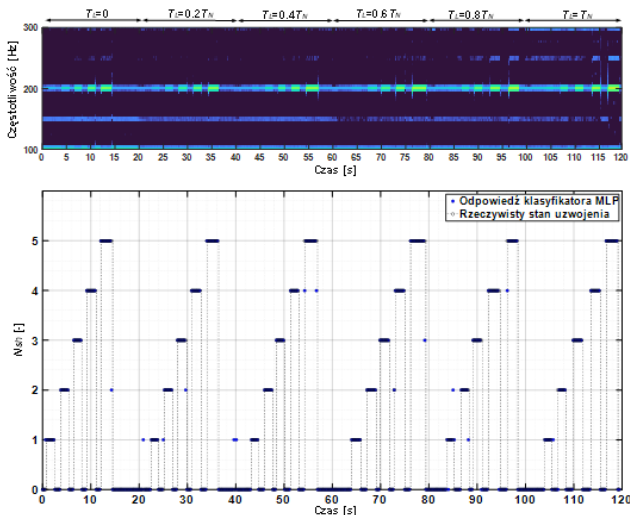
Lokalizacja uszkodzonej fazy uzwojenia stojana

Funkcja lokalizacji uszkodzenia została zrealizowana przy zastosowaniu kaskadowego połączenia klasyfikatora opisanego w poprzedniej sekcji z lokalizatorem uszkodzeń, który również bazuje na algorytmie AI. Jako nadrzędny klasyfikator uszkodzeń zastosowano model SVM, ponieważ charakteryzuje się on lepszym dopasowaniem oraz skutecznością, co potwierdziły przeprowadzone testy. Wektor wejściowy lokalizatora uszkodzonej fazy składa 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-DP} , I_{B-DP} , I_{C-DP}). Ze względu na to, że wraz ze zwiększającą się liczbą elementów wejściowych modelu zwiększa się wymiarowość hiperpłaszczyzny algorytmu SVM, jako lokalizator uszkodzeń zastosowano model MLP.

W procesie treningu wykorzystano 900 wektorów wejściowych dla różnych momentów obciążenia silnika, częstotliwości napięcia zasilającego oraz przy 5 zwartych zwojach kolejno w fazie A, B oraz C. Najwyższe dopasowanie równe 96.7% osiągnął model MLP z dwoma warstwami ukrytymi, które zawierały odpowiednio 9 i 15 neuronów, dlatego to właśnie ten model został wykorzystany



Rys. 15. a) Fragment spektrogramu STFT modułu wektora przestrzennego prądów stojana ($f_s = f_{sN} = 100$ Hz, $T_L = \text{var}$, $H = 2048$), b) odpowiedź klasyfikatora SVM



Rys.16. a) Fragment spektrogramu STFT modułu wektora przestrzennego prądów stojana ($f_s = f_{sN} = 100$ Hz, $T_L = \text{var}$, $H = 2048$), b) odpowiedź klasyfikatora MLP

Na rysunku 17 przedstawiono przebieg wartości międzyszczytowych prądów fazowych stojana (rys. 17a), wartość zmiennej $bIsFault$ typu $bool$, która przyjmuje wartość 0 w momencie, gdy nadrzędny klasyfikator uszkodzeń SVM nie wykrył uszkodzenia – na jego wyjściu jest wartość $N_{sh}=0$ oraz 1, gdy $N_{sh} > 1$ (wykryte uszkodzone uzwojenie). Z kolei na rysunku 17c przedstawiono odpowiedź lokalizatora uszkodzenia przy cyklicznym zwieraniu 5 zwojów kolejno w fazie A, B i C oraz zmieniających się warunkach pracy silnika. Wartości wyjściowe lokalizatora MLP (1, 2, 3) odpowiadają wykryciu uszkodzenia odpowiednio w fazie A, B oraz C. Opracowany model lokalizatora uzyskał bardzo wysoką skuteczność lokalizacji uszkodzenia równą 100%. Ze względu na bardzo

obietujące wyniki kaskadowego połączenia modelu SVM pracującego jako klasyfikatora uszkodzeń oraz sieci MLP jako lokalizatora uszkodzeń planowane są dalsze badania i testy w tym kierunku, szczególnie w kierunku analizy możliwości lokalizacji uszkodzenia w bardzo wczesnym stadium.

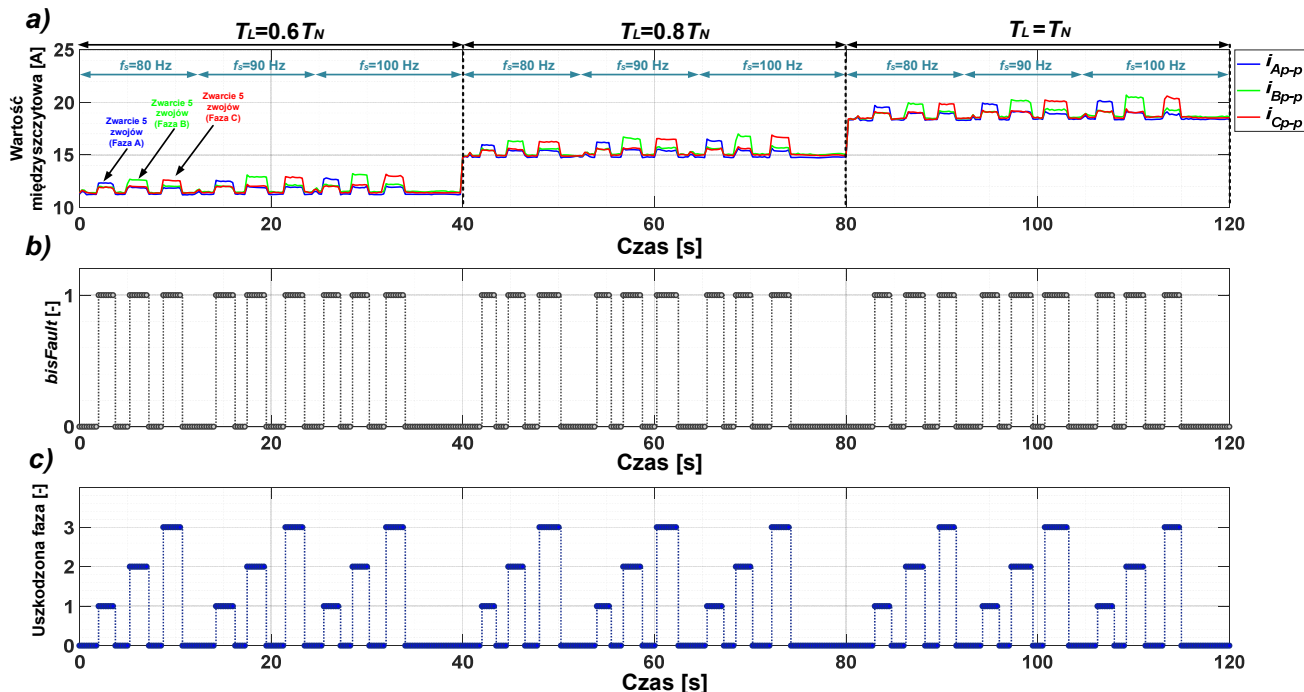
Podsumowanie

W artykule przedstawiono wyniki badań eksperymentalnych dotyczące dziedziny diagnostyki uszkodzeń uzwojeń stojana PMSM we wczesnym stadium. Zaprezentowano, zweryfikowano eksperymentalnie oraz porównano możliwość zastosowania analizy STFT sygnału prądu fazowego stojana oraz modułu wektora przestrzennego prądów stojana do ekstrakcji symptomów zwarcia międzyszczytowych, a także algorytmów bazujących na technikach sztucznej inteligencji do skutecznej klasyfikacji i lokalizacji tego typu awarii.

W artykule skupiono uwagę również na analizie wpływu kluczowych parametrów przygotowanych modeli klasyfikatorów uszkodzeń uzwojeń stojana na ich skuteczność

Dzięki wykorzystaniu kaskadowego połączenia modeli SVM oraz MLP uzyskano bardzo wysoką skuteczność nie tylko klasyfikacji uszkodzenia, ale również lokalizacji uszkodzonej fazy.

Dalsze badania prowadzone będą w kierunku weryfikacji możliwości lokalizacji uszkodzeń uzwojeń stojana PMSM we wczesnym stadium uszkodzenia oraz implementacji sprzętowej zaproponowanej metody.



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

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] Mishra I., Tripathi R.N., Singh V.K., Hanamoto T., Step-by-Step Development and Implementation of FS-MPC for a FPGA-Based PMSM Drive System, *Electronics*, 10 (2021), nr 395.
- [2] Knypiński Ł., Krupiński J., Application of the permanent magnet synchronous motors for tower cranes, *Przegląd Elektrotechniczny*, 96 (2020), nr 1, 27-30.
- [3] 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).
- [4] Huang S., Aggarwal A., Strangas E.G., Li K., Niu F., Huang X., Robust Stator Winding Fault Detection in PMSMs With Respect to Current Controller Bandwidth. *IEEE Transactions on Power Electronics*, 36 (2021), 5032–5042.
- [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] Chen Y., Liang S., Li W., Liang H., Wang C., Faults and Diagnosis Methods of Permanent Magnet Synchronous Motors: A Review. *Applied Sciences*, 9 (2019), nr 10, 2116.
- [8] 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.
- [9] 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.
- [10] 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.
- [11] 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.
- [12] 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.
- [13] 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.
- [14] Tarek K., Abdelaziz L., Zoubir C., Kais K., Karim N., Optimized multi layer perceptron artificial neural network based fault diagnosis of induction motor using vibration signals. *Diagnostyka*, 22 (2021). Nr (1), 65-74.
- [15] 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.
- [16] Satpathi, K., Yeap, Y. M., Ukil, A., Geddada, 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.
- [17] S. Liang, Y. Chen, H. Liang, and X. Li, "Sparse Representation and SVM Diagnosis Method Inter-Turn Short-Circuit Fault in PMSM," *Applied Sciences*, vol. 9, no. 2, p. 224, Jan. 2019.
- [18] D. Martens, B. B. Baesens, T. Van Gestel, "Decompositional Rule Extraction from Support Vector Machines by Active Learning", *IEEE Trans. Know. and Data Eng.*, Vol. 21, pp. 178-191, 2009.
- [19] 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.