

Piotr CZECH, Bogusław ŁAZARZ

KONCEPCJA WYKORZYSTANIA SZTUCZNYCH SIECI NEURONOWYCH W DIAGNOSTYCE PRZEKŁADNI ZĘBATYCH

Streszczenie. W opracowaniu przedstawiono koncepcję zastosowania sztucznych sieci neuronowych w procesie diagnozowania stanu przekładni zębatych. Na podstawie przeprowadzonych badań opracowano schemat postępowania dla różnych typów sztucznych sieci neuronowych.

CONCEPTION OF USE ARTIFICIAL NEURAL NETWORK FOR GEARBOX DIAGNOSIS

Summary. The work presents conception of use artificial neural network in the task of gearbox diagnosis. system which was build with artificial intelligence methods. As an effect of researches was worked out scheme of methodology proceeding for different kind of artificial neural networks.

1. WPROWADZENIE

Literatura wskazuje szczególną przydatność sygnałów drganiowych w procesie diagnozowania stanu elementów układu przeniesienia napędu. W diagnostyce drganiowej wykorzystuje się sygnały przyspieszeń drgań zmierzone piezoelektrycznymi przetwornikami oraz prędkości drgań rejestrowane bezkontaktowo za pomocą wibrometru laserowego [6]. Tak zarejestrowane sygnały należy odpowiednio przefiltrować i poddać jednej ze stosowanych metod analizy sygnału, a następnie wykorzystać wrażliwą na występujące uszkodzenie miarę. Takie podejście do problemu diagnozy stanu technicznego było dotychczas najczęściej stosowane.

Wykrycie uszkodzeń już we wczesnych fazach rozwoju pozwala na uniknięcie awarii, której skutki mogą przynieść duże straty ekonomiczne, a nawet zagrożenie dla zdrowia i życia ludzkiego. Niestety, opisywane w literaturze metody i miary diagnostyczne w większości przypadków nie wykazują wystarczającej wrażliwości na wczesne stadia uszkodzeń.

Obecnie coraz powszechniej można spotkać próby wykorzystania metod sztucznej inteligencji w systemach automatycznej diagnostyki [3,5]. Liczba istniejących wariantów tych metod jest jednak duża, co znacznie utrudnia właściwy wybór [9,10,11]. W przypadku wyboru sztucznej sieci neuronowej należy określić jej typ, architekturę, parametry i algorytm


uczenia. Niestety literatura nie podaje gotowych rozwiązań dotyczących tego wyboru, a wręcz wskazuje na konieczność indywidualnego podejścia do każdego z problemów [3,5,9,10,11].

W niniejszym opracowaniu podjęto próbę stworzenia wytycznych dotyczących przeprowadzania badań z wykorzystaniem sieci neuronowych do celów diagnozowania stanu technicznego elementów układów napędowych.

2. ŹRÓDŁO DANYCH UCZĄCYCH DLA SZTUCZNYCH SIECI NEURONOWYCH

Stosując systemy ekspertowe, wykorzystujące metody sztucznej inteligencji, należy pozyskać odpowiednio liczną bazę danych dotyczących diagnozowanych uszkodzeń o różnym typie i stopniu zaawansowania. W literaturze zauważono rozwijaną w ostatnich latach tendencję do wykorzystywania modeli rzeczywistych obiektów w procesach opracowywania narzędzi diagnostycznych [1,2,4,7]. Trudności związane z uzyskaniem danych z rzeczywistego obiektu, dotyczących konkretnego zjawiska, można rozwiązać stosując odpowiednio dostrojone modele. Sposób ten jest szybszy, ekonomiczniejszy, a w wielu wypadkach stanowi jedyną możliwość.

W pracy [3] postanowiono do celów diagnostycznych wykorzystać model dynamiczny przekładni zębatej pracującej w układzie napędowym (rys. 1). Model ten został opracowany na Wydziale Transportu Politechniki Śląskiej [7]. Zrealizowany w środowisku Matlab–Simulink model dynamiczny przekładni zębatej w układzie napędowym uwzględnia charakterystykę napędowego silnika elektrycznego, jednostopniowej przekładni zębatej, sprzęgieł oraz maszyny roboczej. Opis zjawisk zachodzących w zazębieniu jest zgodny z modelem Müllera [8].



Rys. 1. Model dynamiczny przekładni zębatej w układzie napędowym


Fig. 1. Dynamic model of gearbox in power transmission system

Model przekładni zębatej umożliwia również zamodelowanie różnego rodzaju uszkodzeń zarówno kół zębatych, jak i łożysk tocznych. Własność ta daje możliwość pozyskania niezbędnej w procesie uczenia sieci neuronowych liczby danych.

3. WSTĘPNE PRZETWARZANIE DANYCH


W pracy [3] sygnały prędkości drgań poprzecznych wału koła, uzyskane na drodze symulacji komputerowych, posłużyły za źródło deskryptorów uszkodzeń kół przekładni zębatej. Ponieważ bezpośrednio zarejestrowany sygnał drganiowy nie nadaje się bezpośrednio do użycia jako dane wejściowe dla sieci neuronowych, należy go odpowiednio przetworzyć. Autor [3] do wstępnej fazy przetwarzania sygnałów proponuje wykorzystanie następujących metod filtracji sygnałów:

- filtr 1 (filtr dolnoprzepustowy w zakresie do 12 [kHz]):




Rys. 2. Filtr 1
Fig. 2. Filter 1

- filtr 2 (filtr dolnoprzepustowy w zakresie do 6 [kHz]):



Rys. 3. Filtr 2
Fig. 3. Filter 2


- filtr 3 (filtr pasmowo przepustowy do otrzymywania sygnału resztkowego w zakresie do 6 [kHz]):



Rys. 4. Filtr 3

Fig. 4. Filter 3


- filtr 4 (filtr pasmowo-przepustowy do otrzymywania sygnału różnicowego w zakresie do 6 [kHz]):



Rys. 5. Filtr 4

Fig. 5. Filter 4

- filtr 5 (filtr pasmowo-przepustowy do otrzymywania sygnału w zakresie $\langle \frac{1}{2} f_z, \frac{3}{2} f_z \rangle$):



Rys. 6. Filtr 5


Fig. 6. Filter 5

Z otrzymanych po procesie filtracji sygnałów drganiowych należy utworzyć wzorce danych rodzajów uszkodzeń. Do tego celu służą następujące metody analizy sygnału:

- szybka transformata Fouriera,
- widmo iloczynowe,
- widmo poliharmoniczne,
- cepstrum,
- ciągła transformata falkowa,
- dyskretna transformata falkowa,
- empiryczna dekompozycja sygnału,
- transformata Hilberta-Huanga,
- krótkoczasowa transformata Fouriera,
- transformata Wignera-Ville'a,
- bispektrum.

Wszystkie wymienione analizy zostały przebadane w pracy [3] w celu tworzenia wzorców uszkodzeń kół przekładni zębatych.

Tak przeprowadzony proces umożliwia budowę danych wejściowych dla sztucznych sieci neuronowych (rys. 7).



Rys. 7. Sposób budowy danych wejściowych dla sztucznych sieci neuronowych
Fig. 7. Scheme of built inputs data for artificial neural networks

4. BUDOWA SZTUCZNYCH SIECI NEURONOWYCH

Mając gotowe zestawy wzorców, należy wybrać i odpowiednio zbudować sztuczną sieć neuronową.

W [3] badania nad wykorzystaniem sztucznych sieci neuronowych do rozpoznawania rodzaju i stopnia zaawansowania uszkodzeń kół zębatych oparto na sieciach typu SVM (z ang. Support Vector Machine), RBF (z ang. Radial Basis Function), PNN (z ang. Probabilistic Neural Networks) i MLP (z ang. Multi Layer Perceptrons) [9,10,11]. Zestawy wzorców otrzymane z kolejnych analiz sygnału podawano na wejścia sieci neuronowej typu SVM wybranej ze względu na stosunkowo krótki czas potrzebny na jej naukę. Dla danych wariantów zestawów wzorców dokonano wyboru tych, dla których błąd walidacji był najmniejszy. Przy wykorzystaniu sieci neuronowej tego typu należy dobrać trzy współczynniki odpowiedzialne za jej pracę; są to:

- szerokość marginesu błędu sieci ε ,
- parametr C ,
- wartość współczynnika γ .

Szerokość marginesu błędu ε określa dopuszczalną odchyłkę, dla której wyniki o mniejszej odchyłce nie są traktowane jako błąd. Parametr C steruje złożonością sieci SVM. Określa on wagę, z jaką traktuje się błędy sieci w stosunku do ustalonego marginesu separacji.

Parametr gamma określony jest dla radialnej funkcji jądra z zależności: $\gamma = \frac{1}{\sigma^2}$.

W wyniku tego etapu badań w [3] wybrano dla kolejnych analiz sygnałów najlepsze miary lub miary i falki bazowe dla analiz falkowych. Na tak wybranych zestawach wzorców sprawdzono poprawność procesu klasyfikacji sieci neuronowych typu RBF, PNN i MLP.

Dla sieci radialnych i probabilistycznych konieczny jest dobór odpowiedniej wartości współczynnika odpowiedzialnego za dopasowanie wyników uzyskiwanych z klasyfikatorów do poprawnych wyników.

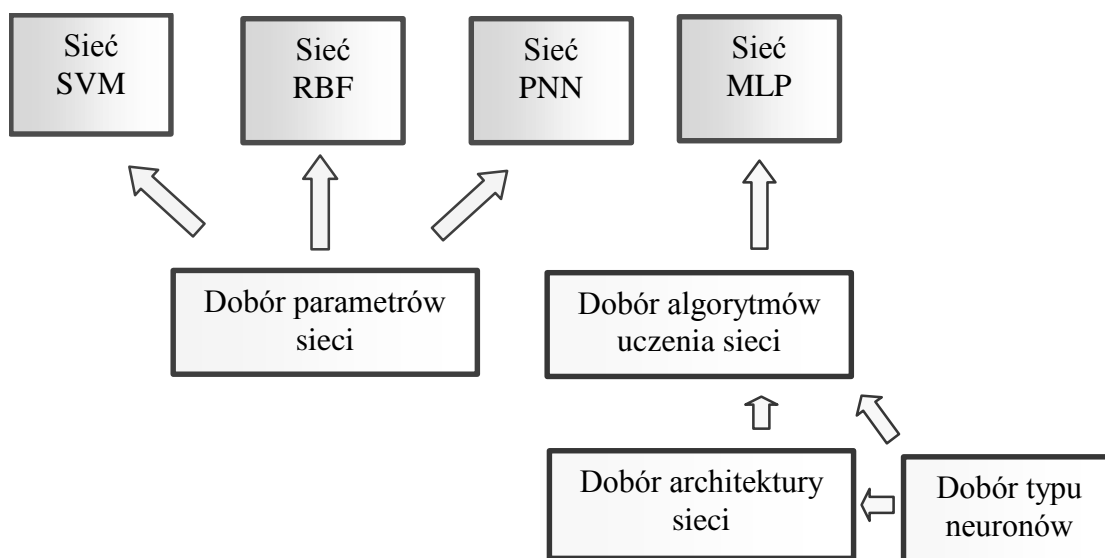
Badania z wykorzystaniem sieci typu perceptron wielowarstwowy można podzielić na dwie części. W pierwszej należy dobrać liczbę warstw ukrytych oraz liczbę neuronów, z których są zbudowane. Druga część polega na doborze algorytmu uczenia sieci. Jako kryterium wyboru należy przyjąć uzyskiwaną najniższą wartość błędu walidacji. Dodatkowo, we wszystkich eksperymentach z wykorzystaniem tego rodzaju sieci należy jeszcze dobrać typ neuronów w warstwach ukrytych. W pracy [3] autor dokonuje wyboru pomiędzy neuronami typu sigmoidalnego a tangensoidalnego.

Schematycznie sposób postępowania z różnymi rodzajami sztucznych sieci neuronowych pokazano na rys. 8.

Wszystkie doświadczenia, w których wykorzystuje się sztuczne sieci neuronowe, mogą być powtórzone dla zestawów wzorców zoptymalizowanych pod względem wielkości za pomocą analizy PCA/SVD.


W badaniach można również sprawdzić przydatność algorytmów genetycznych, za pomocą których wybiera się najlepsze warianty wejść sieci neuronowych, dla których wartość błędu walidacji jest najmniejsza.

Takie postępowanie zostało zaproponowane w pracy [3].



Rys. 8. Sposób budowy sztucznych sieci neuronowych
 Fig. 8. Scheme of built artificial neural networks

Autor [3] założył, że klasyfikator neuronowy będzie podlegał procesowi uczenia i walidacji na danych pochodzących z modelu dynamicznego przekładni zębatej oraz procesowi testowania na danych otrzymanych z rzeczywistej przekładni zębatej (rys. 9).



Rys. 9. Koncepcja metodologii pracy ze sztucznymi sieciami neuronowymi
 Fig. 9. Conception of methodology work with artificial neural networks

Przyjęcie koncepcji wykorzystania w procesie budowy wzorców modeli obiektów technicznych oraz rzeczywistych obiektów do procesu testowania daje możliwość uzyskania poprawnych diagnoz stanu technicznego stawianych dzięki sztucznym sieciom neuronowym. W wielu przypadkach podejście takie jest jedynym możliwym sposobem budowy systemów diagnozujących stan techniczny obiektów.

Bibliografia

1. Bartelmus W.: Diagnostyka maszyn górniczych. Górnictwo odkrywkowe. „Śląsk” Spółka z o.o., Katowice 1998.
2. Cholewa W.: Modele odwrotne i modelowanie diagnostyczne. „Diagnostyka”, Vol. 30, 2004, s. 111÷114.
3. Czech P.: Wykrywanie uszkodzeń przekładni zębatych za pomocą metod sztucznej inteligencji. Rozprawa doktorska. Katowice 2006.
4. Dąbrowski Z., Radkowski S., Wilk A.: Dynamika przekładni zębatych. Badania i symulacja w projektowaniu eksploatacyjnie zorientowanym. ITE 2000.
5. Korbicz J., Kościelny J., Kowalczyk Z., Cholewa W.: Diagnostyka procesów. Modele. Metody sztucznej inteligencji. Zastosowania. Wydawnictwa Naukowo-Techniczne, Warszawa 2002.
6. Łazarz B., Wojnar G.: Bezkontaktowe pomiary laserowe drgań w diagnostyce wibroakustycznej. XI Seminarium Naukowe „Nowe Technologie i Materiały w Metalurgii i Inżynierii Materiałowej”. Katowice 2003.
7. Łazarz B.: Zidentyfikowany model dynamiczny przekładni zębatej jako podstawa projektowania. Studia i Rozprawy. Instytut Technologii Eksploatacji, Katowice–Radom 2001.
8. Müller L.: Przekładnie zębate. Dynamika. Wydawnictwa Naukowo-Techniczne, Warszawa 1986.
9. Nałęcz M., Duch W., Korbicz J., Rutkowski L., Tadeusiewicz R.: Sieci neuronowe. Biocybernetyka i Inżynieria Biomedyczna, tom 6. Akademicka Oficyna Wydawnicza EXIT, Warszawa 2000.
10. Osowski S.: Sieci neuronowe do przetwarzania informacji. Oficyna Wydawnicza Politechniki Warszawskiej, Warszawa 2000.
11. Tadeusiewicz R.: Sieci neuronowe. Akademicka Oficyna Wydawnicza, Warszawa 1993.

Recenzent: Prof. dr hab. inż. Zbigniew Dąbrowski