Piotr CZECH

ZASTOSOWANIE KLASYFIKATORA NEURONOWEGO TYPU MLP PRZY WYKORZYSTANIU DESKRYPTORÓW USZKODZEŃ ZĘBÓW KÓŁ POCHODZĄCYCH Z ANALIZY DWT

Streszczenie. W opracowaniu przedstawiono wyniki eksperymentu mającego na celu wykorzystanie sztucznych sieci neuronowych typu MLP do diagnozowania stopnia pęknięcia w stopie zęba koła. Do nauki sieci typu perceptron wielowarstwowy wykorzystywano deskryptory wyznaczone na podstawie rozkładów uzyskanych z dyskretnej transformaty falkowej. Badania oparto na zidentyfikowanym modelu przekładni zębatej pracującej w układzie napędowym [5].

USE MLP NEUŘAL NETWORK CLASSIFIER OF DIAGNOSIS FAULTS OF GEAR-TOOTH WHICH USED INPUTS FROM DWT ANALYSIS

Summary. The work presents results of an experiment that employs the artificial neuronal network in the task of identification of the degree of tooth root cracking. In the experiment was used discrete wavelets analysis (DWT) and MLP neural network. This experiment was based on a simulation experiment [5].

1. ZAŁOŻENIA WSTĘPNE

Przedstawione w artykule doświadczenia miały na celu zbudowanie poprawnie działającego klasyfikatora stopnia pęknięcia w stopie zęba koła przekładni. W założeniach wstępnych ustalono, że sygnałem niosącym w sobie informacje o stanie przekłądni zębatej będzie sygnał prędkości drgań poprzecznych wału koła, uzyskany na drodze symulacji, przy wykorzystaniu zidentyfikowanego modelu przekładni zębatej pracującej w układzie napędowym [5]. Założono, że badana przekładnia będzie pracować przy prędkości obrotowej wału koła n = 1800 [obr/min] oraz jednostkowym obciążeniu Q = 2,58 [MPa].

Sygnał drganiowy poddano działaniu filtrów dolnoprzepustowych (6 i 12 [kHz] – filtr nr 1 i 2), filtrów umożliwiających uzyskanie sygnałów resztkowych i różnicowych (filtr nr 3 i 4) oraz filtru w zakresie częstotliwości $\langle \frac{1}{2} f_z, \frac{3}{2} f_z \rangle$ (filtr nr 5) [3]. W kolejnym kroku otrzymane po filtracji sygnały poddano działaniu dyskretnej transformaty falkowej (DWT).

Na podstawie uzyskanych przebiegów czasowych opracowano deskryptory stopnia uszkodzenia zębów kół przekłądni.

Opisane w artykule eksperymenty stanowią kontynuację badań przedstawionych w pracy [6].

2. WYKORZYSTANIE DWT W PROCESIE TWORZENIA WZORCÓW USZKODZEŃ ZĘBÓW KÓŁ PRZEKŁADNI

Analiza falkowa polega na dekompozycji sygnału i przedstawieniu go w postaci liniowej kombinacji funkcji bazowych, zwanych falkami [2]. Cechami odróżniającymi tę metodę analizy sygnału od innych są wielostopniowa dekompozycja sygnału, zmienna rozdzielczość w dziedzinie czasu i częstotliwości oraz możliwość stosowania funkcji bazowych innych niż funkcje harmoniczne [4]. W literaturze analiza falkowa przedstawiana jest w dwóch odmianach: dyskretnej DWT (z ang. Discrete Wavelet Transform) i ciągłej CWT (z ang. Continuous Wavelet Transform).

Dyskretną transformatę falkową sygnału x(t) wyznacza się jako iloczyny skalarne x(t) i ciągu funkcji bazowych $\psi(t)$ [2]:

$$DWT = \int_{-\infty}^{+\infty} \psi(t) \cdot x(t) dt$$
(1)

W wyniku wielopoziomowej dekompozycji sygnału otrzymuje się aproksymacje sygnału na danym poziomie a_k oraz sumę detali na kolejnych poziomach d_l [2]:

$$x(t) = a_k + \sum_{l=1}^k d_l$$
 (2)

gdzie:

 d_1 – detal sygnału, składnik wielkoczęstotliwościowy sygnału,

 a_k – aproksymacja sygnału, reprezentacja małoczęstotliwościowa sygnału.

Wraz ze zwiększeniem poziomu dekompozycji sygnału udział detali maleje, co powoduje, że wraz ze zmniejszeniem rozdzielczości maleje zawartość szczegółów w aproksymacji sygnału [2].

Dyskretna transformata falkowa daje możliwość dekompozycji i selektywnej rekonstrukcji (syntezy) sygnału w całym przedziale analizy [1]. Można ją przyrównać do filtracji sygnału ze stałą, względną szerokością pasma [4].

Zgodnie z definicją DWT przebieg czasowy drgań możemy rozłożyć na zadaną liczbę poziomów dekompozycji. W przeprowadzonych doświadczeniach sygnał prędkości drgań poprzecznych wału koła został poddany dekompozycji na pięciu poziomach. Po przeprowadzeniu dekompozycji i rekonstrukcji sygnału, na każdym z poziomów osobno, dokonano opisu charakteru zmian amplitudy przebiegów czasowych za pomocą wektora złożonego z wybranych miar. W skład wektora wchodziły zestawione w tabeli 1 miary [3]. Zestaw tak wyznaczonych miar stanowił wzorzec stopnia uszkodzenia zębów kół przekładni.

Dodatkowo oprócz wyboru odpowiedniego poziomu dekompozycji sygnału dokonano sprawdzenia przydatności wybranych falek bazowych. Do eksperymentów wybrano falki bazowe należące do następującej rodziny falek [7]:

- haar wavelet,
- daubechies wavelets,
- biorthogonal wavelets,
- coiflets,
- symlets,
- reverse biorthogonal wavelets,
- discrete approximation of Meyer wavelet.

W przeprowadzonych eksperymentach diagnozowania stanu przekładni zębatej sprawdzono przydatność 52 falek bazowych.

Nr miary	Nazwa miary	Nr miary	Nazwa miary	
1	Współczynnik zmienności	19	Pozycyjny współczynnik zmienności	
2	Współczynnik szczytu	20	Kwartyl 1	
3	Współczynnik luzu	21	Kwartyl 3	
4	Współczynnik kształtu	22	Wariancja	
5	Współczynnik impulsowości	23	Wartość maksymalna	
6	Współczynnik asymetrii	24	Wartość minimalna	
7	Dyskryminanta X4	25	Wartość międzyszczytowa	
8	Dyskryminanta X6	26	Moment centralny 3	
9	Dyskryminanta X8	27	Moment centralny 4	
10	Dyskryminanta X10	28	Moment centralny 5	
11	Energia sygnału	29	Moment centralny 6	
12	Odchylenie ćwiartkowe	30	Moment centralny 7	
13	Odchylenie przeciętne	31	Moment centralny 8	
14	Wartość skuteczna	32	Moment centralny 9	
15	Średnia arytmetyczna	33	Moment centralny 10	
16	Średnia geometryczna	34	Kumulanta 4	
17	Średnia harmoniczna	35	Dyskryminanta X0	
18	Mediana			

Zestaw miar wykorzystanych jako deskryptor stopnia uszkodzenia

Wynikiem przeprowadzonego, wstępnego przetwarzania sygnałów była budowa 1300 różnych zestawów wzorców otrzymanych z sygnałów prędkości drgań poprzecznych wału koła. Dodatkowo, w celu sprawdzenia poprawności dokonanego wyboru sygnału nośnego informacji w postaci prędkości drgań, przeprowadzono analizy za pomocą danych otrzymanych przy wykorzystaniu wybranych falek bazowych oraz zastosowaniu filtrów nr 1÷5 na sygnale przyspieszeń drgań. Proces budowy wzorców dla tak przetworzonych sygnałów przyspieszeń drgań przeprowadzono dla wybranego 5. poziomu dekompozycji. Wynikiem tego było stworzenie dodatkowych 260 zestawów wzorców.

W pierwszej części eksperymentu z wykorzystaniem wzorców uzyskanych z analizy DWT dokonano wyboru najlepszej falki bazowej dla każdego poziomu dekompozycji i każdego z zastosowanych na sygnale drganiowym filtrów. Do testu przydatności falek bazowych wykorzystano klasyfikator neuronowy typu SVM [3, 6].

Przykładowy wpływ wyboru falki bazowej na wielkość błędu klasyfikacji dla sieci neuronowej typu SVM przedstawiono na rys. 1.

Analiza wyników wykazała słuszność decyzji o przeprowadzeniu badań dla jak największej liczby falek bazowych. Różnice wielkości błędu walidacji uzyskane dla klasyfikatorów uczonych na danych wejściowych otrzymanych przy zastosowaniu różnych falek sięgają ponad 50% dla sygnału prędkości drgań. W przypadku badania sygnału niosącego informacje o uszkodzeniu przekładni w postaci przyspieszeń drgań, różnice te są znacznie mniejsze i osiągają wartość ponad 15% [3].

Tabela 1



Rys. 1. Przykładowy wpływ wyboru falki bazowej na błąd klasyfikatora SVM Fig. 1. Example of choose wavelet on error in SVM classifier

Zestawienia przyjętych do dalszych eksperymentów falek bazowych dokonano w tabeli 2.

Tabela 2

Filtr	Poziom dekomp.	Falka	Filtr	Poziom dekomp.	Falka	Filtr	Poziom dekomp.	Falka
1	1	rbio6.8	1	3	coifl	1	5	db4
2	1	bior3.7	2	3	rbio3.1	2	5	dmey
3	1	coif2	3	3	bior2.2	3	5	bior3.7
4	1	bior2.8	4	3	rbio1.3	4	5	db6
5	1	rbio5.5	5	3	rbio3.7	5	5	sym2
1	2	rbio3.1	1	4	bior1.5			
2	2	bior5.5	2	4	bior3.3			
3	2	rbio3.7	3	4	bior3.7			
4	2	rbio2.8	4	4	bior2.4			
5	2	db2	5	4	rbio2.8			

Zestawienie wybranych falek bazowych

W kolejnej części badań analizowano przydatność sztucznych sieci neuronowych typu MLP w problemie klasyfikacji stopnia uszkodzenia zębów kół przekładni.

3. WYNIKI BADAN KLASYFIKATORÓW MLP

Badania z wykorzystaniem klasyfikatorów neuronowych typu MLP zostały podzielone na dwie części. W pierwszej poszukiwano najlepszej architektury sieci, natomiast w drugiej najlepszej metody uczenia sieci neuronowych. Analizowano strukturę sieci neuronowej z jedną oraz z dwoma warstwami ukrytymi. Dla każdego przypadku sprawdzano wpływ liczby neuronów na poprawność klasyfikacji. Na podstawie badań wstępnych założono dla każdej

z warstw ukrytych możliwość występowania 5, 10, 15, 20, 25 i 30 neuronów. Dobór najlepszej struktury sieci prowadzono wykorzystując jako metodę uczenia algorytm gradientowy (Gradient Descent Backpropagation) [7]. Badania przeprowadzono oddzielnie dla neuronów w warstwie ukrytej typu sigmoidalnego oraz tangensoidalnego.

Przykładowe zależności wpływu struktury sieci MLP na poprawność wyniku klasyfikacji przedstawiono na rys. 2.



- Rys. 2. Przykładowy wpływ architektury sieci MLP na błąd klasyfikacji (LN1 liczba neuronów w pierwszej warstwie ukrytej, LN2 liczba neuronów w drugiej warstwie ukrytej)
- Fig. 2. Example of choose structure of MLP on classifier error (LN1 number of neurons in first hidden layer, LN2 number of neurons in second hidden layer)

Analizując uzyskane charakterystyki można zauważyć przypadki, w których wraz ze wzrostem liczby neuronów w pierwszej warstwie ukrytej błąd najpierw spadał, a następnie rósł. Przyczyną tego zjawiska jest przeuczenie sieci, która traci własności generalizowania posiadanej wiedzy. Sieć taka jest wystarczająco złożona, aby nauczyć się prezentowanych jej w procesie uczenia wzorców na pamięć. W przypadku walidacji takiego klasyfikatora na innym zestawie danych nie potrafi on uogólnić posiadanej wiedzy. Zauważalne są również przypadki, w których zwiększenie liczby warstw ukrytych z odpowiednio dużą liczbą neuronów poprawia skuteczność klasyfikacji. Wynika to z posiadania przez taką sieć większej liczby powiązań, które mogą przechowywać większą liczbę wzorców [8, 9, 10].

Niezależnie od wykorzystywanych w budowie wzorców poziomu dekompozycji, rodzaju zastosowanego filtru oraz typu zastosowanych w warstwach ukrytych neuronów uzyskany poziom błędu klasyfikatorów neuronowych MLP wynosił 40÷60%. Pomimo tego, że klasyfikatory tak zbudowane nie nadają się do oceny stopnia uszkodzenia, postanowiono przeprowadzić drugą część eksperymentu. Dla wybranych, najlepszych architektur sieci sprawdzano przydatność dwunastu algorytmów uczenia [7].

Przykładowy wpływ wyboru metody uczenia klasyfikatora typu MLP zbudowanego z neuronów sigmoidalnych i uczonego za pomocą wzorców uzyskanych dla pięciu kolejnych poziomów dekompozycji sygnału prędkości drgań poddanych działaniu filtru nr 1 przedstawiono na rys. 3.



Rys. 3. Przykładowy wpływ metody uczenia sieci MLP na błąd klasyfikacji, poziom dekompozycji: A-1, B-2, C-3, D-4, E-5

Fig. 3. Example of choose method of learn MLP on classifier error, level of decomposition: A-1, B-2, C-3, D-4, E-5

Uzyskane wyniki wykazały duży wpływ wybranej metody uczenia sieci neuronowej oraz wybranego poziomu dekompozycji sygnału na poprawność procesu klasyfikacji stopnia uszkodzenia zęba koła przekładni.

Najlepsze, uzyskane w procesie doboru metody uczenia, wyniki dla klasyfikatora neuronowego typu MLP, zbudowanego w warstwach ukrytych z neuronów sigmoidalnych lub tangensoidalnych i uczonego z wykorzystaniem danych otrzymanych z sygnału prędkości drgań poddanych działaniu pięciu filtrów oraz DWT na pięciu poziomach dekompozycji, zestawiono na rys. 4.



- Rys. 4. Najlepsze uzyskane wyniki dla klasyfikatorów neuronowych typu MLP, zbudowanych w warstwach ukrytych z neuronów: (a) sigmoidalnych, (b) tangensoidalnych; poziom dekompozycji: A-1, B-2, C-3, D-4, E-5
- Fig. 4. The best results for MLP neural networks which was build in hidden layers with: sigmoid neurons, (b) tangensoid neurons; level of decomposition: A-1, B-2, C-3, D-4, E-5

Najniższy poziom błędu walidacji sieci neuronowej typu MLP zbudowanej w warstwach ukrytych z neuronów sigmoidalnych uzyskano przy wykorzystaniu wzorców otrzymanych z sygnału poddanego działaniu filtru nr 3 i zdekomponowanego na piątym poziomie. Błąd ten wyniósł 7,75% i był około siedmiokrotnie niższy od najgorszego z uzyskanych wyników dla danych wzorców zbudowanych na podstawie dekompozycji sygnału na poziomie pierwszym i przy użyciu filtru nr 4. Podobne wyniki uzyskano dla sieci zbudowanych w warstwach ukrytych z neuronów tangensoidalnych. Najmniejszy błąd klasyfikacji wynoszący 7,75% uzyskano również przy wykorzystaniu w budowie danych uczących filtru nr 3 i podziale na pięć poziomów dekompozycji. Najwyższą wartość błędu równą 54,41% otrzymano dla tego samego wariantu wzorca co w przypadku wykorzystania neuronów typu sigmoidalnego. Różnice pomiędzy klasyfikatorami zbudowanymi z neuronów sigmoidalnych i tangensoidalnych są niewielkie i nie pozwalają wskazać jednego z nich jako najodpowiedniejszego do budowy klasyfikatorów neuronowych typu MLP uczonych za pomocą deskryptorów otrzymanych z analizy DWT.

Literatura

- 1. Batko W., Ziółko M.: Zastosowanie teorii falek w diagnostyce technicznej. Problemy Inżynierii Mechanicznej i Robotyki. AGH, Kraków 2002.
- Białasiewicz J.: Falki i aproksymacje. Wydawnictwa Naukowo-Techniczne, Warszawa 2000.

- Czech P.: Wykrywanie uszkodzeń przekładni zębatych za pomocą metod sztucznej inteligencji. Rozprawa doktorska. Katowice 2006.
- Korbicz J., Kościelny J., Kowalczuk Z., Cholewa W.: Diagnostyka procesów. Modele. Metody sztucznej inteligencji. Zastosowania. Wydawnictwa Naukowo-Techniczne, Warszawa 2002.
- Lazarz B.: Zidentyfikowany model dynamiczny przekładni zębatej jako podstawa projektowania. Studia i Rozprawy. Instytut Technologii Eksploatacji, Katowice-Radom 2001.
- Lazarz B., Madej H., Czech P.: Wykorzystanie dyskretnej transformaty falkowej w neuronowym klasyfikatorze typu SVM. Zeszyty Naukowe Politechniki Śląskiej, s. Transport, z. 56, Wydawnictwo Politechniki Śląskiej, Gliwice 2004, s. 131÷138.
- 7. Misiti M., Misiti Y., Oppenheim G., Poggi J. M.: Wavelet toolbox for use with MATLAB. User's Guide, The MathWorks, 2002.
- Nałęcz M., Duch W., Korbicz J., Rutkowski L., Tadeusiewicz R.: Sieci neuronowe. Biocybernetyka i Inżynieria Biomedyczna. Tom 6. Akademicka Oficyna Wydawnicza EXIT, Warszawa 2000.
- 9. Osowski S.: Sieci neuronowe do przetwarzania informacji. Oficyna Wydawnicza Politechniki Warszawskiej, Warszawa 2000.
- 10. Tadeusiewicz R.: Sieci neuronowe. Akademicka Oficyna Wydawnicza, Warszawa 1993.

Recenzent: Prof. nzw. dr hab. inż. Zbigniew Dąbrowski