ZESZYTY NAUKOWE POLITECHNIKI ŚLĄSKIEJ 2007
Seria: TRANSPORT z. 61 Nr kol. 1704

Piotr CZECH

KLASYFIKATOR NEURONOWY TYPU RBF UCZONY ZA POMOCĄ DESKRYPTORÓW USZKODZEŃ ZĘBÓW KÓŁ OTRZYMANYCH PRZY UŻYCIU ANALIZY CWT

Streszczenie. W opracowaniu przedstawiono wyniki eksperymentu mającego na celu wykorzystanie sztucznych sieci neuronowych typu RBF do diagnozowania stopnia pęknięcia w stopie zęba koła. Do nauki sieci radialnych wykorzystywano deskryptory wyznaczone na podstawie rozkładów uzyskanych z ciągłej transformaty falkowej. Badania oparto na zidentyfikowanym modelu przekładni zębatej pracującej w układzie napędowym [2].

THE RBF NEURAL NETWORK CLASSIFIER OF DIAGNOSIS FAULTS OF GEAR-TOOTH WHICH USED INPUTS FROM CWT 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 continuous wavelets analysis (CWT) and RBF neural network. This experiment was based on a simulation experiment [2].

1. ZAŁOŻENIA WSTĘPNE

Badania przedstawione w artykule poświęcono sprawdzeniu przydatności ciągłej transformaty falkowej wykorzystywanej w procesie tworzenia wzorców klas uszkodzenia zębów kół przekładni pracującej w układzie napędowym. Ta część doświadczeń miała na celu próbę budowy poprawnie działającego klasyfikatora stopnia pęknięcia w stopie zęba koła przekładni pracującej przy obciążeniu $M = 138$ [Nm] oraz prędkości obrotowej wału koła $n = 1800$ [obr/min].

Podstawę uzyskania informacji o stanie przekładni zębatej stanowił sygnał drgań poprzecznych wału koła uzyskany ze zidentyfikowanego modelu przekładni zębatej pracującej w układzie napędowym [2].

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 $\left\langle \frac{1}{2} f_z, \frac{3}{2} f_z \right\rangle$ (filtr nr 5) [1].

Z tak przetworzonych wstępnie sygnałów drganiowych wyznaczono rozkłady CWT, które posłużyły za źródło deskryptorów wykorzystanych jako dane wejściowe dla sztucznych sieci neuronowych typu RBF.

Opisane wyniki badań stanowią kontynuację doświadczeń przedstawionych w pracach [7, 8].

2. WPROWADZENIE DO SIECI TYPU RBF

Sieci radialne mają strukturę warstwową, która składa się z warstw wejściowej, ukrytej i wyjściowej [3, 4, 5]. Warstwa ukryta zbudowana jest z neuronów radialnych, które najczęściej posiadają jako funkcję aktywacji funkcję Gaussa (rys. 1a). Neurony radialne reprezentują w przestrzeni wielowymiarowej hipersferę dokonującą separacji kołowej wokół punktu centralnego (rys. 1b). Neurony w warstwie wyjściowej posiadają liniową lub logistyczną funkcję aktywacji [6]. Rola neuronów w tej warstwie sprowadza się do sumowania wagowego sygnałów z warstwy ukrytej [4, 5].

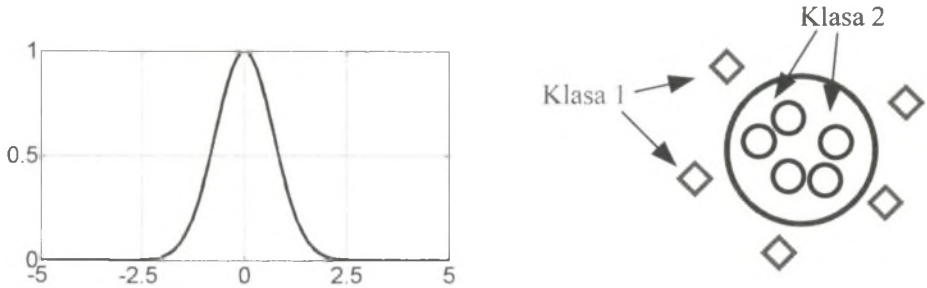

Rys. 1. Neuron radialny: (a) funkcja aktywacji, (b) sposób separacji
Fig. 1. Radial neuron: (a) activation function, (b) method of separate

Podstawowym problemem w projektowaniu tego typu sieci jest odpowiedni dobór liczby i rodzajów funkcji bazowych (neuronów w warstwie ukrytej) [6]. Zbyt mała liczba powoduje słabą jakość dopasowania do wzorców, a zbyt duża utratę zdolności do uogólniania wiedzy przez sieć. Należy określić wartości punktów centralnych, które umiejscawiają funkcje bazowe wewnątrz przestrzeni rozpiętej na danych wejściowych oraz wartości wag połączeń między neuronami w warstwie ukrytej z warstwą wyjściową [4, 5].

W pracy [1], we wstępnym etapie badań poszukiwano optymalnej pod względem minimalnego błędu klasyfikacji liczby neuronów w warstwie ukrytej. Prowadzono eksperymenty metodą polegającą na zwiększaniu liczby neuronów radialnych aż do osiągnięcia liczby równej liczbie wzorców uczących. Ponieważ różnice w wartości błędu klasyfikacji były niewielkie, w pracy przyjęto liczbę neuronów w warstwie ukrytej sieci radialnej równą liczbie wzorców uczących. Z punktu widzenia matematycznego w [4] założenie takie określa się przewymiarowaniem. Występujące małe różnice w wartości błędu dla optymalnej i maksymalnie złożonej sieci radialnej mogą wynikać z rozmiaru wzorców. Jak podano w [5], wstępny dobór liczby funkcji radialnych (neuronów ukrytych) dla każdego problemu jest sprawą indywidualną, mającą wpływ na dokładność odwzorowania wzorców. Równocześnie autor pisze, że wraz ze wzrostem wymiaru wzorców, wymagana liczba funkcji radialnych wzrasta. Zastosowane w pracy założenie pozwoliło znacząco skrócić czas potrzebny na znalezienie minimalnej struktury sieci zdolnej do wykonywania prawidłowej klasyfikacji. W badaniach skupiono się natomiast na doborze odpowiedniego charakteru funkcji bazowej, separującej optymalnie przestrzeń danych. Zmieniając współczynnik γ określano kształt funkcji i wielkość pola recepcyjnego, dla którego wielkość funkcji jest niezerowa. Współczynnik ten powinien być tak dobrany, aby pola recepcyjne wszystkich funkcji bazowych pokrywały cały obszar danych wejściowych, przy dopuszczalnym tylko nieznacznym nachodzeniu na siebie dwóch sąsiednich pól recepcyjnych [4].

3. WYNIKI BADAŃ

W badaniach przedstawionych w [1, 7, 8] sprawdzano, w przypadku użycia sygnału przyspieszeń drgań wału koła, przydatność 39 falek bazowych oraz 83 falek bazowych przy wykorzystaniu w doświadczeniach sygnału prędkości drgań. Sprawdzano przydatność w procesie budowy wzorców stopnia pęknięcia u podstawy zęba falek bazowych należących do rodziny [9]:

- haar wavelet,
- daubechies wavelets,
- biorthogonal wavelets,
- coiflets,
- symlets,
- morlet wavelet,
- mexican hat wavelet,
- meyer wavelet.

Celem opisu charakteru zmian amplitudy sygnału poddanego działaniu CWT dla 20 wybranych we wstępnej analizie skal wyznaczono miarę. Tak utworzony zestaw miar stanowił deskryptor uszkodzenia zęba koła przekładni zębatej. W celu wyboru najlepszej falki bazowej oraz miary charakteryzującej rozkłady CWT w dziedzinie czasu, przeprowadzono testy przy wykorzystaniu sztucznych sieci neuronowych typu SVM [1, 7, 8].

Przykład wpływu wyboru falki bazowej na poprawność procesu klasyfikacji stopnia pęknięcia w stopie zęba koła przekładni w przypadku zastosowania sztucznej sieci neuronowej typu SVM przedstawiono na rys. 2.

W tabeli 1 zestawiono przyjęte do dalszych badań estymaty oraz falki bazowe.

Tabela 1

Wybrane estymaty oraz falki bazowe

Nr filtru	Nazwa miary	Nazwa falki
1	Wartość skuteczna	Reverse biorthogonal wavelet 3.7
2	Współczynnik impulsowości	Morlet wavelet
3	Wartość skuteczna	Morlet wavelet
4	Wartość maksymalna	Morlet wavelet
5	Wartość międzyszczytowa	Daubechies wavelet 9

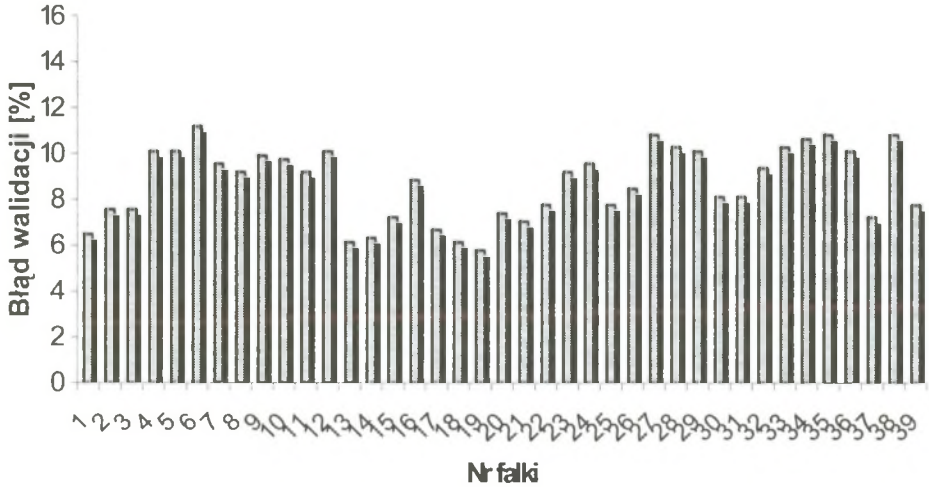

Rys. 2. Przykładowy wpływ wyboru falki bazowej na błąd klasyfikatora SVM
Fig. 2. Example of choose wavelet on error in SVM classifier

Wybrane estymaty i falki bazowe posłużyły do budowy wzorców uszkodzeń zębów kół przekładni zębatej w postaci stopnia pęknięcia u podstawy zęba.

Dla każdego wariantu zastosowanego w procesie przygotowania danych wejściowych filtru poszukiwano optymalnej wartości współczynnika γ, dla której klasyfikator charakteryzuje się najwyższą poprawnością diagnostyczną.

Uzyskane w czasie eksperymentów wyniki przedstawiają podobny charakter zmian wartości błędów klasyfikacji otrzymywanych w wyniku zmian wartości współczynnika γ.

Zależności otrzymywane przy wykorzystaniu klasyfikatorów neuronowych typu *RBF* wykazywały charakter wielomodalny.

Przykładowy wpływ wartości współczynnika γ na poprawność procesu klasyfikacji stopnia pęknięcia u podstawy zęba przedstawiono na rys. 3.

Na rys. 4 zestawiono najlepsze uzyskane wyniki klasyfikacji uszkodzenia zęba koła przekładni przy wykorzystaniu sieci neuronowych typu RBF.

Otrzymane wyniki wskazują na niewielki wpływ na uzyskiwaną poprawność pracy klasyfikatorów sposobu zastosowanej w procesie budowy wzorców filtracji sygnałów drganiowych.

W kolejnych doświadczeniach zostanie dokonane sprawdzenie przydatności innych typów klasyfikatorów wykorzystujących deskryptory uszkodzeń otrzymane z analizy CWT. Dodatkowo zostaną przeprowadzone eksperymenty sprawdzające przydatność minimalizacji wielkości wzorców przy użyciu analizy PCA/SVD oraz przydatność algorytmów genetycznych do wyboru danych wejściowych dla sztucznych sieci neuronowych wykorzystywanych jako klasyfikatory stopnia uszkodzenia zębów kół przekładni zębatej.

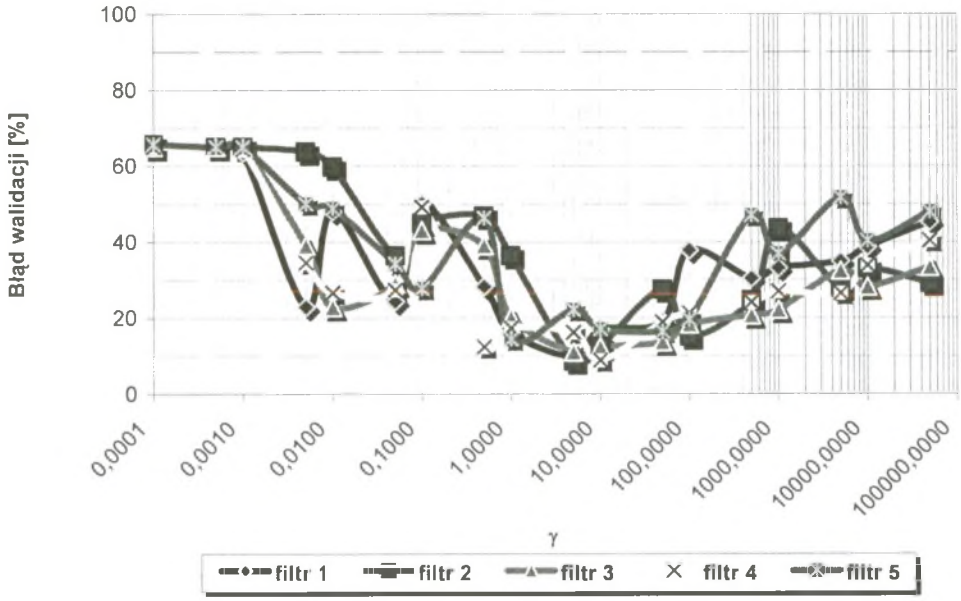

Rys. 3. Wpływ wyboru współczynnika γ na błąd klasyfikatora RBF
Fig. 3. Influence of γ factor on error in RBF classifier

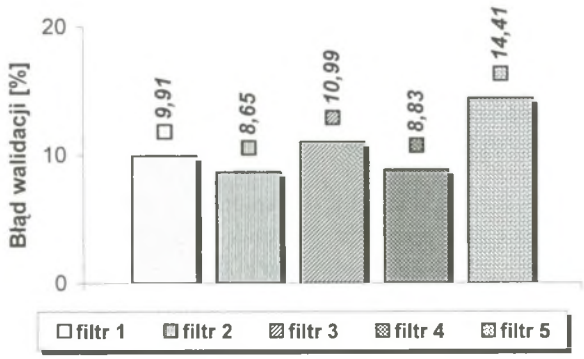

Rys. 4. Najlepsze uzyskane wyniki dla klasyfikatorów RBF
Fig. 4. The best of results for RBF classifier

Literatura

1. Czech P.: Wykrywanie uszkodzeń przekładni zębatych za pomocą metod sztucznej inteligencji. Rozprawa doktorska, Katowice 2006.
2. Łazarz B.: Zidentyfikowany model dynamiczny przekładni zębatej jako podstawa projektowania. Studia i Rozprawy. Instytut Technologii Eksploatacji, Katowice - Radom 2001.
3. Nałęcz M., Duch W., Korbicz J., Rutkowski L., Tadeusiewicz R.: Sieci neuronowe. Biocybernetyka i Inżynieria Biomedyczna. Tom 6. Akademicka Oficyna Wydawnicza EXIT, Warszawa 2000.
4. Osowski S.: Sieci neuronowe do przetwarzania informacji. Oficyna Wydawnicza Politechniki Warszawskiej, Warszawa 2000.
5. Osowski S.: Sieci neuronowe w ujęciu algorytmicznym. Wydawnictwa Naukowo-Techniczne, Warszawa 1996.
6. Witkowska D.: Sztuczne sieci neuronowe i metody statystyczne. Wybrane zagadnienia finansowe. Wydawnictwo C.H. Beck, Warszawa 2002.
7. Łazarz B., Madej H., Czech P.: Ciągła transformata falkowa jako podstawa klasyfikatora neuronowego typu SVM. XXXII Ogólnopolskie Sympozjum „Diagnostyka Maszyn", Węgierska Górka 2005.
8. Łazarz B., Madej H., Czech P.: Wykorzystanie analizy falkowej i współczynników Hoeldera w identyfikacji pęknięcia stopy zęba przy użyciu neuronowego klasyfikatora SVM [w:] Radkowski S. (red.): Degradacja systemów technicznych. Analiza ryzyka i diagnostyka procesów degradacyjnych i zmęczeniowych, Wydawnictwo Politechniki Warszawskiej, Warszawa 2004.
9. Misiti M., Misiti Y., Oppenheim G., Poggi J. M.: Wavelet toolbox for use with MATLAB. User's Guide, The MathWorks, 2002.

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