

Piotr CZECH

Wydział Transportu, Politechnika Śląska, Gliwice

KLASYFIKATOR LOKALNYCH USZKODZEŃ ZĘBÓW KÓŁ PRZEKŁADNI, WYKORZYSTUJĄCY SIECI NEURONOWE MLP ORAZ CIĄGLĄ TRANSFORMATĘ FALKOWĄ

Słowa kluczowe

Diagnostyka przekładni zębatych, metody sztucznej inteligencji, sztuczne sieci neuronowe.

Streszczenie

W artykule przedstawiono wyniki prób mających na celu budowę klasyfikatora lokalnych uszkodzeń zębów kół przekładni, opartego na sztucznych sieciach neuronowych. W badaniach wykorzystano sieci neuronowe typu perceptron wielowarstwowy (MLP).

Obiekt badań stanowiła przekładnia zębata o zębach prostych, pracująca na stanowisku mocy krążącej FZG. Badaniami objęto przekładnie z kołami bez uszkodzeń oraz z lokalnymi uszkodzeniami zębów w postaci pęknięcia u podstawy zęba i wykruszenia wierzchołka zęba.

W artykule zaproponowano budowę deskryptorów lokalnych uszkodzeń zębów kół wykorzystując do tego celu sygnały drganiowe poddane odpowiedniej filtracji oraz przetwarzaniu.


Wprowadzenie

Monitorowanie i diagnozowanie stanu obiektów technicznych jest jednym z podstawowych działań służących konstruowaniu strategii ich poprawnej eks-

ploatacji. Bardzo często wystąpieniu awarii towarzyszy oprócz strat ekonomicznych również zagrożenie dla życia ludzkiego. Niezbędne staje się zatem stworzenie odpowiednich narzędzi diagnostycznych, pozwalających na wczesną wykrywalność wszelkich zagrożeń. Już od wielu lat w ośrodkach krajowych i zagranicznych prowadzone są badania, których celem jest opracowanie odpowiednich narzędzi wspomagających procesy rozpoznawania uszkodzeń elementów układów napędowych [1–4, 6–11, 15, 19, 20, 26, 27, 30, 32, 36, 38, 41]. Obecnie na całym świecie rozwijane są metody umożliwiające diagnozowanie stanu elementów układów przeniesienia napędu bez konieczności jego demontażu. Do takich metod należy diagnostyka wibroakustyczna, w której źródłem informacji o stanie obiektu są emitowane przez niego drgania i/lub hałas. Literatura wskazuje na duże możliwości wykorzystania sygnałów wibroakustycznych w procesie diagnozowania, a ich odpowiednia filtracja, wstępne przetworzenie i analiza umożliwiają uzyskanie informacji o stanie obiektu. Nowością opisywaną w literaturze są systemy ekspertowe wykorzystujące elementy sztucznej inteligencji [1, 2, 7–9, 12–19, 21–26, 28–31, 33–35, 37, 39, 40, 42]. Odpowiednio skonstruowany i nauczony system potrafi automatycznie rozpoznać występujące uszkodzenia.

1. Obiekt badań

Obiektem badań była przekładnia zębata pracująca w układzie napędowym (rys. 1), w którego skład wchodził silnik elektryczny, przekładnia pasowa, badana przekładnia zębata, przekładnia zamykająca oraz sprzęgło napinające. Silnik elektryczny o mocy 15 [kW] za pośrednictwem przekładni pasowej napędzał przekładnię zamykającą. Obciążenie przekładni regulowano za pomocą dźwigni z obciążnikami, sprzęgła napinającego i wałków skrzynek. Prędkość pracy przekładni ustalano za pomocą przemiennika częstotliwości sterującego pracą silnika elektrycznego. Przekładnia badana oraz zamykająca posiadały jednakowe przełożenie i jednakowy rozstaw osi.



Rys. 1. Stanowisko mocy krążącej FZG

Badano przekładnię zębatą o zębach prostych, gdzie liczba zębów zębnika i koła wynosiła odpowiednio 16 i 24.

W badaniach wykorzystano koła zębate wykonane ze stali 20H2N4A, nawęglane i hartowane do twardości wynoszącej 60÷62 HRC.

2. Opis eksperymentu

Celem eksperymentu była próba klasyfikacji rodzaju i stopnia uszkodzeń zębów kół przekładni, wykorzystując do tego celu sztuczne sieci neuronowe [12–18, 21–26, 28, 29, 31, 33–35, 37, 39, 40, 42].


W doświadczeniach postanowiono wykorzystać informację diagnostyczną o stanie obiektu zawartą w sygnale drganiowym. Wykorzystując wibrometr laserowy Ometron VH300+, analizator sygnałów DSPT SigLab oraz komputer zarejestrowano prędkości drgań poprzecznych wału koła. Pomiarów wykonano w kierunku działania siły międzyzębnej. Wybór kierunku dokonano zgodnie z zaleceniami przedstawionymi w [20].

W celu sprawdzenia poprawności działania klasyfikatorów neuronowych w zadaniu identyfikacji stopnia uszkodzenia przekładni zębatej, wykonano serię pomiarów drgań poprzecznych wału koła przekładni nieuszkodzonej oraz przekładni z zamodelowanymi uszkodzeniami:

- pęknięcia u podstawy zęba (na głębokości: 1 mm, 3 mm),
- wykruszenia wierzchołka zęba (o wartość: 0,75 mm, 1,5 mm, 2 mm).

Pomiary wykonano dla przekładni zębatej pracującej przy dwóch prędkościach obrotowych wału koła (900 obr/min, 1800 obr/min) i dwóch obciążeniach (2,58 MPa, 3,85 MPa).

Rezultatem przeprowadzonego procesu rejestracji sygnałów było otrzymanie macierzy składającej się z 971 sygnałów prędkości drgań poprzecznych wału koła. Przykładowe zarejestrowane przebiegi prędkości drgań przedstawiono na rysunku 2.



Rys. 2. Prędkości drgań poprzecznych wału koła dla (a) nieuszkodzonego koła, (b) pęknięcia u podstawy zęba na głębokości 3 mm

Na podstawie przeprowadzonych badań wstępnych ustalono, że klasyfikatory neuronowe uczone za pomocą wzorców otrzymanych bezpośrednio z czasowych sygnałów drganiowych, nie umożliwiają budowy poprawnie działających systemów diagnozujących stan przekładni [8,19].

W pracy [8] pokazano, że podstawowym zadaniem w procesie budowy wzorców rodzaju i stopnia uszkodzenia przekładni zębatych jest dobór odpowiedniego sposobu filtracji i analizy sygnałów drganiowych. Sprawdzone przydatność analizy obwiedni, szybkiej i krótkoczasowej transformaty Fouriera, widma iloczynowego i poliharmonicznego, cepstrum, ciągłej i dyskretnej transformaty falkowej, empirycznej dekompozycji sygnału, transformaty Hilberta-Huanga, transformaty Wignera-Ville'a, bispektrum.

Zarejestrowane na stanowisku FZG sygnały drganiowe poddano działaniu pięciu filtrów. Filtry nr 1 i 2 były dolnoprzepustowe w zakresie 6 i 12 kHz. Kolejne filtry umożliwiały otrzymanie sygnałów resztkowych (filtr nr 3) oraz różnicowych (filtr nr 4). Ostatni z filtrów umożliwiał otrzymanie sygnału w zakresie 0,5÷1,5 częstotliwości zazębienia [8, 9, 19].

Sygnał w dziedzinie czasu, zwany sygnałem resztkowym, otrzymano poprzez usunięcie z widma pasm zawierających składowe obrotowe wałów kół i ich harmoniczne oraz składowe częstotliwości zazębienia i jej harmoniczne, a następnie stosując odwrotną transformatę Fouriera. Sygnał różnicowy otrzymano podobnie jak sygnał resztkowy, lecz usunięte pasma wokół częstotliwości zazębienia i ich harmonicznych są szersze i obejmowały wstęgi boczne związane z częstotliwościami obrotowymi kół zębatych.

Na kolejnym etapie tworzenia wzorców uszkodzeń zębów sygnały drganiowe otrzymane przy użyciu pięciu filtrów poddano działaniu ciągłej transformaty falkowej (CWT) [3, 5].

Analiza falkowa polega na dekompozycji sygnału i przedstawieniu go w postaci liniowej kombinacji funkcji bazowych, zwanych falkami [5]. Cechą odróżniającą tę metodę analizy sygnału od innych jest wielostopniowa dekompozycja sygnału, zmienna rozdzielczość w dziedzinie czasu i częstotliwości, możliwość stosowania funkcji bazowych innych niż funkcje harmoniczne [15].

Ciągła transformata falkowa definiowana jest następująco [3, 5]:

$$CWT(a,b) = \frac{1}{\sqrt{a}} \int_{-\infty}^{+\infty} \psi\left(\frac{t-b}{a}\right) \cdot x(t) dt \quad (1)$$

gdzie: $\psi_{a,b}(t)$ – funkcja bazowa, falka,

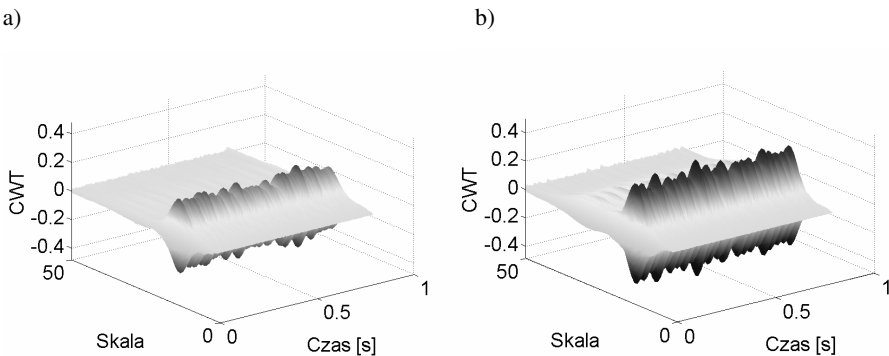
a – parametr skali, związany z lokalizacją w dziedzinie częstotliwości, $a \in R^+$, $a \neq 0$,

b – parametr przesunięcia w dziedzinie czasu, $b \in R$.

Częstotliwość falki reguluje się za pomocą parametru skali a , natomiast wykorzystując parametr b można badać lokalne własności przebiegów czasowych [3].

Metoda ta dzięki możliwości dopasowania szerokości okna do analizowanego zakresu częstotliwości umożliwia badanie sygnałów niestacjonarnych. Dla przebiegów wolnozmiennych okno rozszerza się w dziedzinie czasu, natomiast przy wysokich częstotliwościach zwęża się, zachowując stałe pole powierzchni [3]. Autor w pracy [38] stwierdza, że odpowiedni dobór falki bazowej oraz szeregu wartości skali, warunkuje poprawność procesu diagnozy stanu technicznego obiektu przy wykorzystaniu analizy falkowej.

Przykładowe rozkłady CWT przedstawiono na rysunku 3.



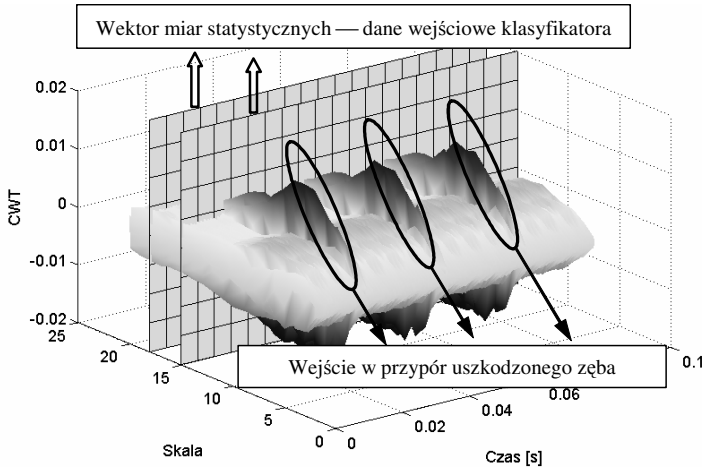
Rys. 3. Rozkłady CWT prędkości drgań poprzecznych wału koła dla (a) nieuszkodzonego koła, (b) wykruszenia wierzchołka zęba o 2 mm

W badaniach wstępnych sprawdzano przydatność 83 falek bazowych należących do rodzin¹: haar, daubechies, biorthogonal, coiflets, symlets, morlet, mexican hat, meyer, reverse biorthogonal, gaussian, complex gaussian, shannon, frequency b-spline, complex morlet, discrete approximation of meyer.

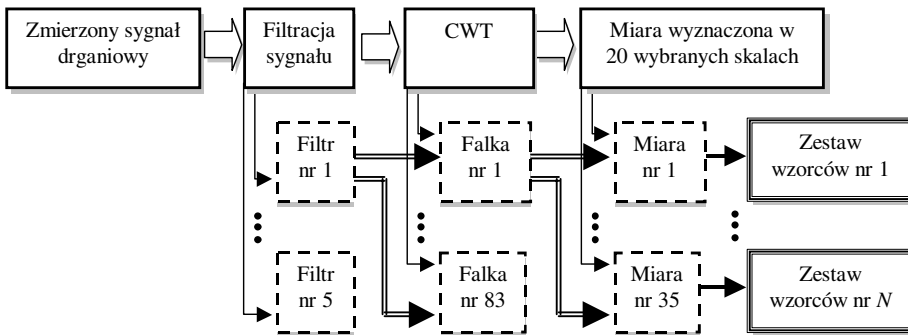
Celem opisu charakteru zmian amplitudy sygnału poddanego działaniu CWT dla 20 wybranych we wstępnej analizie skal wyznaczono miarę. Miara ta opisywała przebieg zmian amplitudy rozkładu CWT w dziedzinie czasu. W badaniach sprawdzono przydatność 35 miar diagnostycznych powszechnie stosowanych w literaturze (współczynniki zmienności, szczytu, luzu, kształtu, impulsowości i asymetrii, odchylenia ćwiartkowe i przeciętne, średnie arytmetyczne, geometryczne i harmoniczne, kwartyle, dyskryminanty bezwymiarowe, momenty centralne, kumulanty, energię sygnału, wartości skuteczne, międzyszczytowe, maksymalne i minimalne, wariancję, pozycyjny współczynnik zmienności) [8].

¹ Zachowano nazewnictwo angielskie.

Sposób postępowania przy budowie wzorców klas uszkodzeń został przedstawiony na rysunkach 4 i 5.



Rys. 4. Sposób pozyskania danych wejściowych dla sztucznych sieci neuronowych



Rys. 5. Sposób budowy zestawów wzorców

W rezultacie zbudowano 14525 zestawów wzorców. Każdy z zestawów miał rozmiar 971×20 . Wymiar ten odpowiadał liczbie przypadków (liczba zmierzonych na stanowisku FZG sygnałów drganiowych) i liczbie wejść sieci (liczba skal, w których wyznaczono miarę). Każdy wariant zestawu wzorców podzielono na pół uzyskując dane uczące i testujące.

Na podstawie badań wstępnych wybrano następujące falki bazowe [8, 9]:

- daubechies wavelet 9 (nr falki = 9),
- morlet wavelet (nr falki = 37),
- reverse biorthogonal wavelet 3.7 (nr falki = 50),

oraz miary:

- współczynnik impulsowości (nr miary = 5),
- wartość skuteczna (nr miary = 14),
- wartość międzyszczytowa (nr miary = 25).

W badaniach mających na celu budowę klasyfikatora diagnostycznego wykorzystano sztuczne sieci neuronowe typu perceptron wielowarstwowy (MLP). Wyboru dokonano ze względu na uzyskiwany w badaniach wstępnych poziom błędu klasyfikacji [8] oraz powszechność ich stosowania w różnych zadaniach wykorzystujących sztuczne sieci neuronowe. Na tej podstawie można sądzić o możliwości łatwiejszej ich implementacji w rzeczywistych systemach diagnostycznych.

W przypadku stosowania tego typu sieci neuronowych należy określić architekturę i metodę uczenia sieci oraz typ neuronów zastosowanych w warstwach ukrytych sieci [2, 12–15, 18, 22–25, 28, 29, 31, 33–35, 37, 42]. Trzeba przy tym pamiętać, iż nie należy rozdzielać tych etapów, gdyż są one ze sobą bezpośrednio powiązane [23, 24]. Jednocześnie literatura uwidacznia brak zasad odnośnie doboru tych parametrów i wskazuje potrzebę ustalenia ich metodą eksperymentalną – prób i błędów [2, 12, 13, 15, 16, 18, 21, 22–24, 28, 29, 31, 33, 34, 35, 37, 39, 40, 42].

W przeprowadzonych doświadczeniach dla każdego zestawu wzorców dobierano najlepszy wariant architektury sieci. Przy wyborze architektury sieci sprawdzano przydatność klasyfikatorów zbudowanych z jednej oraz z dwóch warstw ukrytych. Na podstawie badań wstępnych [8] założono dla każdej warstwy ukrytej możliwość występowania 5, 10, 15, 20, 25 i 30 neuronów. Należy jednak zaznaczyć, iż optymalną liczbą neuronów, przy której sieć uzyskuje najmniejszy błąd, może być dowolna liczba. Wybranie do badań kilku wariantów liczebności neuronów w warstwach ukrytych miało na celu sprawdzenie wpływu ich liczebności na poprawność klasyfikacji wzorców. Równocześnie starano się sprawdzić, czy można określić dla analizowanego zadania diagnostycznego optymalną architekturę sieci, niezależnie od sposobu budowy wzorców. Przy wyborze architektury należy dążyć do jej minimalizacji, co zapewni sieci odpowiednie zdolności generalizacyjne [22, 23, 34]. Jak podaje [39] wielokrotne powtarzanie procesu uczenia pozwala zbudować sieć dostatecznie dużą, by mogła nauczyć się problemu, a jednocześnie na tyle małą, aby poprawnie generalizować.

Kolejnym elementem, jaki należało określić, był rodzaj zastosowanej metody uczenia. Przy jej wyborze należy kierować się zarówno kryterium wartości błędu, jak również nakładami czasowymi niezbędnymi do nauczania sieci. Algorytmy uczenia sieci neuronowych są szczegółowo opisane w literaturze [18, 23–25, 34, 35, 42].

W pracach [2, 12, 18, 23÷25] porównano różne algorytmy uczenia. Jak podano w [2, 23–25], algorytmy newtonowskie, w tym metoda zmiennej metry-

ki i Levenberga-Marquardta, przewyższają metodę największego spadku i gradientów sprzężonych. Przewaga ta zanika jednak przy większych rozmiarach sieci. Podobnie w [18] Autor stwierdza, że dla niewielkich rozmiarów sieci lepsze rezultaty można osiągnąć stosując metodę Levenberga-Marquardta. Potwierdzona została również teza o dużych nakładach czasowych ponoszonych przy uczeniu dużych sieci. Spośród metod gradientowych Autor wskazuje na metodę ze zmiennym w trakcie realizacji procedury współczynnikiem uczenia.

Autorzy [31] wskazują, że algorytmy wydajniejsze nie w każdym zadaniu się sprawdzają. Ponadto są one tak złożone obliczeniowo, że zdarza się, iż mniejsza liczba iteracji nie odpowiada krótszemu czasowi uczenia. Pomimo istnienia wielu algorytmów uczenia Autorzy proponują stosować najprostszą z metod gradientowych.

Podobne zdanie zaprezentowano w [35]. Autorzy wskazują na fakt, iż w pewnych sytuacjach trudno jest dotrzymać lub sprawdzić założenia dotyczące innych metod uczenia. W cytowanej pozycji literaturowej szczególnie akcent położono na stwierdzeniu, że metodą wstecznej propagacji można rozwiązać praktycznie każde zadanie, podczas gdy inne metody w pewnych sytuacjach gwarantują bardzo dużą sprawność przetwarzania, a w innych całkowicie zawodzą. Potwierdzeniem tej tezy były również wyniki uzyskane w [8].

Równocześnie trzeba zauważyć, że efektywność metod uczenia zależy od konkretnego zadania, liczebności dostępnych wzorców i architektury sieci [23]. Dlatego też nie jest możliwe określenie apriori, która metoda jest najefektywniejsza. Zgodnie z [12] każde zastosowanie sieci i wybór jej architektury należy przetestować za pomocą różnych metod uczenia w celu ustalenia, która z nich daje najlepsze rezultaty.

W badaniach postanowiono sprawdzić przydatność różnych metod uczenia sieci. W celach porównawczych proces doboru architektury sieci przeprowadzono dla klasyfikatorów uczonych za pomocą algorytmu gradientowego i algorytmu Levenberga-Marquardta. Dodatkowo klasyfikatory z dobraną optymalną architekturą sieci wybraną przy stosowaniu algorytmu gradientowego, uczono za pomocą 12 metod uczenia (tab. 1).

W tym przypadku proces projektowania klasyfikatorów neuronowych składał się z dwóch etapów. Na pierwszym dobierano architekturę dla sieci, która była uczona algorytmem gradientowym. Na drugim etapie klasyfikatory MLP z dobraną architekturą umożliwiającą uzyskiwanie najniższej wartości błędów (dla metody gradientowej!) uczono za pomocą 12 metod uczenia. Sprawdzano jaki wpływ na poprawność uzyskiwanych wyników ma zastosowany algorytm uczenia sieci.

W każdym z eksperymentów sprawdzano dwa rodzaje neuronów zastosowanych w warstwach ukrytych. Do badań wybrano neurony typu sigmoidalnego i tangensoidalnego [13, 15–17, 21–24, 28, 31, 33–35, 42].

Tabela 1. Algorytmy uczenia sieci neuronowych typu MLP

Nr algorytmu	Typ algorytmu
1	Algorytm gradientowy
2	Algorytm gradientowy ze współczynnikiem momentu
3	Algorytm gradientowy ze współczynnikiem momentu i adaptacyjnie dobraćanym współczynnikiem uczenia
4	Algorytm RPROP
5	Algorytm sprzężonych gradientów Fletcher-Reeves
6	Algorytm sprzężonych gradientów Polak-Ribiere
7	Algorytm sprzężonych gradientów Powell-Beale
8	Algorytm skalowanych sprzężonych gradientów
9	Algorytm one step secant
10	Algorytm BFGS
11	Algorytm Levenberg-Marquardt
12	Algorytm Bayesian regularization

3. Wyniki eksperymentu

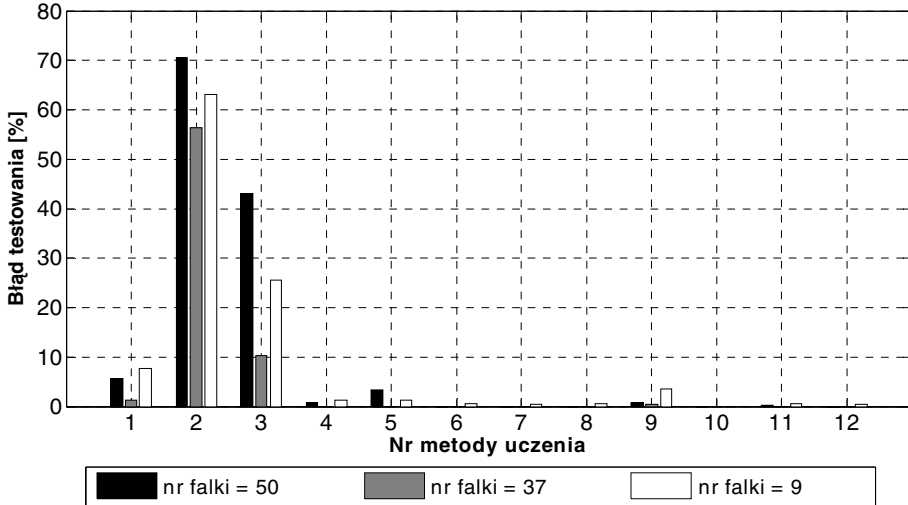
Założeniem badań była próba opracowania klasyfikatora neuronowego zdolnego do diagnozowania uszkodzeń zębów kół przekładni. Wynikiem badań przeprowadzonych na stanowisku mocy krążącej FZG było zarejestrowanie sygnałów drganiowych przekładni bez uszkodzeń oraz przekładni z uszkodzeniami w postaci pęknięcia u podstawy zęba i wykruszenia wierzchołka zęba w różnych stanach zaawansowania. W wyniku wstępnego przetwarzania otrzymano 14525 zestawów wzorców otrzymanych z sygnałów drganiowych, z których po wstępnych badaniach do dalszych eksperymentów wybrano 45 zestawów wzorców [8].

W pierwszych próbach postanowiono zbudować sztuczną sieć neuronową zdolną do rozpoznawania następujących klas uszkodzeń:

- przekładnia bez uszkodzeń,
- przekładnia z pękniętym u podstawy zębem,
- przekładnia z wykruszonym zębem.

Badania z użyciem klasyfikatorów typu MLP uczonych na danych otrzymanych przy wykorzystaniu analizy CWT doprowadziły do zbudowania klasyfikatorów charakteryzujących się bezbłędną diagnozą rodzaju uszkodzenia przekładni zębatej. Niezależnie od typu neuronów zastosowanych w warstwach ukrytych sieci MLP, najniższe wartości błędu klasyfikacji otrzymano w przypadku wykorzystania wartości skutecznej (nr miary = 14) do opisu charakteru zmian rozkładu CWT. Najwyższe wartości błędów klasyfikatorów diagnozujących rodzaj uszkodzenia zębów kół przekładni uzyskano przy wykorzystaniu w procesie uczenia metody nr 1, 2 i 3 (tab. 1).

Przykładowy wpływ wyboru algorytmu uczenia sieci neuronowej na poprawność procesu klasyfikacji rodzaju uszkodzenia zębów koła przekładni pokazano na rysunku 6.



Rys. 6. Przykładowy wpływ algorytmu uczenia na wartość błędu sieci neuronowej typu MLP klasyfikującej rodzaj uszkodzenia, sieć zbudowana z neuronów sigmoidalnych, uczona na danych otrzymanych z rozkładu CWT sygnałów resztkowych (wartość skuteczna), optymalna architektura dobrana dla algorytmu gradientowego

Ponieważ udało się zbudować klasyfikator, który bezbłędnie potrafił ocenić rodzaj występującego uszkodzenia zębów kół przekładni, w kolejnych doświadczeniach postanowiono przejść do celu badań, tzn. sprawdzenia przydatności sieci MLP w procesie klasyfikacji rodzaju i stopnia uszkodzenia zębów kół przekładni.


W przeprowadzonych badaniach sieć neuronową typu MLP uczono do rozpoznawania następujących klas:

- brak uszkodzeń,
- pęknięcie u podstawy zęba o głębokości 1 [mm],
- pęknięcie u podstawy zęba o głębokości 3 [mm],
- wykruszenie wierzchołka zęba o 0,75 [mm],
- wykruszenie wierzchołka zęba o 1,5 [mm],
- wykruszenie wierzchołka zęba o 2 [mm].

Wyniki przeprowadzonych doświadczeń mających na celu dobór optymalnej architektury sieci MLP uwidocznily zależności wynikające ze zwiększenia liczby warstw ukrytych oraz zwiększenia liczby neuronów. Zauważono przypadki, w których wraz ze wzrostem liczby neuronów w pierwszej warstwie

ukrytej, błąd najpierw spada, a następnie rośnie. Wynika to z faktu przeuczenia sieci, która traci własności generalizowania. Sieć taka jest wystarczająco złożona, aby nauczyć się prezentowanych jej w procesie uczenia wzorców na pamięć. Nie potrafi ona jednak w procesie sprawdzenia uogólniać tej wiedzy na podobne wzorce. Widoczne są również sytuacje, w których zwiększenie liczby warstw ukrytych z odpowiednio dużą liczbą neuronów poprawia skuteczność klasyfikacji. Jest to wynikiem posiadania przez taką sieć większej liczby powiązań, które mogą przechowywać większą liczbę wzorców oraz lepiej korzystać z zapamiętanej wiedzy. Uzyskane w ten sposób wyniki potwierdzają tezy głoszone przez Autorów innych publikacji [2, 15, 18, 22–24, 28, 33–35, 42].

Przykładowy wpływ architektury sieci na wielkość błędu testowania przedstawiono na rysunku 7.



Rys. 7. Przykładowy wpływ architektury sieci na wartość błędu klasyfikującej rodzaj i stopnia uszkodzenia zębów, sieć zbudowana z neuronów sigmoidalnych, uczona metodą Levenberga-Marquardta, filtr nr 4, falka nr 9, miara nr 25; LN1, LN2 – liczba neuronów w odpowiednio I i II warstwie ukrytej

Najlepsze uzyskane w procesie doboru architektury klasyfikatory, uczone za pomocą algorytmu gradientowego oraz algorytmu Levenberga-Marquardta, zestawiono w tabeli 2.

Można zauważyć, iż niezależnie od zastosowanego algorytmu uczenia sieci, typu neuronów zastosowanych w warstwach ukrytych oraz wybranej falki bazowej najniższy poziom błędu testowania występował przy klasyfikatorach uczonych na danych otrzymanych z rozkładu CWT scharakteryzowanego za pomocą wartości skutecznej (nr miary = 14). Najwyższy poziom błędu testowania był zaś widoczny przy stosowaniu wartości międzyszczytowej (nr miary = 25).

Tabela 2. Zestawienie najlepszych klasyfikatorów rodzaju i stopnia uszkodzenia zębów kół uczonych za pomocą algorytmu gradientowego (kolumna A) oraz algorytmu Levenberga-Marquardta (kolumna B)

Lp.	Nr falki	Nr miary	Nr filtru	Typ neuronów	Liczba neuronów w warstwie ukrytej				Błąd testowania [%]	
					A		B		A	B
					I	II	I	II		
1	9	5	1	sigmoidalny	20	30	25	20	27,42	14,23
2	9	5	2	sigmoidalny	25	30	25	10	24,12	14,43
3	9	5	3	sigmoidalny	30	20	20	30	37,73	25,77
4	9	5	4	sigmoidalny	30	25	15	15	37,32	26,19
5	9	5	5	sigmoidalny	30	0	25	25	24,54	11,96
6	9	14	1	sigmoidalny	15	25	15	0	12,78	0,00
7	9	14	2	sigmoidalny	20	20	15	0	5,57	0,00
8	9	14	3	sigmoidalny	25	25	30	0	12,99	0,00
9	9	14	4	sigmoidalny	20	30	30	0	14,23	0,00
10	9	14	5	sigmoidalny	15	30	20	0	8,45	0,00
11	9	25	1	sigmoidalny	15	30	25	30	18,97	1,86
12	9	25	2	sigmoidalny	15	30	20	30	12,99	1,24
13	9	25	3	sigmoidalny	20	30	25	25	22,68	5,15
14	9	25	4	sigmoidalny	30	25	20	15	25,15	4,74
15	9	25	5	sigmoidalny	30	25	30	0	11,34	0,62
16	9	5	1	tangensoidalny	30	25	25	0	15,88	13,81
17	9	5	2	tangensoidalny	25	30	30	20	13,81	13,20
18	9	5	3	tangensoidalny	25	30	5	30	27,63	26,80
19	9	5	4	tangensoidalny	25	30	30	30	26,60	25,77
20	9	5	5	tangensoidalny	25	25	25	30	14,23	11,96
21	9	14	1	tangensoidalny	20	30	10	0	0,00	0,00
22	9	14	2	tangensoidalny	30	20	20	0	0,00	0,00
23	9	14	3	tangensoidalny	20	30	25	0	0,82	0,00
24	9	14	4	tangensoidalny	30	25	25	0	1,24	0,00
25	9	14	5	tangensoidalny	25	20	15	0	0,00	0,00
26	9	25	1	tangensoidalny	20	30	25	15	2,06	1,24
27	9	25	2	tangensoidalny	30	25	30	25	1,86	1,03
28	9	25	3	tangensoidalny	30	20	30	0	8,25	4,33
29	9	25	4	tangensoidalny	30	25	15	30	8,04	4,12
30	9	25	5	tangensoidalny	30	20	30	0	2,68	1,24
31	37	5	1	sigmoidalny	30	25	20	25	27,22	10,52
32	37	5	2	sigmoidalny	30	0	25	15	25,36	9,28
33	37	5	3	sigmoidalny	25	25	20	30	37,11	21,44
34	37	5	4	sigmoidalny	30	30	20	25	35,67	20,41
35	37	5	5	sigmoidalny	25	30	20	30	23,30	10,31
36	37	14	1	sigmoidalny	25	30	10	0	2,27	0,00
37	37	14	2	sigmoidalny	25	15	15	0	5,57	0,00
38	37	14	3	sigmoidalny	25	20	20	0	8,87	0,00
39	37	14	4	sigmoidalny	30	30	20	0	8,45	0,00
40	37	14	5	sigmoidalny	30	30	10	0	4,12	0,00
41	37	25	1	sigmoidalny	10	25	30	20	10,93	0,62
42	37	25	2	sigmoidalny	15	30	25	0	13,20	0,21

cd. tabeli 2


43	37	25	3	sigmoidalny	30	25	30	5	17,73	2,89
44	37	25	4	sigmoidalny	30	30	30	0	17,53	3,51
45	37	25	5	sigmoidalny	20	30	25	20	8,87	0,21
46	37	5	1	tangenoidalny	25	25	30	0	14,64	10,93
47	37	5	2	tangenoidalny	30	25	25	15	12,78	9,07
48	37	5	3	tangenoidalny	25	25	25	5	23,71	22,89
49	37	5	4	tangenoidalny	25	30	15	15	23,51	23,92
50	37	5	5	tangenoidalny	30	30	20	15	14,02	9,28
51	37	14	1	tangenoidalny	25	10	10	0	0,00	0,00
52	37	14	2	tangenoidalny	30	15	15	0	0,00	0,00
53	37	14	3	tangenoidalny	30	25	20	0	0,00	0,00
54	37	14	4	tangenoidalny	25	30	20	0	0,21	0,00
55	37	14	5	tangenoidalny	25	25	15	0	0,00	0,00
56	37	25	1	tangenoidalny	25	25	30	25	0,62	0,21
57	37	25	2	tangenoidalny	30	30	30	25	2,27	0,41
58	37	25	3	tangenoidalny	25	30	20	25	4,95	2,89
59	37	25	4	tangenoidalny	25	30	20	30	5,15	2,89
60	37	25	5	tangenoidalny	25	25	20	20	1,86	0,00
61	50	5	1	sigmoidalny	20	30	20	30	25,98	12,16
62	50	5	2	sigmoidalny	20	30	30	20	32,58	15,88
63	50	5	3	sigmoidalny	25	20	30	15	40,41	28,66
64	50	5	4	sigmoidalny	30	30	20	15	37,73	28,25
65	50	5	5	sigmoidalny	25	20	30	25	33,40	18,56
66	50	14	1	sigmoidalny	30	30	20	0	8,04	0,00
67	50	14	2	sigmoidalny	30	30	20	0	5,36	0,00
68	50	14	3	sigmoidalny	25	25	20	0	14,43	0,00
69	50	14	4	sigmoidalny	30	30	25	0	11,75	0,00
70	50	14	5	sigmoidalny	25	30	15	0	12,16	0,00
71	50	25	1	sigmoidalny	15	25	20	10	17,94	0,82
72	50	25	2	sigmoidalny	20	30	30	25	18,56	1,44
73	50	25	3	sigmoidalny	25	25	25	0	26,60	5,77
74	50	25	4	sigmoidalny	20	30	30	0	27,22	6,19
75	50	25	5	sigmoidalny	15	30	10	25	21,03	1,44
76	50	5	1	tangenoidalny	30	25	30	25	17,53	11,75
77	50	5	2	tangenoidalny	30	20	20	25	20,82	17,73
78	50	5	3	tangenoidalny	25	30	25	15	28,25	27,84
79	50	5	4	tangenoidalny	25	20	20	20	32,37	30,10
80	50	5	5	tangenoidalny	20	30	25	30	25,36	18,97
81	50	14	1	tangenoidalny	10	30	20	0	0,00	0,00
82	50	14	2	tangenoidalny	30	30	25	0	0,82	0,00
83	50	14	3	tangenoidalny	30	15	5	25	1,44	0,00
84	50	14	4	tangenoidalny	30	25	15	10	1,65	0,00
85	50	14	5	tangenoidalny	20	20	10	0	0,62	0,00
86	50	25	1	tangenoidalny	25	25	25	20	3,51	0,62
87	50	25	2	tangenoidalny	25	30	30	0	6,19	1,65
88	50	25	3	tangenoidalny	20	30	30	20	11,55	5,77
89	50	25	4	tangenoidalny	30	15	25	30	13,20	5,77
90	50	25	5	tangenoidalny	30	20	25	25	7,42	1,65

Analizując wyniki klasyfikacji pod względem sposobu filtracji sygnału drganiowego wykorzystywanego w czasie tworzenia wzorców można zauważyć, że niezależnie od zastosowanego algorytmu uczenia sieci, typu neuronów zastosowanych w warstwach ukrytych oraz wybranej falki bazowej najmniej dokładne klasyfikatory zbudowano w oparciu o sygnały resztkowe i różnicowe (filtr nr 3 i 4).


Sieci neuronowe uczone metodą gradientową wykazywały dużą wrażliwość na typ neuronów zastosowanych w warstwach ukrytych. Przy wykorzystaniu w procesie uczenia wzorców utworzonych w ten sam sposób, klasyfikatory zbudowane z neuronów tangensoidalnych odznaczały się znacznie lepszym poziomem zgodności wyników z wzorcem niż klasyfikatory zbudowane z neuronów sigmoidalnych. Zależność taka nie występowała dla sieci neuronowych uczonych metodą Levenberga-Marquardta.

Przykładowe najlepsze uzyskane wyniki w procesie wyboru architektury sieci przedstawiono na rysunkach 8 i 9.

Porównując sieci neuronowe z optymalnie dobraną architekturą, uczone metodą gradientową i Levenberga-Marquardta można zauważyć, iż dla wzorców utworzonych w ten sam sposób uzyskiwana wartość błędu testowania kształtowała się na podobnym poziomie. Tylko w przypadku sieci zbudowanych w warstwach ukrytych z neuronów sigmoidalnych i uczonych za pomocą danych otrzymanych z rozkładów CWT scharakteryzowanych wartością skuteczną (nr miary = 14), uzyskiwana wartość błędu testowania przy wykorzystywaniu algorytmu gradientowego była znacznie wyższa niż dla analogicznych rozwiązań przy algorytmie Levenberga-Marquardta.



Rys. 8. Najlepsze wyniki klasyfikacji przy wyborze architektury sieci neuronowej klasyfikującej rodzaj i stopień uszkodzenia zębów uczonej metodą gradientową, falka bazowa nr 9, neurony w warstwach ukrytych typu: (a) sigmoidalnego, (b) tangensoidalnego, A – nr miary = 5, B – nr miary = 14, C – nr miary = 25



Rys. 9. Najlepsze wyniki klasyfikacji przy wyborze architektury sieci neuronowej klasyfikującej rodzaj i stopień uszkodzenia zębów uczonej metodą Levenberga-Marquardta, falka bazowa nr 9, neurony w warstwach ukrytych typu: (a) sigmoidalnego, (b) tangensoidalnego, A – nr miary = 5, B – nr miary = 14, C – nr miary = 25

W kolejnych przeprowadzonych eksperymentach postanowiono sprawdzić przydatność różnych metod uczenia sieci neuronowych MLP. Klasyfikatory z optymalną architekturą dobraną dla metody gradientowej uczone za pomocą 12 metod (tab. 1). Z powodu dużych nakładów czasowych potrzebnych na przeprowadzenie założonych eksperymentów, badania ograniczono tylko do klasyfikatorów uczonych za pomocą wzorców otrzymanych z rozkładów CWT scharakteryzowanych wartością skuteczną (nr miary = 14). Tak zbudowane zestawy wzorców zostały wybrane do dalszych eksperymentów ze względu na uzyskiwane z ich udziałem najniższe wartości błędów testowania.

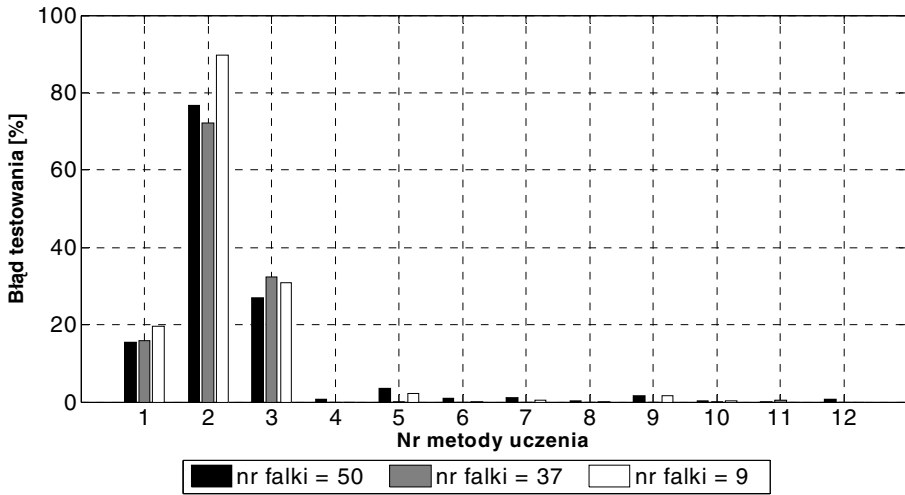
Najlepsze wyniki wraz z podaniem algorytmu uczenia, przy którym były uzyskane przedstawiono w tabeli 3.

W przypadku większości zastosowanych zestawów wzorców udało się zbudować bezbłędne klasyfikatory. Tylko podczas użycia w warstwach ukrytych neuronów typu sigmoidalnego, przy zastosowanej do budowy wzorców falki nr 9, wartość błędu klasyfikacji rodzaju i stopnia uszkodzenia zębów kół była większa od zera. Uzyskane wartości błędów były jednak niewielkie.

Na rysunku 10 przedstawiono przykładowy wpływ wyboru algorytmu uczenia sieci neuronowej na poprawność procesu klasyfikacji rodzaju i stopnia uszkodzenia zębów kół przekładni dla klasyfikatorów zbudowanych dwueta- powo.

Tabela 3. Zestawienie najlepszych klasyfikatorów rodzaju i stopnia uszkodzenia zębów kół (etap 1: dobór optymalnej architektury dla metody gradientowej; etap 2: wybór najlepszej metody uczenia)

Lp.	Nr falki	Nr miary	Nr filtru	Typ neuronów	Liczba neuronów w warstwie ukrytej		Nr algorytmu uczenia	Błąd testowania [%]
					I	II		
1	9	14	1	sigmoidalny	15	25	4,6÷12	0,00
2	9	14	2	sigmoidalny	20	20	6÷12	0,00
3	9	14	3	sigmoidalny	25	25	4,11,12	0,00
4	9	14	4	sigmoidalny	30	20	4,8,12	0,00
5	9	14	5	sigmoidalny	15	30	7,8,10÷12	0,00
6	9	14	1	tangenoidalny	30	10	6÷12	0,00
7	9	14	2	tangenoidalny	30	20	5÷8,10÷12	0,00
8	9	14	3	tangenoidalny	20	30	6,12	0,00
9	9	14	4	tangenoidalny	30	25	7,9,12	0,00
10	9	14	5	tangenoidalny	25	20	6,7,9÷12	0,00
11	37	14	1	sigmoidalny	25	30	4÷12	0,00
12	37	14	2	sigmoidalny	25	15	4÷10,12	0,00
13	37	14	3	sigmoidalny	25	20	4,6÷9,12	0,00
14	37	14	4	sigmoidalny	30	30	4,6÷12	0,00
15	37	14	5	sigmoidalny	30	30	4,6÷12	0,00
16	37	14	1	tangenoidalny	30	0	4÷11	0,00
17	37	14	2	tangenoidalny	30	15	4,6÷12	0,00
18	37	14	3	tangenoidalny	30	25	4,6,8,10÷12	0,00
19	37	14	4	tangenoidalny	30	15	1,4,6÷8,10	0,00
20	37	14	5	tangenoidalny	25	25	4÷12	0,00
21	50	14	1	sigmoidalny	30	30	4÷12	0,00
22	50	14	2	sigmoidalny	30	30	6÷8,10÷12	0,00
23	50	14	3	sigmoidalny	25	25	11	0,21
24	50	14	4	sigmoidalny	30	30	11,12	0,41
25	50	14	5	sigmoidalny	25	30	6÷8,11,12	0,00
26	50	14	1	tangenoidalny	30	25	1,4,6÷12	0,00
27	50	14	2	tangenoidalny	30	25	4÷6,8÷12	0,00
28	50	14	3	tangenoidalny	30	15	10	0,00
29	50	14	4	tangenoidalny	30	25	11	0,00
30	50	14	5	tangenoidalny	20	20	7÷12	0,00



Rys. 10. Przykładowy wpływ algorytmu uczenia na wartość błędu sieci neuronowej typu MLP klasyfikującej rodzaj i stopień uszkodzenia zębów kół, sieć zbudowana z neuronów sigmoidalnych, uczona na danych otrzymanych z rozkładu CWT sygnałów resztkowych (wartość skuteczna), optymalna architektura dobrana dla algorytmu gradientowego

Chcąc zbudować poprawnie działającą sieć neuronową MLP, należy określić jej architekturę oraz algorytm uczenia. Literatura nie podaje gotowych recept doboru tych parametrów, wskazując jednocześnie na konieczność empirycznego podejścia do tych problemów. Znaczna liczba przypadków koniecznych do przetestowania w procesie doboru architektury i metody uczenia sieci mogłaby zostać ograniczona poprzez przyjęcie dwuetapowego podejścia do problemu. W pierwszym etapie dla algorytmu gradientowego (możliwość rozwiązania praktycznie każdego zadania [35]) następowałby dobór architektury, zaś w drugim dla tak dobranej liczby warstw ukrytych i liczby neuronów w nich zawartych następowałby dobór algorytmu uczenia sieci. Przeprowadzone eksperymenty potwierdziły poprawność takiego podejścia. Podejście takie nie jest sprzeczne z gloszoną w literaturze tezą o nierozzerwalności etapu doboru architektury i metody uczenia, gdyż nie mówi się przy tym o dobranej optymalnej architekturze (sensu stricte), a jedynie o parametrach pozwalających uzyskiwać wystarczający poziom błędu testowania. Mając jednak na uwadze fakt, iż eksperymenty tego typu zostały ograniczone ze względów czasowych tylko do danych otrzymanych z rozkładów CWT scharakteryzowanych wartością skuteczną (nr miary = 14), o słuszności zaproponowanego podejścia do projektowania sieci neuronowych MLP będzie można powiedzieć dopiero po przeprowadzeniu dodatkowych badań przy wykorzystaniu danych uczących otrzymanych w inny sposób.

Podsumowanie

W artykule przedstawiono eksperyment mający na celu budowę klasyfikatora rodzaju i stopnia uszkodzenia zębów kół przekładni. Pracę systemu diagnostycznego oparto na danych pochodzących z sygnałów drgań poprzecznych wału koła poddanych odpowiedniej filtracji oraz przetwarzaniu z użyciem ciągłej transformaty falkowej. Sygnały drganiowe zostały zarejestrowane w czasie pracy rzeczywistej przekładni pracującej na stanowisku mocy krążącej.

W wyniku przeprowadzonych badań udało się zbudować poprawnie działający klasyfikator zarówno rodzaju, jak też rodzaju i stopnia uszkodzenia przekładni.

Do budowy klasyfikatorów użyto sztucznych sieci neuronowych typu perceptron wielowarstwowy, dla których dobrano architekturę (liczbę warstw ukrytych, liczbę neuronów w warstwach ukrytych, rodzaj neuronów w warstwach ukrytych) oraz algorytm uczenia.

Na podstawie przeprowadzonych badań można zauważyć, że istotny wpływ na uzyskiwany błąd klasyfikacji ma zarówno sposób przygotowania wzorców uszkodzeń (sposób filtracji, typ zastosowanej falki bazowej, zastosowana miara), jak również architektura i metoda uczenia sztucznych sieci neuronowych.

Bibliografia

1. Bartelmus W., Zimroz R.: Application of self-organised network for supporting condition evaluation of gearboxes. Artificial Intelligence Methods "AI-METH". Gliwice 2004.
2. Barzykowski J., Domańska A., Kujawińska M., Mroczka J., Osowski St., Polański Z., Tłaga W., Turzeniecka D., Winiecki W.: Współczesna metrologia – zagadnienia wybrane. Wydawnictwa Naukowo-Techniczne, Warszawa 2004.
3. Batko W., Ziółko M.: Zastosowanie teorii falek w diagnostyce technicznej. Problemy Inżynierii Mechanicznej i Robotyki. AGH, Kraków 2002.
4. Baydar N., Ball A.: Detection of gear failures via vibration and acoustic signals using wavelet transform. Mechanical Systems and Signal Processing (2003) 17(4), s. 787–804.
5. Białasiewicz J.: Falki i aproksymacje. Wydawnictwa Naukowo-Techniczne. Warszawa 2000.
6. Cempel C.: Diagnostyka wibroakustyczna maszyn. Państwowe Wydawnictwo Naukowe. Warszawa 1989.
7. Chen D., Wang W. J.: Classification of wavelet map pattern using multi-layer neural networks for gear fault detection. Mechanical Systems and Signal Processing (2002) 16(4), s. 695–704.

8. Czech P.: Wykrywanie uszkodzeń przekładni zębatych za pomocą metod sztucznej inteligencji. Rozprawa doktorska. Katowice 2006.
9. Czech P., Łazarz B., Madej H.: Wykorzystanie analizy falkowej i współczynników Hoeldera w identyfikacji pęknięcia stopy zęba przy użyciu neuronowego klasyfikatora SVM (rozdział w monografii pod redakcją Radkowski St.: Degradacja systemów technicznych. Analiza ryzyka i diagnostyka procesów degradacyjnych i zmęzeniowych), Warszawa 2004, s. 165–171.
10. Dalpiaz G., Rivola A., Rubini R.: Effectiveness and sensivity of vibration processing techniques for local fault detection in gears. *Mechanical Systems and Signal Processing* (2000) 14(3), s. 387–412.
11. Dąbrowski Z., Radkowski St., Wilk A.: Dynamika przekładni zębatych. Badania i symulacja w projektowaniu eksploatacyjnie zorientowanym, ITeE, Radom 2000.
12. Gately E.: Sieci neuronowe. Prognozowanie finansowe i projektowanie systemów transakcyjnych. WIG-Press, Warszawa 1999.
13. Hertz J., Krogh A., Palmer R.G.: Wstęp do teorii obliczeń neuronowych. Wydawnictwa Naukowo-Techniczne, Warszawa 1995.
14. Hu Y. H., Hwang J. N.: Handbook of neural network signal processing. CRC Press 2002.
15. Korbicz J., Kościelny J., Kowalczyk Z., Cholewa W. (praca zbiorowa): Diagnostyka procesów. Modele. Metody sztucznej inteligencji. Zastosowania. Wydawnictwa Naukowo-Techniczne, Warszawa 2002.
16. Kosiński R. A.: Sztuczne sieci neuronowe. Dynamika nieliniowa i chaos. Wydawnictwa Naukowo-Techniczne, Warszawa 2002.
17. Kościelny J. M.: Diagnostyka zautomatyzowanych procesów przemysłowych. Akademska Oficyna Wydawnicza EXIT, Warszawa 2001.
18. Lula P.: Jednokierunkowe sieci neuronowe w modelowaniu zjawisk ekonomicznych. Wydawnictwo Akademii Ekonomicznej w Krakowie, Kraków 1999.
19. Łazarz B., Czech P.: Wykorzystanie sieci neuronowych do identyfikacji pęknięcia stopy zęba. *Diagnostyka* Vol. 31, 2004, s. 79–88.
20. 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.
21. Mańdziuk J.: Sieci neuronowe typu Hopfielda. Teoria i przykłady zastosowań. Akademska Oficyna Wydawnicza EXIT, Warszawa 2000.
22. Nałęcz M., Duch W., Korbicz J., Rutkowski L., Tadeusiewicz R.: Sieci neuronowe. Biocybernetyka i Inżynieria Biomedyczna, tom 6. Akademska Oficyna Wydawnicza EXIT, Warszawa 2000.
23. Osowski St.: Sieci neuronowe do przetwarzania informacji. Oficyna Wydawnicza Politechniki Warszawskiej, Warszawa 2000.

24. Osowski St.: Sieci neuronowe w ujęciu algorytmicznym. Wydawnictwa Naukowo-Techniczne, Warszawa 1996.
25. Osowski St., Cichocki A., Siwek K.: Matlab w zastosowaniach do obliczeń obwodowych i przetwarzania sygnałów. Oficyna Wydawnicza Politechniki Warszawskiej, Warszawa 2006.
26. Paya B.A., Esat I.I., Badi M.N.M.: Artificial neural network based fault diagnostics of rotating machinery using wavelet transforms as a preprocessor. *Mechanical Systems and Signal Processing* (1997) 11(5), s. 751–765.
27. Randall R.B.: Detection and diagnosis of incipient bearing failure in helicopter gearboxes. *Engineering Failure Analysis* 11 (2004), s. 177–190.
28. Rutkowska D., Piliński M., Rutkowski L.: Sieci neuronowe, algorytmy genetyczne i systemy rozmyte. Wydawnictwo Naukowe PWN, Warszawa – Łódź 1997.
29. Rymarczyk M.: Decyzje, symulacje, sieci neuronowe. Wydawnictwo Wyższej Szkoły Bankowej, Poznań 1997.
30. Samanta B., Al-Balushi K. R.: Artificial neural network based fault diagnostics of rolling element bearings using time-domain features. *Mechanical Systems and Signal Processing* (2003) 17(2), s. 317–328.
31. Stateczny A., Praczyk T.: Sztuczne sieci neuronowe w rozpoznawaniu obiektów morskich. Gdańskie Towarzystwo Naukowe, Gdynia 2002.
32. Sung C. K., Tai H. M., Chen C. W.: Location defects of gear system by the technique of wavelet transform. *Mechanism and Machine Theory* 35 (2000), s. 1169–1182.
33. Tadeusiewicz R.: Elementarne wprowadzenie do techniki sieci neuronowych z przykładowymi programami. Akademicka Oficyna Wydawnicza PLJ, Warszawa 1998.
34. Tadeusiewicz R.: Sieci neuronowe. Akademicka Oficyna Wydawnicza, Warszawa 1993.
35. Tadeusiewicz R., Lula P.: Wprowadzenie do sieci neuronowych. StatSoft, Kraków 2001.
36. Wang W.Q., Ismail F., Golnaraghi M.F.: Assessment of gear damage monitoring techniques using vibration measurements. *Mechanical Systems and Signal Processing* (2001) 15(5), s. 905–922.
37. Witkowska D.: Sztuczne sieci neuronowe i metody statystyczne. Wybrane zagadnienia finansowe. Wydawnictwo C.H. Beck, Warszawa 2002.
38. Wysogład B.: Metody diagnozowania łożysk tocznych z zastosowaniem transformacji falkowej. *Diagnostyka* Vol. 29, 2004, s. 47–52.
39. Zieliński J. S.: Inteligentne systemy w zarządzaniu. Teoria i praktyka. Wydawnictwo Naukowe PWN, Warszawa 2000.
40. Ziemiański L.: Sieci neuronowe w dynamice konstrukcji. Wybrane zagadnienia. Oficyna Wydawnicza Politechniki Rzeszowskiej, Rzeszów 1999.

41. Żółtowski B., Cempel C. (praca zbiorowa): Inżynieria Diagnostyki Maszyn. Biblioteka Problemów Eksploatacyjnych. Polskie Towarzystwo Diagnostyki Technicznej. Instytut Technologii Eksploatacji – PIB Radom – Warszawa, Bydgoszcz, Radom 2004.
42. Żurada J., Barski M., Jędruch W.: Sztuczne sieci neuronowe. Wydawnictwo Naukowe PWN, Warszawa 1996.

Recenzent:
Stanisław OSOWSKI

Classifier of fault diagnosis in a gear wheel which used MLP neural network and continuous wavelet transform

Key words

Diagnostic testing of toothed gears, artificial intelligent methods, PNN.

Summary

The paper presents the results of an experimental application of an artificial neural network as a classifier of the degree of the cracking root and the chipping tip of the tooth in a gear wheel. The neural classifier was based on the artificial neural network of an MLP type (Multi-Layer Perceptions). The input data for the classifier was in the form of a matrix composed of statistical measures, obtained from continuous wavelet analysis. In order to create a basis of knowledge, a stand testing was done. The experimental tests were conducted in the system operating as circulating power test rigs. As a result, the method of standard construction for diagnostic systems based on artificial intelligence was also worked out by means of defining the ways of filtrating and analysing of signals and diagnostic measurements. Additionally, the choice of the architecture and algorithm of teaching artificial neural networks used to classify the state of an object was researched.

