

Piotr CZECH¹

WYKORZYSTANIE ALGORYTMÓW GENETYCZNYCH ORAZ ANALIZY PCA DO DOBORU WEJŚĆ KLASYFIKATORÓW USZKODZEŃ KÓŁ ZĘBATYCH OPARTYCH NA SIECIACH NEURONOWYCH Z RADIALNYM JĄDREM

Streszczenie. W artykule przedstawiono wyniki eksperymentów mających na celu budowę klasyfikatora lokalnych uszkodzeń zębów kół przekładni opartego na sztucznych sieciach neuronowych. W badaniach wykorzystywano sieci neuronowe z radialnym jądrem. Dodatkowo podjęto próbę wykorzystania algorytmów genetycznych oraz analizy PCA w celu wyboru wejść klasyfikatora neuronowego. Badania oparto na sygnałach drganiowych otrzymanych z modelu dynamicznego przekładni pracującej w układzie napędowym. W artykule zaproponowano sposób budowy deskryptorów lokalnych uszkodzeń zębów kół, wykorzystując do tego celu sygnały drganiowe poddane odpowiedniej filtracji oraz selekcji widmowej.

Słowa kluczowe: diagnostyka, drgania, sieci neuronowe, przekładnie zębate

APPLICATION OF GENETIC ALGORITHM AND PRINCIPAL COMPONENT ANALYSIS FOR CHOOSING INPUTS FOR CLASSIFIERS OF TOOTH GEAR FAULTS WHICH USED NEURAL NETWORKS WITH RADIAL NUCLEUS

Summary. The paper presents the results of an experimental application of neural network as a classifier of tooth gear faults. The neural classifiers were based on the artificial neural networks with radial nucleus. In the experiment genetic algorithm and principal component analysis were used to check influence of choosing inputs for neural classifier on diagnostic error. The model of gearbox was used in order to create a base of knowledge. The input data for the classifier was in a form of matrix composed of statistical measures, obtained from vibration signals after filtration and selection of spectrum range.

Keywords: diagnostics, vibrations, neural networks, gearboxes

1. WSTĘP

Występowanie korelacji między zmiennymi wejściowymi utrudnia i spowalnia proces uczenia sztucznych sieci neuronowych. Podczas modelowania wzorców uczących należy

¹ Wydział Transportu, Politechnika Śląska, ul. Krasińskiego 8, 40-019 Katowice, tel. (+48 32) 6034230, e-mail: piotr.czech@polsl.pl

dążyć do jej minimalizacji. Proces dekorelacji może zostać wykonany za pomocą metody ortogonalizacji w postaci analizy składowej głównej (z ang. Principal Component Analysis). PCA jest statystyczną metodą obróbki danych znanej również pod nazwą transformacji Karhunen-Loeve'a. Polega ona na znalezieniu w n -wymiarowej przestrzeni wejść, ortogonalnych wektorów leżących w kierunkach największej wariancji danych. Liczba pierwszych głównych składowych jest zwykle dużo mniejsza niż wymiar przestrzeni wejść ($m \ll n$). Przyjmuje się, że pierwsza główna składowa leży wzdłuż kierunku maksymalnej wariancji, druga główna składowa jest ograniczona do podprzestrzeni prostopadłej do pierwszej, trzecia główna składowa ma kierunek maksymalnej wariancji w podprzestrzeni prostopadłej do dwóch pierwszych itd. Uogólniając, kierunek k -tej składowej pokrywa się z kierunkiem wektora własnego, który odpowiada k -tej co do wielkości wartości własnej pełnej macierzy kowariancji lub korelacji [3, 4, 9].

Przetworzony wzorzec za pomocą metody PCA można zapisać:

$$X = ZU^T = \sum_{i=1}^m z_i u_i^T \quad (1)$$

gdzie:

z_i – wektory składowych głównych,

u_i – wektory własne macierzy korelacji lub kowariancji.

Wartości własne macierzy autokorelacji lub kowariancji oraz wartości osobliwe macierzy X wykazują ze sobą związek. Wartości osobliwe tworzą pseudodiagonalną macierz, która jest jedną ze składowych rozkładu SVD (z ang. Singular Value Decomposition) macierzy X .

Wzorzec zdekomponowany metodą SVD przedstawia się następująco:

$$X = USV^T \quad (2)$$

gdzie:

S – macierz wartości własnych,

U – macierz lewostronnych wektorów własnych,

V – macierz prawostronnych wektorów własnych.

Rozkładowi PCA na m składowych głównych odpowiada w rozkładzie SVD macierzy X m wartości osobliwych i skojarzonych z nimi m kolumn macierzy U i V , tak więc z dużej liczby skorelowanych ze sobą wejść można otrzymać dane wejściowe znacznie mniej liczne i mniej skorelowane ze sobą. Proces ten odbywa się kosztem minimalnej straty informacji zawartej w pełnym wymiarze wejść. Sztuczne sieci neuronowe wykorzystujące tak przetworzone wzorce mają mniej złożone struktury architektury, a przez to proces uczenia ich jest łatwiejszy i szybszy [2, 4, 9-11, 13].

Kolejnym sposobem umożliwiającym zmniejszenie złożoności struktury architektury sieci neuronowych jest zastosowanie algorytmów genetycznych. Algorytmy genetyczne (AG) należą do najpopularniejszych algorytmów ewolucyjnych stanowią najbardziej znaną metodę optymalizacji stochastycznej [4, 9, 10].

Do najważniejszej zalety algorytmów genetycznych należy prowadzenie poszukiwań w wielu punktach jednocześnie. Poszukiwane rozwiązanie nazywa się osobnikiem, a cały zbiór możliwych rozwiązań populacją. Każdy osobnik zawiera stałą liczbę chromosomów, w których parametry zadania są reprezentowane przez sekwencję zakodowanych genów. Najczęściej spotykanym sposobem kodowania jest kod bialleliczny, nazywany również binarnym.

Sposób działania algorytmu genetycznego można przedstawić następująco:

- określenie sposobu kodowania rzeczywistych parametrów w postaci chromosomu,
- przyjęcie postaci funkcji przystosowania oceniającej analizowany zestaw parametrów pod względem poszukiwanego rozwiązania,
- losowy dobór punktów startowego zestawu parametrów,
- selekcja najlepiej przystosowanych chromosomów do nowej populacji,
- zastosowanie na nowej populacji operatorów genetycznych w postaci krzyżowania i mutacji,
- sprawdzenie wartości funkcji przystosowania.

Jednokrotne przejście wszystkich wymienionych etapów nosi nazwę generacji. Pierwsza generacja, zwana zerową, operuje na losowo wybranych jednostkach. W każdej kolejnej generacji w celu poprawy populacji stosuje się operatory genetyczne. Schemat postępowania powtarza się do chwili osiągnięcia przez funkcję przystosowania założonej wartości lub do osiągnięcia założonej liczby powtórzeń.

Do najważniejszego operatora genetycznego należy operator krzyżowania, zwany również operatorem rekombinacji. Jego zadanie polega na rekombinacji łańcuchów genów przez wymianę segmentów łańcuchów pomiędzy chromosomami osobników rodzicielskich.

Dla każdej generacji dokonywana jest selekcja najlepiej przystosowanych osobników. Najczęściej stosowaną metodą wyboru jest selekcja z wykorzystaniem koła ruletki. W metodzie tej każdemu osobnikowi w populacji wyznacza się prawdopodobieństwo jego wyboru jako stosunek wartości jego przystosowania do sumy wartości przystosowania wszystkich osobników w populacji. Na tej podstawie jest budowane koło ruletki, w której każdemu osobnikowi przypisuje się pole o wielkości proporcjonalnej do prawdopodobieństwa jego wyboru. Przez wielokrotne uruchomienie koła ruletki wybiera się osobniki.

W badaniach wykorzystano algorytm genetyczny do wyboru zmiennych wejściowych, a przez to do redukcji liczby wejść i złożoności sieci. Funkcją celu w tym zadaniu stanowiła minimalizacja błędu klasyfikacji.

2. OPIS BADAŃ

W badaniach postanowiono sprawdzić przydatność widma sygnału drganiowego w procesie tworzenia wzorców klas uszkodzeń zębów kół przekładni. W tym celu sygnał drgań poprzecznych wału koła poddano transformacji FFT, uzyskując jego reprezentację w dziedzinie częstotliwości. Do diagnozy wybrano uszkodzenia przekładni zębatej w postaci pęknięcia u podstawy zęba. W badaniach wykorzystywano model dynamiczny przekładni zębatej pracującej w układzie napędowym.

W celu opisu charakteru zmian widma w zależności od stopnia uszkodzeń wyodrębniono z niego:

- zakres do wartości częstotliwości obrotowej f_o ,
- kolejne częstotliwości zazębienia $i \cdot f_z$,
- zakresy częstotliwości $f \in \langle i \cdot f_z - f_o, i \cdot f_z \rangle$,
- zakresy częstotliwości $f \in \langle i \cdot f_z, i \cdot f_z + f_o \rangle$.

Zakresy częstotliwości $f \in \langle f_o, f_z - f_o \rangle$ oraz $f \in \langle i \cdot f_z + f_o, (i+1) \cdot f_z - f_o \rangle$ podzielono na 20, 10 oraz 5 podzakresów. Celem podziału na podzakresy o trzech wariantach liczebności było sprawdzenie wpływu ich wielkości na wynik klasyfikacji. Podział ten dał odpowiednio podzakresy o długościach $\Delta f \cong 30$ [Hz], $\Delta f \cong 65$ [Hz] oraz $\Delta f \cong 150$ [Hz].

W każdej z wydzielonej części widma wyznaczono miary zmienności jego rozkładu. Wektor składający się z wyznaczonej miary w każdej z części widma stanowił dane wejściowe dla klasyfikatora neuronowego.

Sprawdzono wpływ wyboru miar statystycznych jako danych wejściowych klasyfikatorów na wartość błędu klasyfikacji. Przebadano 35 miar. Analizy powtórzono dla wzorców otrzymanych z sygnałów czasowych uzyskanych przez zastosowanie 5 filtrów, tj.:

- filtr dolnoprzepustowy w zakresie do 12 [kHz],
- filtr dolnoprzepustowy w zakresie do 6 [kHz],
- filtr pasmowo przepustowy do otrzymywania sygnału resztkowego w zakresie do 6 [kHz],
- filtr pasmowo przepustowy do otrzymywania sygnału różnicowego w zakresie do 6 [kHz],
- filtr pasmowo przepustowy do otrzymywania sygnału w zakresie $\langle \frac{1}{2}f_z, \frac{3}{2}f_z \rangle$.

Wyniki eksperymentu przeprowadzonego z wykorzystaniem sieci neuronowej typu SVM z jądrem radialnym pozwoliły na wybór najwrażliwszej miary zastosowanej przy budowie wzorców klas uszkodzeń zębów kół przekładni. W zależności od wariantu podziału na podzakresy oraz typu zastosowanego filtra do dalszych obliczeń przyjęto miary zestawione w tabeli 1.

Tabela 1

Najlepsze uzyskane wyniki dla sieci typu SVM

Lp.	Liczba podzakresów	Nr filtru	Liczba wejść klasyfikatora neuronowego	Nazwa miary	Błąd klasyfikacji [%]
1	20	1	368	Odchylenie ćwiartkowe	4,14
2		2	181	Kwartyl 3	3,96
3		3	153	Pozycyjny współczynnik zmienności	3,60
4		4	140	Wartość międzyszczytowa	3,96
5		5	24	Kwartyl 3	3,06
6	10	1	206	Dyskryminanta X6	3,60
7		2	91	Pozycyjny współczynnik zmienności	3,78
8		3	83	Współczynnik asymetrii	3,78
9		4	70	Współczynnik asymetrii	3,60
10		5	15	Średnia arytmetyczna	3,78
11	5	1	128	Odchylenie przeciętne	3,78
12		2	56	Odchylenie przeciętne	3,42
13		3	48	Energia sygnału	3,42
14		4	35	Odchylenie przeciętne	2,88
15		5	9	Wartość skuteczna	4,86

Kolejnym etapem eksperymentu było sprawdzenie przydatności sieci neuronowych typu RBF i PNN w problemach klasyfikacji stopnia pęknięcia w stopie zęba koła. W tej części eksperymentu badano wpływ zastosowanego filtru oraz liczby podzakresów na wartość błędu klasyfikacji. W procesie budowy wzorców wykorzystano miary wyznaczone jako optymalne w badaniach sieci neuronowych typu SVM. Dla każdego wariantu zastosowanego filtru i każdej liczby podzakresów poszukiwano optymalnej wartości współczynnika γ .

Dodatkowo przeprowadzono doświadczenia przy wykorzystaniu wzorców zbudowanych na podstawie analizy PCA/SVD danych otrzymanych z widma FFT. Utworzono nowe zestawy wzorców, w skład których wchodziły tylko najbardziej znaczące składowe główne. Sprawdzono również poprawność pracy klasyfikatorów, których wejścia zostały wybrane za pomocą algorytmów genetycznych (AG).

W tabeli 2 zestawiono liczebność wejść klasyfikatorów neuronowych wykorzystujących w procesie uczenia wzorce otrzymane przez analizę FFT oraz dodatkowo zredukowane w wyniku działania analizy PCA/SVD (FFT-PCA/SVD) i algorytmów genetycznych (FFT-AG).

Tabela 2

Liczba wejść klasyfikatora neuronowego

Lp.	Liczba podzakresów	Nr filtru	Liczba wejść klasyfikatora neuronowego		
			<i>FFT</i>	<i>FFT-PCA/SVD</i>	<i>FFT-AG</i>
1	20	1	368	13	–
2		2	181	10	98
3		3	153	25	4
4		4	140	8	67
5		5	24	8	4
6	10	1	206	22	7
7		2	91	24	4
8		3	83	19	30
9		4	70	20	46
10		5	15	6	7
11	5	1	128	5	69
12		2	56	5	19
13		3	48	4	14
14		4	35	4	6
15		5	9	3	3

W przypadku zastosowania danych otrzymanych w wyniku podziału wybranych zakresów widma na 20 podzakresów przy zastosowanym filtrze nr 1 ze względu na złożoność sieci nie udało się poprawnie przeprowadzić procesu wyboru wejść sieci za pomocą algorytmów genetycznych.

Przy użyciu sieci neuronowej typu RBF można zauważyć, że dla większości sposobów budowy wzorców oraz redukcji ich rozmiaru największą wartością błędu klasyfikacji charakteryzują się klasyfikatory wykorzystujące wzorce otrzymane dzięki filtrowi nr 5. Błąd ten wzrasta w stosunku do najniższego uzyskanego poziomu nawet czterokrotnie.

Największą poprawność działania pokazują klasyfikatory pracujące przy wykorzystaniu danych wejściowych otrzymanych z podziału wybranych zakresów widma na 10 podzakresów.

Próby wykorzystania wzorców, których wielkość została zredukowana za pomocą analizy PCA/SVD, nie przyniosły poprawy wyników uzyskanych w procesie klasyfikacji

stopnia uszkodzenia zębów kół przekładni. W większości przypadków wyniki okazały się niewiele gorsze niż dla danych otrzymanych bezpośrednio z widma.

Wartości błędów klasyfikacji otrzymane dla sieci RBF, dla których liczba wejść została dobrana przy użyciu algorytmów genetycznych, są równe lub nieznacznie wyższe niż w przypadku stosowania wzorców otrzymanych bezpośrednio w wyniku przeprowadzenia analizy FFT. Powodem tego może być wykorzystanie w procesie doboru optymalnego zestawu wejść innego typu sieci – PNN. Wybór tego typu sieci był jednak koniecznością ze względu na szybkość ich uczenia. Zastosowanie wzorców otrzymanych z użyciem algorytmów genetycznych pozwoliło na szybsze przeprowadzanie procesów uczenia.

Poprawę wyników klasyfikacji stopnia uszkodzenia zębów kół można zauważyć w przypadku stosowania wszystkich sposobów budowy i redukcji zestawów wzorców wykorzystanych w procesie uczenia sztucznych sieci neuronowych typu PNN. Szczególnie widoczną poprawę uzyskiwanych wyników w stosunku do klasyfikatorów RBF odnotowano dla przypadków stosowania danych otrzymanych przy użyciu filtra nr 5.

Widoczny dla klasyfikatorów typu RBF wpływ użytego w procesie budowy wzorców typu filtracji oraz sposobu selekcji widma jest znikomy w większości przetestowanych klasyfikatorów typu PNN.

Również w przypadku stosowania tego typu klasyfikatorów uczonych na wzorcach otrzymanych w wyniku działania analizy PCA/SVD nie udało się uzyskać poprawy wyników w porównaniu z klasyfikatorami wykorzystującymi niezredukowane zestawy wzorców.

W przypadku doboru wejść sieci przy użyciu algorytmów genetycznych uzyskane dla klasyfikatorów typu PNN wyniki są w większości przypadków lepsze od wyników uzyskanych bez stosowania procesu doboru danych wejściowych, a co najwyżej im równe. Wyniki te potwierdziły przydatność stosowania algorytmów genetycznych.

3. PODSUMOWANIE

Przeprowadzone badania miały na celu budowę poprawnie działającego klasyfikatora lokalnych uszkodzeń zębów kół przekładni opartego na sztucznych sieciach neuronowych. W celu pozyskania odpowiednio liczego ciągu uczącego zdecydowano się skorzystać z modelu dynamicznego przekładni zębatej pracującej w układzie napędowym. Do diagnozy wybrano uszkodzenia przekładni zębatej w postaci pęknięcia w stopie zęba. W modelu symulacyjnym zaadaptowano pęknięcie w stopie zęba jako procentową zmianę sztywności zazębienia w stosunku do nieuszkodzonej przekładni. W celu zwiększenia reprezentatywności ciągu uczącego symulacje powtórzono dla różnych błędów cyklicznych i losowych zębniaka i koła.

Doświadczenia, w których wykorzystywano sztuczne sieci neuronowe typu RBF i PNN do celu diagnozy uszkodzeń zębów kół przekładni, zostały powtórzone dla zestawów wzorców zoptymalizowanych pod względem wielkości za pomocą analizy PCA/SVD. W badaniach sprawdzono również przydatność algorytmów genetycznych, za pomocą których wybrano najlepsze warianty wejść sieci neuronowych, dla których wartość błędu walidacji była najmniejsza.

Przeprowadzone badania pozwoliły na zbudowanie prawie bezbłędnie działających klasyfikatorów uszkodzeń zębów kół przekładni.

Realizowane eksperymenty są zgodne z międzynarodowymi trendami dotyczącymi szeroko prowadzonych badań związanych z elementami układów napędowych [1-9, 12, 14, 15].

Bibliografia

1. Bartelmus W., Zimroz R.: A new feature for monitoring the condition of gearboxes in nonstationary operating conditions. *Mechanical Systems and Signal Processing*. Vol. 23, 2009, p. 1528-1534.
2. Bartelmus W., Zimroz R.: Application of self-organised network for supporting condition evaluation of gearboxes. *Artificial Intelligence Methods "AI-METH"*, Gliwice 2004.
3. Cempel C.: Multidimensional condition monitoring of mechanical systems in operation. *Mechanical Systems and Signal Processing*, 17(6), 2003, p. 1291-1303.
4. Czech P., Łazarz B., Wojnar G.: Wykrywanie lokalnych uszkodzeń zębów kół przekładni z wykorzystaniem sztucznych sieci neuronowych i algorytmów genetycznych. ITE, Radom 2007.
5. Dąbrowski Z., Komorska I., Puchalski A.: Diagnostowanie błędów wykonania i montażu układów wirujących. *Biblioteka Problemów Eksploatacji*. ITE, Radom 2001.
6. Dąbrowski Z., Radkowski S., Wilk A.: Dynamika przekładni zębatych. *Badania i symulacja w projektowaniu eksploatacyjnie zorientowanym*. ITE 2000.
7. Figlus T., Wilk A.: Comparison of the sound pressure measurement and the speed measurement of the gearbox vibrating surface. *Transport Problems*, Vol. 7, 2012, Issue 1, p. 37-42.
8. Grega R., Homišin J., Kaššay P., Krajňák J.: The analyse of vibrations after changing shaft coupling in drive belt conveyer. *Zeszyty Naukowe*, z. 72, s. Transport, Wydawnictwo Politechniki Śląskiej, Gliwice 2011, p. 23-31.
9. Korbicz J., Kościelny J., Kowalczyk Z., Cholewa W. (praca zbiorowa): Diagnostyka procesów. *Modele. Metody sztucznej inteligencji. Zastosowania*. Wydawnictwa Naukowo-Techniczne, Warszawa 2002.
10. Nałęcz M., Duch W., Korbicz J., Rutkowski L., Tadeusiewicz R.: Sieci neuronowe. *Biocybernetyka i Inżynieria Biomedyczna*, tom 6. Akademicka Oficyna Wydawnicza EXIT, Warszawa 2000.
11. Osowski S.: Sieci neuronowe do przetwarzania informacji. *Oficyna Wydawnicza Politechniki Warszawskiej*, Warszawa 2000.
12. Puškár M., Bigoš P., Puškárová P.: Accurate measurements of output characteristics and detonations of motorbike high-speed racing engine and their optimization at actual atmospheric conditions and combusted mixture composition. *Measurement*, Vol. 45, 2012, p. 1067-1076.
13. Tadeusiewicz R.: Sieci neuronowe. *Akademicka Oficyna Wydawnicza*, Warszawa 1993.
14. Urbanský M., Homišin J., Krajňák J.: Analysis of the causes of gaseous medium pressure changes in compression space of pneumatic coupling. *Transactions of the Universities of Košice*, Vol. 2, 2011, p. 35-40.
15. Zuber N., Ličen H., Klačnja-Miličević A.: Remote online condition monitoring of the bucket wheel excavator SR1300 – a case study. *Facta Universitatis. Series: Working and Living Environmental Protection*, Vol. 1(5), 2008, p. 25-37.