

doi:10.15199/48.2023.04.06

Zastosowanie sieci neuronowych do detekcji zwarców zwojowych silnika PMSM z wykorzystaniem modelowania matematycznego

Streszczenie. W artykule zaprezentowano metodę diagnostyki zwarców zwojowych stojana silnika PMSM, wykorzystującą sieć neuronową. Przeanalizowano sygnały prądowe i napięciowe pochodzące ze struktury sterowania, a następnie poddano je analizie w celu ekstrakcji najlepszych symptomów uszkodzeń. Wybrane cechy podano na wejście sieci neuronowej podczas procesu treningu. Badania eksperymentalne prezentują potencjał zastosowania modelowania matematycznego jako generatora wzorców symptomów uszkodzeń.

Abstract. This paper presents a method for diagnosing the inter-turn short circuits of a PMSM, using a neural network. Current and voltage signals from the control structure were then analysed to extract the best fault symptoms. The selected features were given to the neural network input during the training process. The tests performed on an experimental setup demonstrate the potential of using mathematical modelling as a fault symptom pattern generator. (Application of neural networks to the detection of PMSM interturns short circuits windings using mathematical modelling).

Słowa kluczowe: diagnostyka uszkodzeń, zwarcia zwojowe, silnik synchroniczny z magnesami trwałymi, sieci neuronowe.

Keywords: damage diagnostics, shorted turns, Permanent Magnet Synchronous Motors, neural networks.

Wstęp

Ciągle rozwijający się przemysł oraz dążenie do najefektywniejszego wykorzystania energii elektrycznej powoduje, że silniki z magnesami trwałymi stają się coraz częściej stosowane. Silniki synchroniczne PMSM zawdzięczają swoją popularność wielu zaletom, takim jak wysoka sprawność, szeroki zakres regulacji prędkości obrotowej, duża przeciążalność momentem oraz mała bezwładność wirnika [1]. Pomimo wspomnianych zalet silników PMSM, są one również narażone na uszkodzenia występujące podczas eksploatacji. Dlatego awarie powinny być wykrywane w jak najkrótszym czasie i naprawiane. Niezareagowanie w odpowiednim momencie może doprowadzić do nagłego zatrzymania maszyny, prowadzącego do ogromnych strat ekonomicznych, jak również do zagrożeń w zakresie bezpieczeństwa. W związku z tym, diagnostyka usterek PMSM staje się coraz bardziej powszechna i znacząca w ostatnich latach [2].

Zwarcia zwojowe są typową usterką stojana w silnikach elektrycznych. Uszkodzenie w postaci zwarcia zwojowego w stojanie jest zwykle spowodowane zniszczeniem warstwy izolacyjnej pomiędzy uzwojeniami w tej samej fazie. Niewykryte uszkodzenie powoduje w początkowej fazie niewielkie zmiany, jednak jego zaniedbane przez pewien czas, powoduje gwałtowny wzrost lokalnej temperatury i prowadzi do całkowitego uszkodzenia całej fazy ze względu na ogromny prąd zwarcia [3]. Odzwierciedlenie zachowanie maszyny w stanach awaryjnych było opisywane w wielu artykułach [4-11]. Powstały opis matematyczny bazuje na: modelach analitycznych [4-7], wykorzystywanych do estymacji parametrów jak również badania dynamiki obiektów, oraz modelach polowo-obwodowych [8-11], które są wykorzystywane m.in. podczas projektowania nowo powstałych maszyn elektrycznych. Metody detekcji oparte na modelach wymagają dokładnego odzwierciedlenia parametrów maszyny, które w rzeczywistych warunkach mogą być trudne do precyzyjnego określenia.

Również prace z obszaru sieci neuronowych oraz uczenia maszynowego są obecne chętnie wykorzystywane w środowisku naukowym. Autorzy pracy [12] proponują zastosowanie przetworzenia prądów fazowych, a następnie wykorzystanie tej informacji trafia na wejście sieci neuronowej. Autorzy publikacji poruszyli temat wykrywania zwarców zwojowych, gdzie na podstawie analizy widmowej

sygnału prądu fazowego stojana dokonano ekstrakcji symptomów, a następnie wykorzystano maszynę wektorów nośnych do klasyfikacji zwarcia [13]. W literaturze również można znaleźć przykłady analizy symptomów oraz wykorzystania modeli polowo-odwodowy, jednak autorzy do uczenia sieci neuronowej wykorzystali wyłącznie dane eksperymentalne [14]. Podobne podejście zastosowano w publikacji [15] gdzie model został wykorzystany tylko do weryfikacji. Wykorzystana rekurencyjna sieć neuronowa pozwoliła na określenie stanu technicznego maszyny. Z kolei autorzy [16] wykorzystali zbioru danych utworzonych za pomocą modelu matematycznego nauczania sieci neuronowej.

Z aktualnego stanu badań wynika, że potrzebna jest dogłębna analiza modeli matematycznych, pozwalających modelować różne uszkodzenia pojawiające się w silnikach elektrycznych. Rozwinięcie tego obszaru badań pozwoli na ograniczenie kosztów związanymi z przystosowaniem specjalnie przygotowanych silników do poszukiwania symptomów jak również pozyskiwane symptomy będą zawierać tylko informację o określonym uszkodzeniu w maszynach elektrycznych.

W niniejszym artykule przedstawiono możliwość wykorzystania dwóch modeli matematycznych (model analityczny oraz polowo-obwodowy) pozwalających modelować uszkodzenia uzwojenia stojana. Informacje zawarte w modelach matematycznych zostały wykorzystane do przygotowania zestawów danych uczących. Symptomy uszkodzeń pozyskane z układu sterowania stanowią elementy wektorów wielowarstwowego klasyfikatora neuronowego. Należy wyraźnie podkreślić, że zastosowane modele silnika PMSM zostały wykorzystane jedynie do przygotowania wektorów uczących dla analizowanych sieci neuronowej. Testowanie opracowanych detektorów i klasyfikatorów uszkodzeń przeprowadzono metodą weryfikacji eksperymentalnej na rzeczywistym układzie napędowym. Weryfikację eksperymentalną proponowanych zastosowań diagnostycznych opartych na sieci neuronowej przeprowadzono na specjalnie zaprojektowanym stanowisku laboratoryjnym o mocy 2,5 kW PMSM.

Artykuł został podzielony na 5 nienumerowanych rozdziałów. Kolejny rozdział przedstawia w skrócie opis modeli matematycznych pozwalających na modelowanie zwarców zwojowych w silniku PMSM oraz układ sterowania

wektorowego zastosowanego w badaniach symulacyjnych, jak i eksperymentalnych. Zaprezentowano również wykorzystane stanowisko do badań eksperymentalnych. W kolejnym rozdziale pokazano ekstrakcję symptomów z układu sterowania oraz zaprezentowano wybrane sygnały diagnostyczne. Następnie opisano sieci neuronowe nauczone na podstawie danych z symulacji. Zaprezentowano podstawowe dane perceptronu wielowarstwowego, rodzaj wektora wejściowego oraz zastosowane struktury sieci. Kolejno przedstawiono odpowiedzi sieci oraz ich skuteczność w diagnostyce zwarcz zwojowych. Całość krótko podsumowano.

Metodyka badań silnika PMSM

Na rysunku 1 zaprezentowano schemat układu sterowania wraz z poszczególnymi obiektami badań. W celu umożliwienia analizy w podobnych warunkach, częstotliwość akwizycji danych wynosiła 8192 Hz, a podczas analizy wykorzystywano ustalony stan maszyny. Podczas badań użyto jeden z najczęściej wykorzystywanych systemów sterowania wektorowego silnika z magnesami trwałymi, który powszechnie można spotkać w zastosowaniach przemysłowych. W pracy wykorzystano układ bezpośredniego sterowania połowo zorientowanego DFOC, wraz z układem odsprzęgania torów sterowania d-q. Schemat ideowy analizowanego układu przedstawiono na rysunku 1a. Układ sterowania składa się z trzech regulatorów typu PI oraz układu odsprzęgającego. Nadrzędny regulator prędkości

wypracowuje wartość dla regulatora prądu w osi q, natomiast regulator w osi d wymusza składową $I_{sd} = 0$, zgodnie z przyjętą ideą sterowania z zachowaniem stałego kąta mocy. Wyjścia regulatorów prądu są odsprzęgane za pośrednictwem sygnałów napięciowych E_{sd} oraz E_{sq} .

Sygnały odsprzęgające opisano następującymi równaniami

$$(1) \quad E_{sd} = -p_p \Omega_m \hat{\Psi}_{sq},$$

$$(2) \quad E_{sq} = p_p \Omega_m \hat{\Psi}_{sd},$$

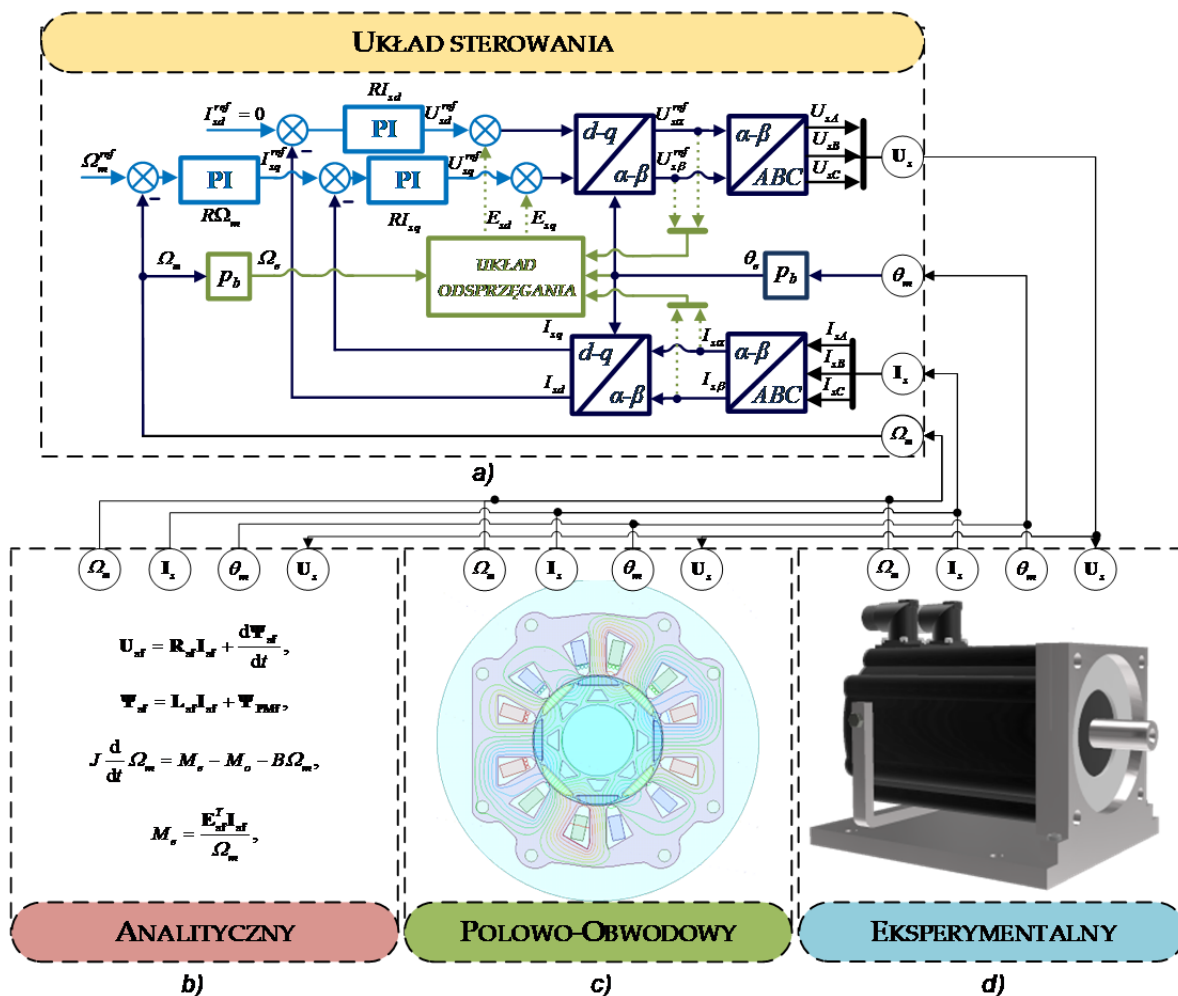
gdzie: p_p – liczba par biegunów, Ω_m – prędkość kątowna wału, $\hat{\Psi}_{sd}, \hat{\Psi}_{sq}$ – estymowane składowe wektora strumienia stojana.

Niezbędne do odsprzęgania wartości składowych strumienia stojana estymuje się następującymi równaniami:

$$(3) \quad \frac{d}{dt} \hat{\Psi}_{sa} = U_{sa} - R_s I_{sa} - \frac{1}{T_f} \hat{\Psi}_{sa},$$

$$(4) \quad \frac{d}{dt} \hat{\Psi}_{sb} = U_{sb} - R_s I_{sb} - \frac{1}{T_f} \hat{\Psi}_{sb},$$

gdzie T_f – stała czasowa filtru dolnoprzepustowego.



Rys.1. Ujednoczony schemat akwizycji danych silnika PMSM dla wszystkich badanych przypadków: a) układ sterowania, b) model analityczny, c) model połowo-obwodowy, d) obiekt eksperymentalny

W estymatorze zastosowany jest najprostszy filtr dolnoprzepustowy (ze stałą czasową T_f), który eliminuje problemy z określeniem warunków początkowych i dryftem DC spowodowanym przesunięciami czujnika pomiarowego. Do poprawnej pracy opisanego układu sterowania niezbędne jest uzyskanie z badanego modelu informacji o aktualnych prądach fazowych I_s , aktualnym położeniu wirnika θ_m oraz prędkości kątowej Ω_m .

Model analityczny silnika PMSM z uwzględnieniem zwarc zwojowych w uzwojeniu stojana

Do odtworzenia zjawisk zachodzących w silniku PMSM, podczas pracy w stanie nieuszkodzonym, jak również podczas stanów awaryjnych wykorzystano model matematyczny. Podstawowe wzory opisujące model analityczny zaprezentowano na rysunku 1b. Omawiany model wymaga zastosowania szeregu założeń upraszczających, tj.:

- parametry indukcyjności oraz rezystancji przyjmuje się za stałe,
- obwody magnetyczne są liniowe, izotropowe (pomija się nasycenia, prądy wirowe oraz zjawisko histerezy),
- szczelina powietrzna maszyny jest regularna w całym obwodzie,
- uwzględnia się jedynie harmoniczną podstawową rozkładu pola w szczelinie powietrznej, pozostałe są pomijane,
- przyjmuje się sinusoidalny rozkład indukcji magnetycznej w szczelinie powietrznej,
- brak uzwojenia w wirniku z powodu zastosowania magnesów trwałych.


Powyższe założenia powiązane z podstawowymi prawami elektrotechniki takimi jak prawo Kirchhoffa pozwalają na sformułowanie modelu analitycznego. Parametry omawianego silnika zaprezentowano w Tabeli 1. Dokładny opis matematyczny modelu, wraz ze szczegółowymi badaniami oraz wpływem zwarcia zwojowego na poszczególne prądy fazowe przedstawiono w [17].

Model polowo-obwodowy silnika PMSM z uwzględnieniem zwarc zwojowych w uzwojeniu stojana

Opracowując model polowo-obwodowy silnika PMSM wykorzystano silnik o mocy 2,5 kW firmy Lenze model 14H 15. Dokładne parametry silnika zestawiono w tabeli 1 jak również można odnaleźć w nocie katalogowej silnika. Na rysunku 1c zaprezentowano poglądowy przekrój silnika. Odzwierciedlono geometrię wirnika z rozmieszczonymi magnesami trwałymi, jak również stojan maszyny. Zastosowane w silniku Lenze 14H15 uzwojenie stojana ma charakter skupiony, na jedną fazę składają się po dwa pasma po 125 zwojów.

W celu umożliwienia modelowania uszkodzeń w postaci zwarc zwojowych odseparowano z jednego pasma odpowiednio jeden, dwa oraz trzy zwoje. Podczas pracy w stanie nieuszkodzonym przez pasma silnika przepływa wyłącznie prąd roboczy. Natomiast podczas stanów awaryjnych uszkodzenie stojana modelowane jest poprzez zmianę rezystancji R_f do wartości około 1 m Ω co odpowiada praktycznie metalicznemu zwarciu uszkodzonej części uzwojenia silnika. W uszkodzonej części powstaje oczko zwarciove, przez które przepływa prąd zwarciovy, co pokazane zostało na rysunku 2.

Utworzony model polowo-obwodowy w całości został wykonany w oprogramowaniu Ansys Maxwell. Dokonywane badania wykonywane są w procesie co-symulacji, gdzie następuje wymiana danych między modelem silnika (Ansys Maxwell) a układem sterowania (MATLAB-Simulink).




Rys. 2. Podział uzwojenia stojana podczas wystąpienia zwarcia zwojowego

Tabela 1. Parametry silnika Lenze 14H15

Nazwa parametru	Symbol	Wartość	Jednostka
Moc znamionowa	P_N	2500	W
Moment znamionowy	M_N	16	Nm
Prędkość znamionowa	n_N	1500	obr/min
Napięcie znamionowe	U_{sN}	325	V
Prąd znamionowy	I_{sN}	6,6	A
Częstotliwość znamionowa	f_{sN}	100	Hz
Liczba par biegunów	p_p	4	–
Liczba zwojów jednej fazy	N_s	2x125	–
Moment bezwładności silnika	J	1,42	kg cm ²
Indukcja remanentu	B_r	1,27	T
Rezystancja uzwojenia stojana	R_s	1,206	Ω
Indukcyjność uzwojenia stojana	L_s	7,02	mH

Stanowisko do badań silnika PMSM pozwalającego realizować zwarcia zwojowe

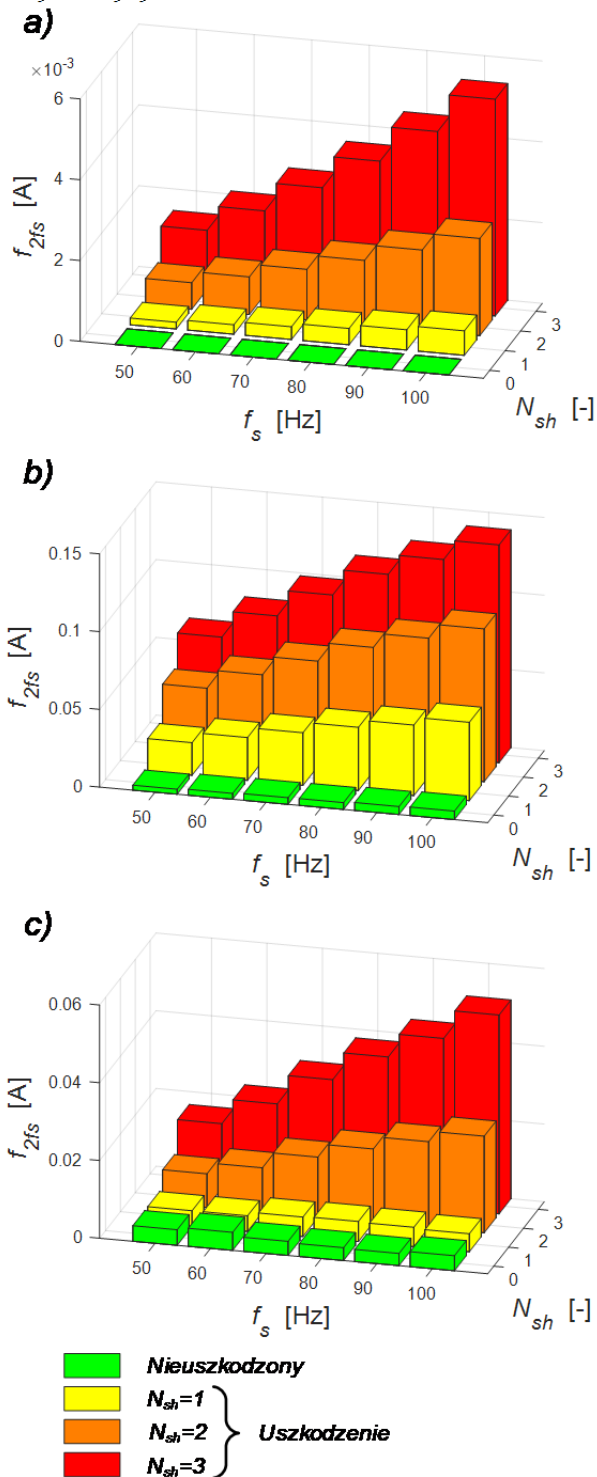
Schemat ideowy stanowiska do badań eksperymentalnych przedstawiono na rysunku 3. Obiektem badań był wcześniej wspomniany silnik PMSM 14H15 o mocy 2,5 kW firmy Lenze ①. Silnik zasilany był z przemiennika częstotliwości firmy TWERD ④ wyposażonego w interfejs światłowodowy, który umożliwił wykorzystanie układu sterowania zaprezentowanego na rysunku 1a. Badany silnik został sprzęgnięty mechanicznie z silnikiem PMSM 15H32 firmy Lenze ② zasilanym z przemiennika częstotliwości Lenze 8400 TopLine C ③. Regulacja momentu obciążenia była dokonywana poprzez zadanie wartości momentu generowanego w oprogramowaniu NI VeriStand zainstalowanym na komputerze przemysłowym NI PXI 8186 ⑥. Niezbędne pomiary prądów oraz napięcia DC potrzebne w układzie sterowania rejestrowane były za pośrednictwem przetworników pomiarowych LEM LA 25-NP ⑤.



Rys. 3. Schemat stanowiska eksperymentalnego

Ekstrakcja symptomów uszkodzeń stojana w silniku PMSM

Diagnostyka stanu technicznego maszyny wymaga obserwacji maszyny w celu wykrywania zmian wartości mierzonych w czasie. Zmiana trendów widocznych w maszynie pozwala określić rodzaj usterki, jak również wyodrębnić charakterystyczne jej symptomy. Podczas badań symulacyjnych, jak i eksperymentalnych wykorzystano szybką transformatę Fouriera, która jest najczęściej wykorzystywana w stacjonarnych warunkach pracy maszyny.




Rys. 4. Analiza symptomów uszkodzenia widocznych w sygnale prądowym I_{sd} dla $M_o \approx 0$, dla a) modelu analitycznego, b) modelu polowo-obwodowego, c) eksperymentu.

Podczas badań poszukiwano symptomów z zamkniętego układu regulacji silnika; pod uwagę wzięto dwa sygnały prądowe I_{sd} , I_{sq} , oraz 4 sygnały napięciowe E_{sd} , E_{sq} , U_{sd} , U_{sq} . Wyodrębnione symptomy uzyskane w wyniku modelowania analitycznego oraz polowo-obwodowego przeanalizowano pod kątem opracowania detektorów uszkodzeń neuronowych. Porównano je z symptomami uzyskanymi na podstawie pomiarów silnika rzeczywistego z takim samym uszkodzeniem wykonanych na stanowisku laboratoryjnym opisanym w poprzedniej sekcji. Podczas badań analizowano amplitudy sygnałów harmonicznycch o częstotliwościach $2f_s$ oraz $4f_s$. Przykładowe zestawienie składowej prądu w osi d zaprezentowano na rysunku 4. Jak można zauważyć składowa $2f_s$, rośnie wraz ze wzrostem częstotliwości, jak również widoczny jest wzrost analizowanej składowej wraz z nasilającym się uszkodzeniem. W przypadku modelu analitycznego (rys. 4a), można zauważyć niewielkie wartości amplitud analizowanej składowej, jak również to, że jej wartość wynosi w przybliżeniu zero w sytuacji braku uszkodzenia, co w jest nierealne w warunkach rzeczywistych.

Po przeanalizowaniu danych wybrano następujące sygnały: I_{sd} , U_{sd} , E_{sq} , które poddano normalizacji do wektorów wejściowych w zakresie od -1 do 1.

Proces treningu i testowania sieci neuronowej został przeprowadzony z wykorzystaniem środowiska MATLAB. Zbiór uczący stanowiły wyłącznie próbki z modelu matematycznego, natomiast w zbiorze testującym znalazły się próbki uzyskane podczas pomiarów na modelu rzeczywistym. Dla wszystkich analizowanych przypadków zastosowano 144 próbki uczące w zbiorze treningowym oraz testującym.



Rys. 5. Znormalizowana wartość symptomu prądu I_{sd} dla $M_o = var$, $f_s = var$ dla modelu analitycznego, modelu polowo-obwodowego oraz eksperymentu.

Detekcja uszkodzeń obwodów elektrycznych silnika PMSM

W pracy do wykrywania uszkodzeń stojana silnika PMSM pracującego w zamkniętej strukturze sterowania polowo zorientowanego wykorzystano sztuczne sieci neuronowe. Zaprojektowano detektory oparte na jednodierunkowych sieciach neuronowych z dwoma warstwami ukrytymi, złożone z neuronów o nieliniowych funkcjach aktywacji.

W procesie uczenia wykorzystano dane z modelowania PMSM. Wektor wejściowy sieci zawierał amplitudy widma składowych I_{sd} , U_{sd} , E_{sq} o częstotliwości $2f_s$.

Przebieg procesu uczenia sieci MLP odbywa się poprzez prezentację sieci neuronowej wszystkich wektorów wejściowych i odpowiadających im reakcji systemu. Parametry perceptronu wielowarstwowego oraz procesu treningu dla modelu analitycznego zaprezentowano w tabeli 2, natomiast dla modelu polowego w tabeli 3.

Zaprezentowane dane można podzielić na 4 przypadki w zależności od faktu wystąpienia uszkodzenia: jego braku

($N_{sh} = 0$) oraz uszkodzenia uzwojenia ($N_{sh} = 1, 2, 3$). Każdy stopień zawierał 24 próbki dla różnych warunków pracy maszyny w zakresach częstotliwości stojana od 50 do 100 Hz z krokiem co 10 Hz oraz zmiany momentu obciążenia M_o od 0 do 1 z krokiem 0,2 M_N .


Skuteczność sieci neuronowych oceniono 2 etapowo. W pierwszym kroku skupiono się na skuteczności detekcji wystąpienia uszkodzenia. Rozróżniono dwa stany: stan „Nieuškodzony” oraz stan „Uszkodzony”. W kolejnym kroku oceniono zdolność klasyfikacji uszkodzenia, czyli dokładnej prezentacji stanu uszkodzenia maszyny (liczby zwartych zwojów). Zestawienie odpowiedzi sieci neuronowych dla danych uzyskanych na obiekcie rzeczywistym przedstawiono na rysunkach 7-10.

Tabela 2. Parametry sieci neuronowej podczas procesu treningu dla danych z modelu analitycznego


Nazwa parametru	Wartość
Struktura (liczba neuronów w warstwach)	{3}-{10}-{3}-{4}
Rozmiar wektora wejściowego	[1x3]
Funkcja aktywacji	Tangens hiperboliczny
Normalizacja wektora wejściowego	[-1,1]
Algorytm uczący	Levenberg-Marquardt
Liczba epok treningowych	100
Dane treningowe (symulacja) rozmiar pakietu	144
Dane testowe (pomiary rzeczywiste) rozmiar pakietu	144
Liczba rozpatrywanych stanów	2
Liczba rozpatrywanych kategorii klasyfikacji usterek	4

Tabela 3. Parametry sieci neuronowej podczas procesu treningu dla danych z modelu polowo-obwodowego

Nazwa parametru	Wartość
Struktura (liczba neuronów w warstwach)	{3}-{4}-{5}-{4}
Rozmiar wektora wejściowego	[1x3]
Funkcja aktywacji	Tangens hiperboliczny
Normalizacja wektora wejściowego	[-1,1]
Algorytm uczący	Levenberg-Marquardt
Liczba epok treningowych	400
Dane treningowe (symulacja) rozmiar pakietu	144
Dane testowe (pomiary rzeczywiste) rozmiar pakietu	144
Liczba rozpatrywanych stanów	2
Liczba rozpatrywanych kategorii klasyfikacji usterek	4




Rys. 7. Odpowiedź detektora nauczonego na podstawie danych z modelu analitycznego.




Rys. 8. Odpowiedź detektora nauczonego na podstawie danych z modelu polowo-obwodowym.

Analiza klasyfikatorów neuronowych podczas badań eksperymentalnych przedstawiona została na rysunkach 7–8. Zastosowanie danych uczących z modeli pokazuje możliwość detekcji uszkodzenia, co potwierdza poprawność zaproponowanego podejścia diagnostycznego. Podczas

weryfikacji systemu opartego na sieci neuronowej określono skuteczność detekcji wystąpienia uszkodzenia na poziomie 82% dla danych z modelu analitycznego oraz 88% dla danych z modelu polowo-obwodowego. Sieć neuronowa poprawnie sklasyfikowała stopień uszkodzenia w 63% przypadków dla danych z modelu analitycznego, natomiast dla sieci nauczonej z danych modelu polowo-obwodowego skuteczność klasyfikacji wynosiła 74%. Jak widać na rys. 9–10, dezinformacja o stanie PMSM najczęściej polega na wykryciu jednego zwartego zwoju ($N_{sh} = 1$) zamiast braku uszkodzenia ($N_{sh} = 0$). Należy natomiast zauważyć, że stan jednego zwartego zwoju jest trudny do rozpoznania ze względu na niewielkie zmiany sygnału diagnostycznego w porównaniu ze stanem zdrowym silnika.



Rys. 9. Odpowiedź klasyfikatora nauczonego na podstawie danych z modelu analitycznego.



Rys. 10. Odpowiedź klasyfikatora nauczonego na podstawie danych z modelu polowo-obwodowego.

Wnioski

W artykule zaprezentowano modele matematyczne silnika PMSM w zastosowaniu do utworzenia detektorów neuronowych uszkodzeń stojana dla napędu sterowanego metodą wektorową. Ponadto zaprezentowano badania eksperymentalne dla napędu pracującego ze zwarcie zwojowym. Wykorzystanie informacji z modeli matematycznych pozwala na niewątpliwą przewagę w zakresie generowania wzorców diagnostycznych dla dowolnych warunków pracy maszyny. Zaproponowane podejście pozwala na uzyskanie symptomów i zaniechanie fizycznego modelowania uszkodzeń analizowanego obiektu, co szczególnie w przypadku silników o większej mocy może być kosztowne i niebezpieczne.

Wyniki badań symulacyjnych uzyskane na podstawie modeli matematycznych odpowiadają sytuacji, w której napęd pracuje w idealnych warunkach. Widoczny jest również wpływ warunków upraszczających na działanie modelu analitycznego, gdzie widać brak wpływu zakłóceń pomiarowych, błędów czujników oraz asymetrii elektrycznej i mechanicznej maszyn. Wpływ warunków zewnętrznych widoczny jest w widmach FFT obiektu eksperymentalnego, gdzie w mierzonych sygnałach ze struktury pojawiają się zwiększonego poziomu szumu pomiarowego.

Niemniej jednak przedstawione w artykule wyniki badań eksperymentalnych potwierdzają możliwość praktycznego wdrożenia zaproponowanej metody diagnostycznej dla napędów PMSM. Należy zaznaczyć, że zaproponowane detektory neuronowe oparte są wyłącznie na danych symulacyjnych. Jednakże, są w stanie wykryć awarię napędu. Informacje zawarte w symulacjach dostarczają podstawowych informacji na temat trendów zmian podczas pracy napędu w stanach uszkodzeń.

Badania finansowane przez Narodowe Centrum Nauki w ramach projektu 2017/27/B/ST7/00816.

Autorzy: mgr inż. Mateusz Krzysztofiak, dr hab. inż. Grzegorz Tarchala, Politechnika Wroclawska, Katedra Maszyn, Napędów i Pomiarów Elektrycznych, ul. Smoluchowskiego 19, 50-372 Wrocław, E-mail: mateusz.krzysztofiak@pwr.edu.pl; E-mail: grzegorz.tarchala@pwr.edu.pl.

LITERATURA

- [1] Zawirski K., Deskur J., Kaczmarek T., Automatyka napędu elektrycznego. *Wydawnictwo Politechniki Poznańskiej*, 2012
- [2] Orłowska-Kowalska, T., Wolkiewicz, M., Pietrzak, P., Skowron, M., Ewert, P., Tarchala, G., Krzysztofiak, M., Kowalski, C.T., Fault Diagnosis and Fault-Tolerant Control of PMSM Drives- State of the Art and Future Challenges, *IEEE Access*, 10 (2022), str. 59979-60024
- [3] Antal L., Gwoździewicz M., Marciniak T., Antal, M.. Badania skutków cieplnych zwarć zwojowych w uzwojeniach stojana silnika indukcyjnego. *Prace Naukowe Instytutu Maszyn, Napędów i Pomiarów Elektrycznych Politechniki Wrocławskiej. Studia i Materiały*, 66(32, t. 2), (2012), str. 316-324.
- [3] Foitzik, S., Doppelbauer, M. Simulation of stator winding faults with an analytical model of a PMSM. *2018 IEEE International Conference on Power Electronics, Drives and Energy Systems (PEDES)*, (2018), str. 1-6.
- [5] Ma Y., Wang J., Xiao Y., Zhou L., Kang, H. Transfer learning-based surrogate-assisted design optimisation of a five-phase magnet-shaping PMSM. *IET Electric Power Applications*, 15(10), (2021). Str. 1281-1299.
- [6] Romeral L., Urresty J. C., Ruiz J. R. R., Espinosa, A. G. Modeling of surface-mounted permanent magnet synchronous motors with stator winding interturn faults. *IEEE Transactions on Industrial Electronics*, 58(5), (2010). str. 1576-1585.
- [7] Ge Y., Song B., Pei Y., Mollet Y. A., Gyselinck J. J. Analytical expressions of isolation indicators for permanent-magnet synchronous machines under stator short-circuit faults. *IEEE Transactions on Energy Conversion*, 34(2), (2018), str. 984-992.
- [8] Fitouri M., Bensalem Y., Abdelkrim M. N. Modeling and detection of the short-circuit fault in PMSM using Finite Element Analysis. *IFAC-PapersOnLine*, 49(12), (2016), str. 1418-1423.
- [9] Jeong H., Lee H., Kim S. W., Classification and Detection of Demagnetization and Inter-Turn Short Circuit Faults in IPMSMs by Using Convolutional Neural Networks, *2018 IEEE Energy Conversion Congress and Exposition (ECCE)*, Portland, OR, USA, (2018) str. 3249-3254,
- [10] Sun W., Hang J., Ding S., Hu Q., Ren X., Electromagnetic Parameters Analysis of Inter-Turn Short Circuit Fault in DTP-PMSM Based On Finite Element Method, *2020 8th International Conference on Power Electronics Systems and Applications (PESA)*, Hong Kong, China, pp. 1-4 (2020),
- [11] Alvarez-Gonzalez F., Griffo, A., Wang, B. Permanent magnet synchronous machines inter-turn short circuit fault detection by means of model-based residual analysis. *IECON 2018-44th Annual Conference of the IEEE Industrial Electronics Society*, (2018). str. 647-652.
- [12] Bazan G. H., Scalassara P. R., Endo W., Goedtel A., Palácios R. H. C., Godoy, W. F. Stator short-circuit diagnosis in induction motors using mutual information and intelligent systems. *IEEE Transactions on Industrial Electronics*, 66(4), (2018). Str. 3237-3246.
- [13] Pietrzak, P., Wolkiewicz, M. Application of Support Vector Machine to stator winding fault detection and classification of permanent magnet synchronous motor. *2021 IEEE 19th International Power Electronics and Motion Control Conference (PEMC)*, (2021), str. 880-887.
- [14] Moosavi S. S., Djerdir A., Ait-Amirat Y., Khaburi D. A. ANN based fault diagnosis of permanent magnet synchronous motor under stator winding shorted turn. *Electric Power Systems Research*, 125, (2015), str. 67-82.
- [15] Dai X., Zhang Y., Qiao L., Sun, D. Fault Diagnosis of Permanent Magnet Synchronous Motor Based on Improved Probabilistic Neural Network. *2021 40th Chinese Control Conference (CCC)*, (2021), str. 2767-2772
- [16] Sá B. A., Barros C. M., Siebra C. A., Barros L. S. A multilayer perceptron-based approach for stator fault detection in permanent magnet wind generators. *2019 IEEE PES Innovative Smart Grid Technologies Conference-Latin America (ISGT Latin America)* (2019), str. 1-6,
- [17] Krzysztofiak, M., Skowron, M., Orłowska-Kowalska, T. Analysis of the impact of stator inter-turn short circuits on PMSM drive with scalar and vector control. *Energies*, 14(1), (2020).str. 153.