

Jarosław Kozik

Akademia Górniczo-Hutnicza, Kraków

ZASTOSOWANIE SIECI NEURONOWYCH W DETEKCJI USZKODZEŃ SILNIKA SYNCHRONICZNEGO ZE ZWARTYM UZWOJENIEM WIRNIKA

APPLICATION OF NEURAL NETWORKS IN FAULTS DETECTION OF THE SYNCHRONOUS MOTOR WITH SHORTED FIELD WINDING

Abstract: This paper describes an automatic recognition of synchronous motor faults based on spectral analysis of stator and field currents with the aid of neural networks. As the diagnostic object a specially designed and constructed 2-pair pole synchronous machine with two parallel branches containing two groups of coils on each stator phase was used. The ends of every group are accessible allowing different connections to be made thus simulation of various fault conditions to be done. For the purpose of the paper a nineteen different fault conditions were investigated, including alone breaks of one group of coils for each phase, simultaneous breaks of one group of coils for each pair of phases and for all three phases, alone shorts of one group of coils for each phase and combined short and break faults. The spectral analysis of the phase and field currents revealed the frequencies which are representative for a particular fault. The amplitudes relating to these frequencies were then used in automatic process of motor state recognition. The recognition was made by a two different neural networks – one for analyzing the phase currents and the other one for analyzing the field current.

1. Wstęp


Maszyny elektryczne, podobnie jak inne urządzenia elektryczne i mechaniczne są wystawione na ciągłe działanie różnorodnych czynników zewnętrznych i wewnętrznych, mających charakter destrukcyjny [1]. Czynniki te są przyczyną powstawania postępujących stopniowo i nieodwracalnych zmian w strukturze maszyny oraz jej funkcjonalności i prowadzą do występowania uszkodzeń, których stopień bardzo szybko się pogłębia, znacznie podnosząc koszt późniejszej naprawy. Dlatego bardzo istotne jest wykrycie powstających uszkodzeń we wczesnym ich stadium i przedsięwzięcie odpowiednich kroków w celu ich usunięcia. Dodatkowo ciągle monitorowanie stanu maszyn i urządzeń pozwala odpowiednio wcześniej zaplanować harmonogram ich remontów, co ma ogromne znaczenie w warunkach przemysłowych, gdzie każda przerwa spowodowana awarią urządzeń wiąże się z bardzo wysokimi kosztami. Powszechnie stosowane nieinwazyjne metody diagnostyki stanu maszyn w trakcie ich pracy opierają się głównie na analizie spektralnej lub falkowej prądów, strumienia osiowego, drgań oraz hałasu (dźwięku), a wnioskowanie dokonywane jest przez eksperta. Jednak bardzo szybki rozwój elektroniki i techniki mikroprocesorowej jaki dokonał się w ostatnich dziesięcioleciach, doprowadził do upowszechnienia się

automatycznych metod wnioskowania opartych na technikach sztucznej inteligencji. Niniejszy artykuł poświęcony jest wykrywaniu uszkodzeń silnika synchronicznego ze zwartym uzwojeniem wirnika bazującym na analizie spektralnej prądów stojana oraz wirnika z zastosowaniem sieci neuronowej jako automatycznego klasyfikatora stanu obiektu.

2. Opis układu diagnostycznego

2.1 Obiekt diagnostyczny

Obiekt diagnostyczny stanowi maszyna synchroniczna o specjalnym wykonaniu, pozwalającym na symulowanie stanów awaryjnych. Stojan maszyny posiada uzwojenia dwuwarstwowe umieszczone w 48 żłobkach. Każda z faz stojana posiada po dwie gałęzie równoległe, z których każda składa się z dwóch grup zwojów. Końce każdej z grup są wyprowadzone na zewnątrz maszyny, przez co możliwe są różne konfiguracje ich połączeń, a przez to symulacja różnych stanów awaryjnych. Wirnik maszyny jest jawnobiegunowy o 4 biegunach i 145 zwojach/biegun. Schemat połączeń uzwojeń stojana dla stanu bezawaryjnego przedstawiono na rysunku 1. Podczas prób wirnik był zwarty przez rezystancję stanowiącą dziesięciokrotność jego własnej rezystancji.




Rys. 1. Schemat połączeń uzwojeń stojana maszyny dla stanu bezawaryjnego

2.2 Symulowane stany awaryjne

Dla celów niniejszej pracy dokonana została symulacja 19 różnych stanów awaryjnych takich jak: przerwa w jednej grupie zewojów w jednej fazie (dla każdej z faz osobno), jednoczesna przerwa w jednej grupie zewojów w dwóch fazach (dla każdej pary faz osobno), oraz w trzech fazach jednocześnie, zwarcie jednej grupy zewojów w jednej fazie (dla każdej z faz osobno) oraz różne kombinacje zwarć w jednej fazie i przerw w jednej, dwóch i trzech fazach. Zwarcia dokonywane były przez rezystancję zwierającą o wartości $1,25 \Omega$.

2.3 Procedura wyznaczania zbiorów uczących i weryfikacyjnych dla sieci neuronowych

Zbiory uczące i weryfikacyjne dla sieci neuronowych wyznaczono według schematu pokazanego na rysunku 2.



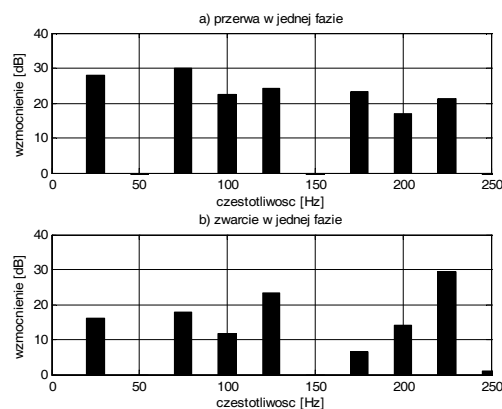
Rys. 2. Sposób wyznaczania zbiorów uczących i weryfikacyjnych dla sieci neuronowych

Sygnały prądowe (stojana oraz wirnika) z przekładników poddawane były filtracji w celu uniknięcia zjawiska aliasingu. W tym celu wykorzystano filtry Butterwortha trzeciego rzędu o częstotliwościach charakterystycznych 5 kHz. Odfiltrowane sygnały były następnie rejestrowane przez kartę pomiarową zainstalowaną w komputerze PC. Częstotliwość próbkowania wynosiła 25 kHz. Przeprowadzono osiem serii pomiarów (każda w inny dzień), podczas których dwukrotnie rejestrowano przebiegi dla wszystkich branych pod uwagę przypadków awarii oraz dla stanu bezawaryjnego. Następnie

wszystkie próbki poddano analizie FFT w środowisku Matlab i na jej podstawie wybrano częstotliwości, których amplitudy w wyniku uszkodzenia zmieniają się w wyraźny sposób dla wszystkich próbek pomiarowych. Następnie wartości tych amplitud odniesione do odpowiadających im wartości amplitud dla stanu bezawaryjnego (uśrednionych dla wszystkich próbek) w połączeniu z żadaną odpowiedzią sieci użyte zostały do zbudowania zbiorów uczącego oraz weryfikacyjnego dla sieci neuronowych (osobne zbiory dla prądu wirnika i prądów stojana).

3. Analiza spektralna prądu wirnika

Transformowane do dziedziny częstotliwości za pomocą funkcji FFT próbki sygnałów poddane zostały analizie, podczas której dokonano oceny przydatności amplitud odpowiadających poszczególnym częstotliwościom do wykrywania stanu maszyny. Podczas analizy stwierdzono, że amplitudy odpowiadające częstotliwościom: 25 Hz, 75 Hz, 100 Hz, 125 Hz, 175 Hz, 200 Hz oraz 225 Hz ulegają największym zmianom w wyniku wystąpienia uszkodzenia, a przy tym zmiany te zachodzą dla wszystkich badanych próbek pomiarowych. Uśrednione dla wszystkich próbek pomiarowych zmiany amplitud harmonicznych prądu wirnika, odpowiadające stanom przerwy jednej grupy zewojów w jednej fazie oraz zwarcia jednej grupy zewojów w jednej fazie, przedstawione zostały na rys. 3.



Rys. 3. Zmiany amplitud odpowiadających poszczególnym częstotliwościom powstałe w wyniku wystąpienia stanów awaryjnych: przerwy (a) i zwarcia (b)

4. Analiza spektralna prądów stojana


Podczas analizy spektralnej prądów stojana postępowano podobnie jak w przypadku prądu wirnika. Analizowano prądy we wszystkich

trzech fazach jednocześnie. W trakcie oceny zmian amplitud poszczególnych harmoniczných stwierdzono, iż nie są one tak wyraźne jak w przypadku prądu wirnika, a zatem informacja diagnostyczna zawarta w prądach stojana badanego silnika pracującego ze zwartym wirnikiem wydaje się być mniej przydatna w procesie detekcji uszkodzeń, niż informacja zawarta w prądzie zwartego wirnika. Ostatecznie, jako dające najlepszą informację o stanie silnika, wytypowano trzy częstotliwości: 25 Hz, 150 Hz i 175 Hz.

5. Struktury sieci neuronowych do rozpoznawania stanów awaryjnych

5.1 Struktura sieci do detekcji uszkodzeń bazującej na prądzie wirnika

Po przeprowadzeniu analizy spektralnej prądu wirnika wytypowano siedem częstotliwości, które najlepiej obrazują stan badanego silnika. Amplitudy odpowiadające tym częstotliwościom wykorzystane zostały jako wielkości wejściowe dla sieci neuronowej determinując liczbę neuronów w jej warstwie wejściowej. Ilość neuronów w warstwie wyjściowej wynika z informacji, którą sieć powinna zwracać. Ponieważ oczekuje się, że sieć będzie informować o wystąpieniu jednego z czterech stanów: bezawaryjnego, przerwy, zwarcia oraz przerwy ze zwarciem liczbę neuronów w warstwie wyjściowej ustalono na trzy. Możliwe są zatem następujące odpowiedzi generowane przez sieć: 1,0,0 dla stanu bezawaryjnego, 0,1,0 dla przerwy, 0,0,1 dla zwarcia oraz 0,1,1 dla przerwy ze zwarciem.




Rys. 4. Struktura sieci neuronowej do detekcji uszkodzeń silnika synchronicznego bazującej na widmie prądu wirnika

Liczba warstw ukrytych oraz neuronów w tych warstwach została wyznaczona na podstawie wyników przeprowadzonych prób, polegających na uczeniu i późniejszej weryfikacji działania sieci w różnych jej konfiguracjach.

Strukturę sieci neuronowej do detekcji uszkodzeń bazującej na analizie prądu wirnika przedstawiono na rysunku 4.

5.2 Struktura sieci do detekcji uszkodzeń bazującej na prądach stojana

Strukturę sieci do detekcji uszkodzeń bazującej na analizie prądów stojana przedstawiono na rysunku 5. Od zaprezentowanej w poprzednim punkcie sieci, która bazuje na analizie prądu wirnika odróżnia ją ilość neuronów w warstwie wejściowej. Ponieważ zaobserwowano, iż uszkodzenia najlepiej uwidaczniają się w amplitudach odpowiadających trzem częstotliwościom i analizowane są prądy we wszystkich trzech fazach, liczba neuronów wejściowych w tym przypadku wynosi 9. Liczba neuronów warstwy wyjściowej oraz sposób prezentowania odpowiedzi sieci są takie same jak w przypadku sieci bazującej na widmie prądu wirnika. Optymalna liczba warstw ukrytych oraz neuronów w tych warstwach została wyznaczona symulacyjnie.



Rys. 5. Struktura sieci neuronowej do detekcji uszkodzeń silnika synchronicznego bazującej na widmach prądów stojana

6. Wyniki rozpoznawania

Wyniki rozpoznawania w dużym stopniu zależą od konfiguracji sieci, od metody i przebiegu jej uczenia oraz od wartości początkowych wag poszczególnych neuronów. W celu określenia optymalnej konfiguracji sieci przeprowadzono liczne symulacje (trenowanie oraz weryfikacja) dla różnej liczby warstw sieci oraz liczby neuronów w warstwie. Kryterium oceny działania sieci była liczba błędnych odpowiedzi w procesie jej weryfikacji. Za odpowiedź błędną uznaje się odpowiedź w której wartość na poszczególnym neuronie warstwy wyjściowej różni się więcej niż o 10% od wartości jaka jest oczekiwana (0 lub 1). Ciąg testujący składał się z 80 próbek. Jak się okazało, konstrukcja ciągu uczącego również ma wpływ na przebieg procesu uczenia sieci. Spośród kilku rozpatrywa-

nych algorytmów uczenia sieci autor uznał za najlepszy algorytm Levenberga-Marquardta [2]. Liczba epok (kolejnych prezentacji sieci ciągu uczącego) uzależniona jest od struktury sieci (od jej rozmiarów) i również wyznaczona została doświadczalnie dla różnych konfiguracji sieci. W celu wyeliminowania wpływu wartości początkowych wag (które generowane są losowo), a co za tym idzie niebezpieczeństwa utknięcia procesu uczenia w minimum lokalnym [3] funkcji błędu, proces uczenia i weryfikacji przeprowadzany był dwudziestokrotnie dla danej konfiguracji sieci i liczby epok, a następnie notowany był najlepszy wynik (dający najmniejszą liczbę błędnych odpowiedzi). Wyniki symulacji dla różnych struktur sieci oraz różnej liczby epok dla sieci bazującej na prądzie wirnika oraz sieci bazującej na prądach stojana, przedstawione zostały odpowiednio w tabeli 1 i tabeli 2.

Tabela 1. Przykładowe wyniki symulacji działania sieci bazującej na informacji zawartej w prądzie wirnika w zależności od struktury sieci i liczby epok w procesie uczenia.

liczba neur. w warst. ukrytych	liczba epok procesu uczenia	liczba błędnych odpow. sieci	liczba neur. w warst. ukrytych	liczba epok procesu uczenia	liczba błędnych odpow. sieci
10	100	2	30	200	1
10	200	3	30	300	2
15	100	2	30	400	2
15	200	2	40	200	3
15	300	3	10+10	200	3
20	200	2	10+10	300	3
20	300	3	10+15	200	2
20	400	3	10+15	300	2
25	200	2	15+10	200	3
25	300	2	15+10	300	2
25	400	2	15+15	300	3

Analiza wyników zawartych w tabeli 1 prowadzi do wniosku, iż najlepszą strukturą dla sieci bazującej na spektrum prądu wirnika jest struktura z 30 neuronami w warstwie ukrytej (7 – 30 – 3). Optymalna liczba epok procesu uczenia dla tej konfiguracji wynosi 200. Jak można zauważyć, większa liczba epok nie prowadzi do poprawy funkcjonowania sieci, co związane jest ze słabnącą zdolnością sieci do uogólniania zdobytej w procesie uczenia wiedzy wraz ze wzrostem liczby epok (zjawisko przetrenowania).

Tabela 2. Przykładowe wyniki symulacji działania sieci bazującej na informacji zawartej w prądach stojana w zależności od struktury sieci i liczby epok w procesie uczenia

liczba neur. w warst. ukrytych	liczba epok procesu uczenia	liczba błędnych odpow. sieci	liczba neur. w warst. ukrytych	liczba epok procesu uczenia	liczba błędnych odpow. sieci
15	200	3	10+10	200	5
15	300	5	10+10	300	3
15	400	4	10+10	400	5
20	200	4	10+15	300	3
20	300	3	10+15	400	4
20	400	4	15+10	300	4
25	200	2	15+10	400	4
25	300	2	15+20	300	3
25	400	4	15+20	400	4
30	300	5	20+15	300	3
30	400	5	20+15	400	4

Na podstawie wyników zaprezentowanych w tabeli 2 można stwierdzić, iż pomimo wcześniejszych obaw, co do wyników rozpoznawania prowadzonego na podstawie analizy prądów stojana, sieć poradziła sobie z tym zadaniem w stopniu zadowalającym. Optymalna konfiguracja w tym przypadku to: 9 – 25 – 3, a liczba epok 200-300.

7. Wnioski

Przeprowadzone badania dowodzą, że automatyczne rozpoznawanie uszkodzeń silnika synchronicznego ze zwartym uzwojeniem wirnika dla rozpatrywanych stanów awaryjnych przy wykorzystaniu analizy spektralnej oraz sieci neuronowych w roli klasyfikatora, daje dobre rezultaty. Odpowiedni dobór architektury sieci i sposobu jej uczenia dość znacząco minimalizuje liczbę generowanych przez sieć błędnych odpowiedzi.

8. Literatura

- [1]. Korbicz J., Kościelny J.M., Kowalczyk Z., Cholewa W.: *Diagnostyka procesów. Modele. Metody sztucznej inteligencji. Zastosowania*. WNT, Warszawa, 2002.
- [2]. Osowski S., *Sieci neuronowe do przetwarzania informacji*, OWPW, Warszawa, 2006.
- [3]. Rutkowski L.: *Metody i techniki sztucznej inteligencji*, WN PWN, Warszawa, 2006.

O autorze

Jarosław Kozik zatrudniony jest na stanowisku asystenta w Katedrze Maszyn Elektrycznych Akademii Górniczo-Hutniczej w Krakowie, al. Mickiewicza 30. E-mail: kozik@agh.edu.pl.