

Tomasz CISZEWSKI, Leon SWĘDROWSKI

POLITECHNIKA GDAŃSKA, WYDZIAŁ ELEKTROTECHNIKI I AUTOMATYKI, KATEDRA METROLOGII I SYSTEMÓW INFORMACYJNYCH
ul. G. Narutowicza 11/12, 80-233 Gdańsk

Diagnostyka łożysk silnika indukcyjnego na podstawie prądu zasilającego przy użyciu sztucznych sieci neuronowych

Mgr inż. Tomasz CISZEWSKI

Pracownik Politechniki Gdańskiej, zatrudniony na stanowisku wykładowcy w katedrze Metrologii i Systemów Informacyjnych Wydziału Elektrotechniki i Automatyki. W 2010 roku ukończył studia magisterskie na kierunku Elektrotechnika. Od ponad roku zajmuje się badaniami nad prądową diagnostyką łożysk silnika indukcyjnego.



e-mail: t.ciszeński@ely.pg.gda.pl

Dr hab. inż. Leon SWĘDROWSKI

Od ukończenia studiów pracuje w Katedrze Metrologii i Systemów Informacyjnych Wydziału Elektrotechniki i Automatyki Politechniki Gdańskiej, aktualnie jako profesor nadzwyczajny PG. Jego zainteresowania zawodowe koncentrują się wokół pomiarów wielkości nieelektrycznych metodami elektrycznymi, diagnostyki technicznej oraz pomiarów o wysokiej dokładności.



e-mail: l.swedrowski@ely.pg.gda.pl

Streszczenie

W artykule zawarto wyniki badań dotyczące diagnostyki łożysk silnika indukcyjnego na podstawie pomiarów prądu zasilającego z wykorzystaniem sztucznych sieci neuronowych. Zaprezentowano wyniki uczenia sieci oraz rezultaty testów przeprowadzonych na danych spoza zbioru uczącego. Badania wykonane zostały na obiektach z celowo wprowadzonymi uszkodzeniami łożysk. Przedstawiona nowa koncepcja zakłada użycie zestawu sieci neuronowych wybieranych na podstawie prędkości obrotowej silnika podczas pomiaru. Metoda ta ma szanse na wdrożenie w przemyśle.

Słowa kluczowe: diagnostyka, silnik indukcyjny, sieci neuronowe, uszkodzenia łożysk.

Diagnostics of induction motor bearings with use of supply current signal and artificial neural networks

Abstract

The paper contains research results on the diagnostics of induction motor bearings by measuring the supply current with usage of artificial neural networks. Bearing failure amount is greater than 40% of all engine failures, so their damage-free operation is so important [1]. Tests were performed on objects with intentionally made bearings defects. Section 2 introduces the concept of artificial neural networks. It presents the general structure of a multilayer neural network (Fig.1) and the model of a single neuron (Fig. 2) which explains how to create an output signal (1,2). A backpropagation algorithm was chosen to be the learning method for the network being created. It uses equation (4) for calculating the errors in the k-th layer. As the model data for the network learning, DREAM vibration diagnostics system results were used. Section 3 describes how the network input data was created. The essence of the algorithm is to choose the right set of weights for each rotor speed. This is an innovative solving of this diagnostic problem. The results of this study are listed in Table 1. Equations (6) - (14) describe how each error was counted. The method presented in this paper, after developing, can be very useful for industry.

Keywords: diagnostics, induction motor, neural networks, bearings defects.

1. Wprowadzenie

Silnik indukcyjny jest bez wątpienia najczęściej stosowaną maszyną we współczesnych, elektrycznych układach napędowych. Jego prosta i niemalże niezawodna konstrukcja sprawia, że najbardziej awaryjnym elementem są łożyska, które jak wykazują analizy statystyczne stanowią ponad 40% wszystkich uszkodzeń [1].

Dobrze znaną i szeroko stosowaną w przemyśle metodą wykrywania uszkodzeń łożysk jest metoda wibracyjna, wykorzystująca tradycyjne akcelerometry piezoelektryczne. Posiada ona jednak bardzo istotną wadę – wymaga bezpośredniego dostępu do obiektu badanego. W związku z tym poszukuje się nowych metod, które nie posiadają takich ograniczeń.


W ścisłym kręgu zainteresowań autorów leży diagnostyka, wykorzystująca prąd zasilający silnika jako medium niosące informacje o uszkodzeniach. Można przyjąć, że każda wada łożyska wzbudza promieniowy ruch pomiędzy wirnikiem a stojanem maszyny [2]. Powoduje to zmiany szczeliny powietrznej maszyny w sposób, który można opisać kombinacją wirujących nieregularności w dwóch kierunkach, zgodnie i przeciwnie do kierunku wirowania wirnika. Zmiany te generują dodatkowe harmoniczne prądu stojana [3]. Składowe te są jednak trudne do identyfikacji, zatem do celów diagnostycznych zastosowano algorytm sztucznej sieci neuronowej.

W dalszej części artykułu zaprezentowane zostaną wyniki uczenia sieci neuronowych. Badania zostały wykonane na obiektach z celowo wprowadzonymi uszkodzeniami łożysk. Pomiar prądu służący do diagnostyki zostały wykonane przy pomocy specjalnego bardzo nisko szumowego układu, szerzej opisanego w [4]. Aby właściwie ocenić stan łożysk oraz wykryć ewentualne uszkodzenia wtórnie równolegle wykonywano pomiary przy użyciu systemu diagnostyki wibracyjnej DREAM. Wyniki, uzyskane systemem DREAM posłużyły do nauki sieci neuronowych jako prawidłowe rezultaty.

2. Algorytm sztucznych sieci neuronowych

Sztuczne sieci neuronowe to procedury, które rozwiązują problemy za pomocą symulacji komputerowych sposobami wzorowanymi na ludzkich umiejętnościach poznawczych. Podstawowym elementem sieci jest neuron, którego działanie jest bardzo proste. Sygnały wejściowe mnoży się przez odpowiadające im wagi. Zsumowane wartości tworzą sygnał odzwierciedlający działanie części liniowej neuronu. Funkcja zwana funkcją aktywacji przetwarza go na sygnał wyjściowy [5].

Na rysunku 1 przedstawiono ogólny schemat wielowarstwowej sieci neuronowej wykorzystanej do prezentowanych badań.



Rys. 1. Uogólniona struktura wielowarstwowej sieci neuronowej
Fig. 1. Generalized structure of a multilayer neural network


W każdej warstwie znajduje się N_k neuronów, gdzie $k=1, \dots, L$. Neurony oznaczono jako N_i^k , $i=1, \dots, N_k$. Sygnały wejściowe zostały oznaczone jako $x_1 \dots x_{N_0}$. Na drodze przejścia pomiędzy neuronami następuje mnożenie sygnału wejściowego przez wagę odpowiadającą danemu przejściu. Sygnał wyjściowy danego neuronu jest połączony z każdym neuronem kolejnej warstwy [5].

Model matematyczny pojedynczego neuronu przedstawia rysunek 2. Neuron N_i^k ma N_k wejść, które tworzą wektor $x^{(k)}(t)$. Waga i -tego neuronu k -tej warstwy, łącząca ten neuron z j -ym sygnałem wejściowym $x_j^{(k)}(t)$ oznaczona jest jako $w_{ij}^{(k)}(t)$. Sygnał wyjściowy neuronu wyrażony jest następująco [5]:

$$y_i^{(k)}(t) = f(s_i^{(k)}(t)), \quad (1)$$

gdzie:

$$s_i^{(k)}(t) = \sum_{j=0}^{N_k-1} w_{ij}^{(k)}(t)x_j^{(k)}(t). \quad (2)$$



Rys. 2. Model matematyczny pojedynczego neuronu
Fig. 2. Mathematical model of a single neuron

Do wszystkich neuronów w stworzonej sieci jako funkcję aktywacji wykorzystano funkcję sigmoidalną unipolarną daną wzorem [5]:

$$f(x) = \frac{1}{1 + e^{-\beta x}}, \quad (3)$$

przy czym wartość parametru β w zastosowanej sieci wynosi 0,1.

W tak zdefiniowanej sieci neuronowej najistotniejszą rolę pełnią wagi, w których zapisana jest cała wiedza. Poprzez odpowiednią modyfikację wag można uczyć sieci neuronowe. W tym przypadku do nuki sieci użyto algorytmu wstecznej propagacji błędów. Polega on na obliczeniu błędów w k -tej warstwie zgodnie ze wzorem [5]:

$$\delta_i^{(k)}(t) = \sum_{m=1}^{N_{k+1}} \delta_m^{(k+1)}(t)w_{mi}^{(k+1)}(t), \quad (4)$$

dla $k=L-1, \dots, 1$. Jako pierwsze obliczone zostają błędy ostatniej warstwy zdefiniowane jako różnica pomiędzy wartością wzorcową a wartością otrzymaną na wyjściu. Następnie sygnał błędu przemieszcza się wstecz aż do początkowej warstwy. Kolejnym krokiem jest modyfikacja wag przy pomocy wzoru [5]:


$$w_{ij}^{(k)}(t+1) = w_{ij}^{(k)}(t) + \eta \delta_i^{(k)}(t) f'(s_i^{(k)}(t)) x_j^{(k)}(t), \quad (5)$$

gdzie: $w_{ij}^{(k)}$ – odpowiednie wagi, η – współczynnik uczenia, $\delta_i^{(k)}$ – błąd, f' – pochodna funkcji aktywacji, $s_i^{(k)}$ – suma iloczynów wag i wejść do danego neuronu, $x_j^{(k)}$ – sygnał wejściowy, k – numer warstwy, t – krok.

3. Zastosowany algorytm

Do diagnostyki łożysk wykorzystano pomiary prądu silnika wykonane równolegle w 3 fazach przy zasilaniu sieciowym. Stworzony algorytm poddaje wyniki pomiarów szeregowi prostych modyfikacji po których wprowadzane są one na wejścia sieci neuronowej. Pierwszym krokiem jest przekształcenie sygnału

trójfazowego na wektor prądu przy użyciu transformaty Parka. Następnie z modułu wektora Parka obliczane jest widmo przy zastosowaniu okna wygładzającego Blackmana. Wykorzystany układ pomiarowy podczas jednego cyklu pomiarowego dokonuje ośmiu kolejno następujących pomiarów, każdy z nich trwa 8 sekund. Poszczególne pomiary w formie próbek zapisane zostały w ośmiu osobnych plikach. Tak skonstruowany układ pozwala dokonać ośmiu uśrednień widma. Po dokonaniu uśrednień widmo zostaje poddane logarytmowaniu względem największej składowej, co pozwala zmniejszyć stosunek wartości największych składowych do najmniejszych. Kolejnym krokiem jest obcięcie widma do częstotliwości 1kHz, ponieważ zgodnie z założeniami tej metody wszystkie składowe niosące informacje diagnostyczne o stanie łożysk znajdują się w tym przedziale. Tak uformowane widmo jest przeskalowywane liniowo aby wartość największej składowej wynosiła 1 a najmniejszej 0. Pozwala to na uniezależnienie poziomu sygnałów wejściowych sieci od mocy sygnałów pomiarowych. Przykładowe wyznaczone w taki sposób widmo przedstawione jest na rysunku 3.



Rys. 3. Przykładowy sygnał wejściowy sieci
Fig. 3. Exemplary network input signal


Gotowe widmo podawane jest na wejścia sieci. Liczba wejść wynosi 8000 a ich ilość podyktowana jest badanym zakresem częstotliwości – od 0 do 1kHz oraz rozdzielczością widma uzyskaną z pomiarów – 1/8Hz. Zastosowana sieć zawiera 100 neuronów w warstwie wejściowej, 1500 w warstwie ukrytej i 6 w warstwie wyjściowej. Każde wyjście symbolizuje inny rodzaj uszkodzenia łożyska. Możemy wyróżnić następujące uszkodzenia: zużycie bieżni zewnętrznej lub wewnętrznej, wgłębienia bieżni zewnętrznej lub wewnętrznej, zużycie elementów tocznych, wgłębienia oraz złuszczenia na elementach tocznych. Wyjścia mogą przybierać wartości z przedziału (0, 1), a ich poziom odzwierciedla stopień uszkodzenia danego elementu. Na podstawie tego sygnału obliczany zostaje błąd, potem z kolei następuje uczenie sieci według algorytmu opisanego w poprzednim rozdziale. Jako dane wzorcowe do uczenia sieci wykorzystano wyniki systemu diagnostyki wibracyjnej DREAM.

Z wcześniejszych badań [1] oraz [6] wynika, że częstotliwości składowych, które świadczą o uszkodzeniach elementów łożyska zależą od prędkości obrotowej. Prędkość wirnika można łatwo wyznaczyć, ponieważ ujawnia się ona w paśmie częstotliwości żłobkowych. W stworzonym algorytmie jest ona obliczana z dokładnością 0,1 obr/min. Na podstawie wyznaczonej prędkości obrotowej wybierana jest sieć do której trafiają przetworzone dane. W gruncie rzeczy sprowadza się to do selekcji zestawu wag odpowiedniego dla danej prędkości obrotowej.

4. Wyniki przeprowadzonych badań

Do uczenia sieci zostało wykorzystane 400 zestawów uczących zawierających wyniki pomiarów prądu oraz dane wzorcowe. O tym który zestaw zostanie wykorzystany w danym cyklu uczenia decyduje zmienna losowa. Rysunek 4 przedstawia wykres błędu na jednym z wyjść sieci w kolejnych cyklach uczących. Jak

widać moduł błędu wyraźnie maleje wraz ze wzrostem liczby cykli nauki sieci.



Rys. 4. Błąd na wyjściu sieci w kolejnych cyklach uczących
Fig. 4. The network output error in the successive cycles of learning

Po zakończeniu nauki zostały wykonane testy sieci na 35 zestawach nie należących do zbioru uczącego. Zestawy testowe zostały tak dobrane aby prędkości obrotowe dla tych pomiarów pokrywały się prędkościami z zestawu uczącego. W tabeli 1 przedstawiono zestawienie wyników wspomnianych testów.

Tab. 1. Zestawienie wyników testów
Tab. 1. Statistics of test results

i	Rodzaj uszkodzenia	δ_{1i}	δ_{2i}	δ_{3i}	δ_{4i}	$\delta_{20\%i}$	$\delta_{10\%i}$
1	Zużycie bieżni zewnętrznej	7,2%	7,2%	64,9%	1,3%	91,4%	82,9%
2	Wgłębienia na bieżni zewnętrznej	12,6%	3,9%	36,1%	2,0%	74,3%	60%
3	Zużycie bieżni wewnętrznej	8,0%	1,5%	21,3%	0,5%	94,3%	71,4%
4	Wgłębienia na bieżni wewnętrznej	30,5%	6,9%	79,3%	0,2%	45,7%	22,9%
5	Zużycie elementów tocznych	4,3%	1,0%	19,1%	0,1%	100%	97,1%
6	Wgłębienia, złuszczenia na elementach tocznych	14,5%	7,5%	35,4%	0,1%	62,9%	60%

Dane prezentowane w tabeli 1 zostały dobrane tak aby możliwie szeroko przedstawić wyniki testów. Błąd e_{in} został zdefiniowany następująco:

$$e_{in} = y_{in} - y'_{in} \quad (6)$$

gdzie: y'_{in} – wartość wzorcowa i -tego wyjścia dla n -tego zestawu testowego otrzymana na podstawie systemu diagnostyki wibracyjnej, y_{in} – wartość i -tego wyjścia dla n -tego zestawu testowego.

Średni moduł błędu (kolumna 3 tabeli 1) obliczono na podstawie wzoru:

$$\delta_{1i} = \frac{1}{Z} \sum_{n=1}^Z |e_{in}| \cdot 100\% \quad (7)$$

gdzie: Z – ilość zestawów danych testowych.

Moduł średniego błędu (kolumna 4 tabeli 1) wyznaczono następująco:

$$\delta_{2i} = \left| \frac{1}{Z} \sum_{n=1}^Z e_{in} \right| \cdot 100\%, \quad (8)$$

Poniższe zależności posłużyły do wyznaczenia wartości maksymalnej i minimalnej błędu e_{in} (kolumna 5 i 6 tabeli 1).

$$\delta_{3i} = \max_{n \in [1, Z]} |e_{in}| \cdot 100\%. \quad (9)$$

$$\delta_{4i} = \min_{n \in [1, Z]} |e_{in}| \cdot 100\%. \quad (10)$$

Dodatkowo wyznaczono procentowy udział zestawów dla których moduł błędu jest mniejszy odpowiednio niż 0,2 oraz 0,1.

$$\delta_{20\%i} = \frac{A}{Z} \cdot 100\% \quad (11)$$

$$\delta_{10\%i} = \frac{B}{Z} \cdot 100\% \quad (14)$$

gdzie: A – ilość zestawów danych testowych dla których $|e_{in}| < 0,2$, B – ilość zestawów danych testowych dla których $|e_{in}| < 0,1$.

5. Analiza danych pomiarowych

Uzyskane wyniki pokazują najlepsze działanie algorytmu dla diagnostyki zużycia elementów tocznych. Przy tym elemencie dla ponad 97% spośród zestawów testowych uzyskano błąd względny mniejszy niż 0,1. Nieco gorsze wyniki uzyskano dla zużycia bieżni zewnętrznej oraz wewnętrznej. Największe błędy otrzymano dla wyjść, które powinny wykrywać ubytki w poszczególnych elementach łożyska. Takie rezultaty mogą być skutkiem danych użytych do uczenia sieci jak również danych testowych. Jak wynika z przedstawionych statystyk algorytm wykazuje zdecydowanie większą skuteczność diagnostyki zużycia poszczególnych elementów łożyska niż ich ubytków.

6. Plany rozwoju systemu diagnostycznego

Wyniki wstępnych badań algorytmu potwierdziły jego oczekiwane możliwości w zakresie diagnostyki łożysk tocznych w silniku indukcyjnym. Przedstawiona metoda wymaga jednak bardzo dużej liczby danych do nauki sieci.

Oczekuje się, że wyniki diagnostyki silników, realizowanej przy wykorzystaniu opracowanego algorytmu, będą miały znacznie wyższą wiarygodność, niż rozwiązania dotychczasowe.

Dalszym kierunkiem badań przewidywanym przez autorów jest uczenie sieci w oparciu o dane symulacyjne a następnie testowanie na danych pochodzących z rzeczywistych pomiarów.

7. Literatura

- [1] Ciszewski T., Swędrowski L., Wołoszyk M., Ziółko M.: Porównanie wyników badań diagnostycznych łożysk silnika indukcyjnego poprzez pomiary wibracji i prądu stojana, Electrical engineering, Issue 72, s. 217, Poznań University of Technology, Poznań 2012.
- [2] Kowalski Cz. T.: Monitorowanie i diagnostyka uszkodzeń silników indukcyjnych z wykorzystaniem sieci neuronowych, monografia nr 18, Oficyna Wydawnicza Politechniki Wrocławskiej, Wrocław 2005.
- [3] Rusek J., Swędrowski L.: Induction machine model for current diagnostics of bearings. Tagungsband 48. Internationales Wissenschaftliches Kolloquium. Ilmenau, 2003.
- [4] Swędrowski L., Wołoszyk M., Ziółko M.: Nowe rozwiązanie przetwornika prądu w diagnostyce prądowej silników indukcyjnych, Pomiary Automatyka Kontrola nr 12, s. 1570 – 1572 (2011).
- [5] Rutkowski L.: Metody i techniki sztucznej inteligencji. Wydawnictwo naukowe PWN, Warszawa 2006.
- [6] Swędrowski L.: Nowa metoda diagnostyki silnika indukcyjnego oparta na pomiarze i analizie widmowej prądu zasilającego. Wydawnictwo Politechniki Gdańskiej, Gdańsk 2005.