

## KLASYFIKACJA RODZAJU I STOPNIA USZKODZENIA ZĘBÓW KÓŁ PRZEKŁADNI OPARTA NA CIĄGŁEJ TRANSFORMACIE FALKOWEJ I SIECI NEURONOWEJ TYPU MLP–KONCEPCJA WYKORZYSTANIA DANYCH Z MODELU I RZECZYWISTEJ PRZEKŁADNI

Piotr CZECH, Bogusław ŁAZARZ

Katedra Budowy Pojazdów Samochodowych, Wydział Transportu, Politechnika Śląska  
ul. Krasińskiego 8, 40-019 Katowice, e-mail: [piotr.czech@polsl.pl](mailto:piotr.czech@polsl.pl); [boguslaw.lazarz@polsl.pl](mailto:boguslaw.lazarz@polsl.pl)

### Streszczenie

W opracowaniu przedstawiono wyniki próby zastosowania sztucznej sieci neuronowej jako klasyfikatora rodzaju i stopnia uszkodzenia zębów kół w przekładni. Klasyfikator neuronowy oparto na sztucznej sieci neuronowej typu MLP. Dane wejściowe do klasyfikatora stanowiła macierz złożona z miar statystycznych otrzymanych z ciągłej analizy falkowej. Zidentyfikowany model przekładni zębatej pracującej w układzie napędowym oraz stanowisko mocy krążącej FZG posłużyły do generacji zbiorów uczących i testujących zastosowanych w eksperymencie.

Słowa kluczowe: diagnostyka, przekładnie zębate, sztuczne sieci neuronowe, ciągła transformata falkowa.

### CLASSIFICATION OF KINDS AND DEGREE OF TOOTH GEAR FAIL BY USING CONTINUOUS WAVELET TRANSFORM AND MLP NEURAL NETWORK – CONCEPTION OF USING DATES FROM THE MODEL AND REAL GEARBOX

### Summary

The work presents results of an experiment that employs the artificial neuronal network in the task of identification of kinds and degree of tooth failure. Neural Networks were based on the Multi Layer Perceptrons. Statistical measures that describe the emergence and degree of tooth gear diagnostic served as input data for the artificial neural networks. The measures employed in the experiment were obtained from signals through the continuous wavelet transform. In the experiment the dynamic model of gearbox and power circulating gear testing machine was used as generator of data.

Keywords: diagnostics, gear faults, neural network, continuous wavelet transform.

## 1. WSTĘP

Przekładnie zębate ze względu na ich powszechne stosowanie w układach napędowych są obiektem zainteresowania wielu ośrodków zajmujących się diagnostyką maszyn [5, 7-9, 11-14, 18-21, 26-29, 31-34]. Prowadzone są prace w celu stworzenia odpowiednich narzędzi wspomagających procesy rozpoznawania uszkodzeń, zwłaszcza w ich początkowych stadiach. Różnorodność rozwiązań konstrukcyjnych przekładni i układów napędowych sprawia, że pomimo istnienia różnych algorytmów analizy sygnałów diagnostycznych oraz reguł wnioskowania opracowanych na ich podstawie, stopień pewności diagnozy jest w wielu przypadkach niewystarczający. Spowodowane jest to generowaniem przez różne rodzaje uszkodzeń przekładni podobnych zakłóceń w sygnale wibroakustycznym.

Wykrycie uszkodzenia już we wczesnej fazie może zapobiec uszkodzeniu maszyny i wynikających stąd wysokich strat ekonomicznych,

a w niektórych przypadkach nawet zagrożeniu życia ludzkiego.

Z dotychczasowych badań wynika, że około 60% awarii przekładni zębatych spowodowane jest uszkodzeniem zębów, około 90% tych uszkodzeń to lokalne uszkodzenia, do których należy pęknięcie u podstawy zęba oraz wykruszenie wierzchołka zęba. Głównym celem diagnostyki przekładni jest identyfikacja tych procesów już we wczesnych stadiach. Szczególne znaczenie nabiera tutaj diagnostyka nieinwazyjna, do której należą metody diagnostyki wibroakustycznej [2-5, 7-9, 11-14, 16-21, 24-29, 31-34].

Obecnie coraz częściej zawarte w sygnale symptomy uszkodzenia analizuje się z pomocą metod sztucznej inteligencji [1, 3, 8, 9, 11, 14, 17, 18, 24, 28]. Metody te pozwalają modelować dowolne nieliniowości, charakteryzując się odpornością na zakłócenia oraz zdolnością do uogólniania wiedzy [15, 17, 22, 23, 30].

W artykule przedstawiono wyniki eksperymentu, którego celem było zastosowanie sieci neuronowej typu MLP w zadaniu klasyfikacji

rodzaju i stopnia uszkodzenia zębów kół przekładni [9].

W eksperymencie zaproponowano sposób budowy i uczenia klasyfikatorów neuronowych wykorzystujących wzorce otrzymane z sygnałów drganiowych poddanych odpowiedniej filtracji i przetwarzaniu.

## 2. OBIEKT BADAŃ

Obiektem badań była przekładnia zębata pracująca w układzie napędowym. Parametry przekładni przedstawiono w tabeli 1.

Tabela 1: Parametry przekładni FZG

Parametr	Wartość
liczba zębów zębnika	$z_1 = 16$
liczba zębów koła	$z_2 = 24$
kąt pochylenia linii zębów	$\beta = 0^\circ$
współczynnik przesunięcia zarysu zębnika	$x_1 = 0,8635$
współczynnik przesunięcia zarysu koła	$x_2 = -0,5$
nominalny kąt przyporu	$\alpha = 20^\circ$
moduł nominalny	$m_n = 4,5 \text{ mm}$
czołowy wskaźnik przyporu	$\varepsilon_\alpha = 1,32$
współczynnik wysokości głowy zęba	$h_{ao} = 1$
współczynnik luzu wierzchołkowego	$c_o = 0,25$
szerokość koła	$b = 20 \text{ mm}$

W przeprowadzonych badaniach wykorzystano zidentyfikowany model przekładni zębatej pracującej w układzie napędowym oraz rzeczywistą przekładnię pracującą na stanowisku mocy krążącej FZG.

Wykorzystany w pracy model został opracowany na Wydziale Transportu Politechniki Śląskiej [19]. 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.

W modelu przekładni zębatej symulowano lokalne uszkodzenia zębów w postaci pęknięcia u podstawy zęba i wykruszenia wierzchołka zęba. Ponieważ pęknięciu u podstawy zęba towarzyszy spadek sztywności zazębienia, uszkodzenie tego typu odwzorowano na zasadzie określenia procentowej zmiany sztywności w stosunku do przekładni bezbłędnej. Wykruszenie wierzchołka zęba na całej długości zostało zamodelowane jako skrócenie odcinka przyporu o wartość stanowiącą ustaloną część podziałki. Uwzględniono także

wpływ zmiany długości odcinka przyporu na czas zazębienia.

Obiekt rzeczywisty stanowiła przekładnia zębata pracująca w układzie mocy krążącej, 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 skrętnych. Prędkość pracy przekładni ustalano za pomocą przemiennika częstotliwości sterującego pracą silnika elektrycznego. Przekładnia badana oraz zamykająca posiadały jednakowe przełożenie i jednakowy rozstaw osi.

Na obiekcie rzeczywistym przeprowadzono pomiary drgań poprzecznych wału koła dla przekładni bez uszkodzeń oraz z uszkodzeniami w postaci pęknięcia w stopie zęba i wykruszenia wierzchołka zęba. Pomiarów dokonano dla uszkodzeń w różnym stopniu zaawansowania. Układ pomiarowy składał się z czujników położenia kąтового wałów, jednostki logicznej, wibrometru laserowego, analizatora sygnałów oraz komputera. Pomiaru drgań poprzecznych wału koła dokonano w kierunku siły międzyzębnej za pomocą wibrometru laserowego Ometron VH300+. Zgodnie z [20, 21] wybrano kierunek pomiarów pozwalający najlepiej rejestrować występujące przy uszkodzeniu elementów przekładni modulacje sygnału drganiowego. Jednostka logiczna wraz z dwoma czujnikami położenia kąтового wałów umożliwiła precyzyjne określenie momentu skojarzenia tej samej pary zębów. Zarejestrowany sygnał prędkości drgań oraz sygnał odniesienia z jednostki logicznej był przetwarzany w analizatorze sygnałów DSPT SigLab. Zmierzone sygnały rejestrowano w komputerze PC.

## 3. OPIS EKSPERYMENTU

Odpowiedni dobór i przygotowanie danych wzorcowych, które mają posłużyć do procesu uczenia klasyfikatorów opartych na metodach sztucznej inteligencji, warunkuje poprawność działania finalnego systemu diagnostycznego [1, 3, 9, 14, 15, 17, 22, 23, 30]. W badaniach zdecydowano się na wykorzystanie jako nośnika informacji o stanie obiektu technicznego, sygnału drganiowego emitowanego przez ten obiekt w czasie pracy.

Ponieważ zestaw wzorców musi zawierać dużą liczbę przykładów uczących założono, że nie ma możliwości pozyskania z badań na obiekcie rzeczywistym wystarczającej ich liczby dla wszystkich rodzajów uszkodzeń. W celu pozyskania niezbędnego do dalszych badań ciągu uczącego, zdecydowano się skorzystać z modelu

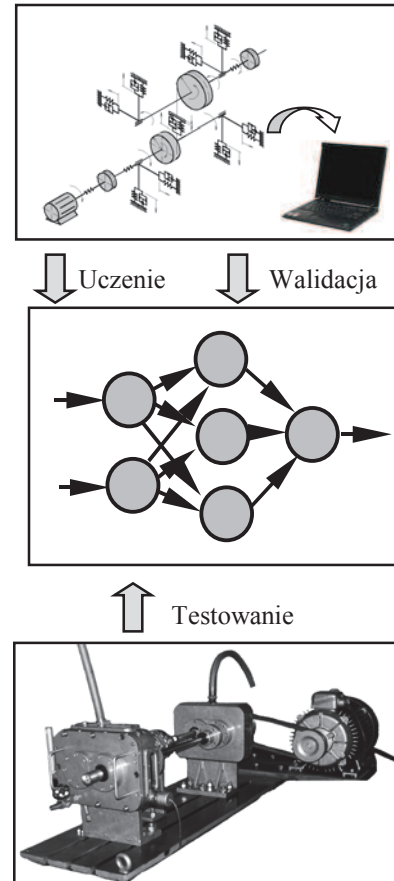
dynamicznego przekładni zębatej pracującej w układzie napędowym [19]. Mając na względzie potrzebny czas na uzyskanie z modelu symulacyjnego wystarczająco licznego wzorca, należało już na początku badań założyć liczbę i rozpiętość diagnozowanych klas uszkodzeń. Założono, że będą rozpoznawane następujące klasy:

- pęknięcie u podstawy zęba w postaci procentowego zmniejszenia sztywności pary zębów w stosunku do nieuszkodzonej przekładni o wartość:
  - klasa 1 ] 0 ÷ 9 %,
  - klasa 2 ] 10 ÷ 19 %,
  - klasa 3 ] 20 ÷ 29 %,
  - klasa 4 ] 30 ÷ 40 %,
- wykruszenie wierzchołka zęba w postaci procentu długości podziałki o jaki zmniejsza się odcinek przyporu w wyniku wystąpienia tego rodzaju uszkodzenia:
  - klasa 5 ] 0 ÷ 9 %,
  - klasa 6 ] 10 ÷ 19 %,
  - klasa 7 ] 20 ÷ 29 %,
  - klasa 8 ] 30 ÷ 40 %.

Konieczność pozyskania wystarczającego i obejmującego wszystkie sklasyfikowane wzorce uszkodzeń zębów kół przekładni zbioru danych wymusiła wielokrotne powtarzanie procesu symulacyjnego na modelu przekładni zębatej. Ponieważ dane uczące powinny obejmować jak najszerszą grupę przypadków dla każdej z klas, ustalono przeprowadzenie symulacji zmieniając co jeden procent wielkość uszkodzeń. Symulacje zostały przeprowadzone dla różnych wartości błędów cyklicznych i losowych zębów kół przekładni. W rezultacie otrzymano 902 sygnały prędkości drgań poprzecznych wału koła przekładni zębatej. Cała seria symulacji została powtórzona dla dwóch prędkości obrotowych wałów i dwóch obciążeń.

W badaniach założono, że klasyfikator neuronowy będzie podlegał uczeniu i walidacji na danych pochodzących z modelu dynamicznego przekładni zębatej, zaś procesowi testowania na danych otrzymanych z rzeczywistej przekładni zębatej (rys. 1).

Celem umożliwienia testowania tak uczonych klasyfikatorów neuronowych określono zależność pomiędzy powstającym pęknięciem, a zmianą sztywności w ząbieniu przekładni zębatej. W tym celu przeprowadzono badania z wykorzystaniem MES, MEB oraz badania doświadczalne na maszynie wytrzymałościowej MTS [9, 10].



Rys. 1. Schemat przyjętej metodologii pracy z klasyfikatorami neuronowymi

#### 4. SPOSÓB BUDOWY WZORCÓW KLAS USZKODZEŃ

Celem eksperymentu było zastosowanie sztucznej sieci neuronowej do oceny rodzaju i stopnia uszkodzenia zębów kół przekładni.

Podstawowym problemem w przypadku użycia sztucznej sieci neuronowej jest odpowiedni dobór danych wejściowych [1, 3, 9, 14, 15, 17, 22, 23, 30].

W eksperymencie postanowiono sprawdzić przydatność jednego z najpopularniejszych i najdynamiczniej rozwijanych obecnie narzędzi analizy sygnałów niestacjonarnych – ciągłej transformaty falkowej [4-6, 8, 9, 11, 16, 17, 20, 24, 25, 29, 33, 34]. Znajduje ona zastosowanie przy analizie sygnałów procesów przejściowych, które często są wynikiem zmienności w czasie parametrów i nieliniowości [4, 6]. Analiza niestacjonarnych sygnałów wymaga posługiwania się oknami, które dla wysokich częstotliwości zostają zawężone, natomiast dla niskich zostają rozszerzone. Podstawową zaletą transformaty falkowej jest kompromis w doborze rozdzielczości w dziedzinie czasu i częstotliwości [4, 6]. Charakteryzuje ją zależność matematyczna:

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

gdzie:

a - współczynnik skali,

b - parametr przesunięcia w dziedzinie czasu.

W eksperymencie wyznaczono ciągłą transformatę falkową dla filtrowanych sygnałów czasowych zawierających składowe w zakresie częstotliwości:


- do 12,8 kHz (nr sygnału = 1),
- do 6,4 kHz (nr sygnału = 2),
- do 6,4 kHz - sygnał różnicowy (nr sygnału = 3),
- do 6,4 kHz - sygnał resztkowy (nr sygnału = 4),
- od 0,5 fz do 1,5 fz (nr sygnału = 5).

Sposób filtracji sygnału pokazano na rys. 2.


W procesie budowy wzorców klas uszkodzeń sprawdzano przydatność 83 falek bazowych należących do rodziny:

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

Celem opisu charakteru zmian amplitudy sygnału poddanego działaniu ciągłej transformaty falkowej dla 20 wybranych we wstępnej analizie skal wyznaczono miarę statystyczną. Miara ta opisywała przebieg zmian amplitudy rozkładu CWT w dziedzinie czasu. Sprawdzone przydatność 35 miar. Sposób postępowania został przedstawiony na rys. 3.



Rys. 2. Sposoby filtracji sygnału umożliwiające uzyskanie: (a) — sygnału różnicowego, --- sygnału resztkowego, (b) ..... sygnału z pasma częstotliwości  $\langle \frac{1}{2} f_z, \frac{3}{2} f_z \rangle$



Rys. 3. Sposób pozyskania danych wejściowych dla sztucznych sieci neuronowych

W tabeli 2 przedstawiono wybrane na podstawie badań wstępnych falki bazowe oraz miary [9].

Tabela 2: Wybrane miary i 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

## 5. Wyniki eksperymentu

Badania skuteczności diagnozowania rodzaju i stopnia uszkodzenia zębów kół przekładni przy wykorzystaniu klasyfikatora neuronowego przeprowadzono przy wykorzystaniu sieci neuronowej typu perceptron wielowarstwowy (MLP).

Na rys. 4 przedstawiono schemat sieci neuronowej wykorzystywanej w badaniach. Eksperymenty podzielono na dwie części. Celem pierwszej było określenie najlepszej architektury sieci. Badano wariant sieci z jedną oraz z dwoma warstwami ukrytymi. W każdym z przypadków sprawdzano wpływ liczby neuronów na poziom uzyskiwanej zgodności odpowiedzi klasyfikatora z wzorcem. Na podstawie badań wstępnych założono dla każdej warstwy ukrytej możliwość występowania 5, 10, 15, 20, 25 i 30 neuronów. Do pierwszej części eksperymentu wybrano metodę uczenia sieci MLP za pomocą algorytmu gradientowego. Wybór stanowił kompromis pomiędzy szybkością działania algorytmu, a wielkością błędu klasyfikacji tak nauczonej sieci neuronowej. W drugim etapie przeprowadzonych eksperymentów klasyfikatory MLP z dobraną architekturą umożliwiającą uzyskiwanie najniższej wartości błędów uczono za pomocą 12 różnych metod (tabela 3). Sprawdzano jaki wpływ na poprawność uzyskiwanych wyników ma zastosowany algorytm uczenia sieci. Wszystkie eksperymenty z wykorzystaniem sieci neuronowych typu MLP zostały przeprowadzone dwukrotnie, dla klasyfikatorów zbudowanych w warstwach ukrytych z neuronów sigmoidalnych i tangensooidalnych.

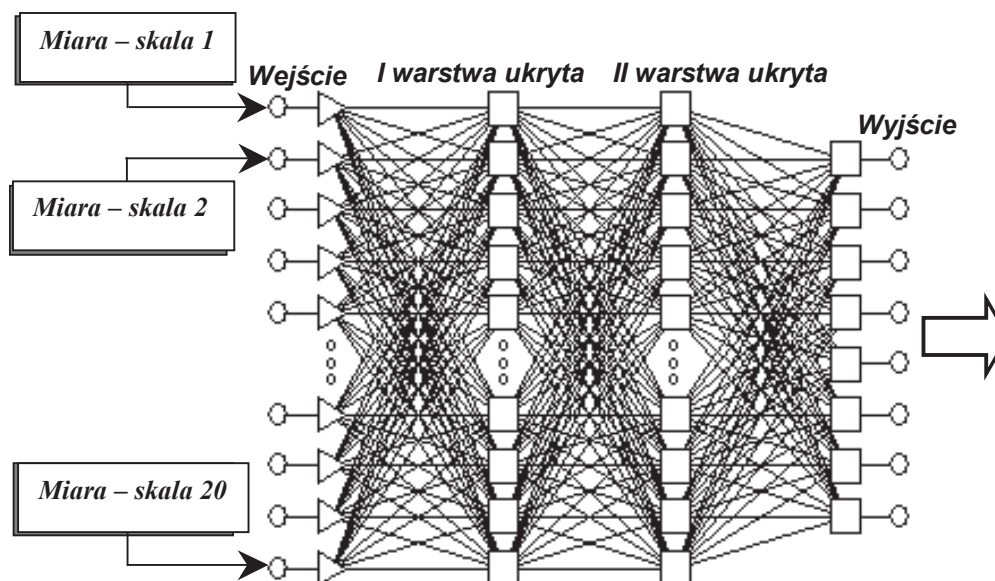
Tabela 3: Algorytmy uczenia sieci MLP

Nr algorytmu	Typ algorytmu
1	Algorytm gradientowy
2	Algorytm gradientowy ze współczynnikiem momentum
3	Algorytm gradientowy ze współczynnikiem momentum i adaptacyjnie dobiernym 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

Przy doborze złożoności sieci zaobserwowano, iż 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. Uzyskiwane wyniki pozwalają również zauważyć 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 jednak w procesie sprawdzenia uogólnić tej wiedzy na podobne wzorce.

Otrzymane wyniki wskazują na znaczącą rolę doboru algorytmu uczenia sieci neuronowej typu MLP. Najniższymi wartościami błędu klasyfikacji stopnia uszkodzenia przekładni charakteryzowały się sieci neuronowe uczone przy wykorzystaniu metody uczenia nr 11 i 12 (tabela 3). Dla tych wariantów budowy klasyfikatorów wartości błędu są nawet do kilkudziesięciu razy niższe, niż w przypadku stosowania najmniej efektywnego algorytmu uczenia sieci.

Po zakończeniu procesu doboru architektury sieci oraz algorytmu uczenia przystąpiono do testowania tak zbudowanych klasyfikatorów. Proces testowania polegał na ostatecznym sprawdzeniu poprawności działania klasyfikatora na danych pochodzących z sygnałów drganiowych zarejestrowanych na rzeczywistej przekładni. Proces



Rys. 4. Schemat sieci neuronowej typu MLP wykorzystywanej w badaniach

postępowania był zgodny z przyjętą w badaniach metodologią (rys. 1).

W wyniku ostatecznego sprawdzenia klasyfikatorów neuronowych uczonych za pomocą danych otrzymanych z modelu symulacyjnego przekładni zębatej okazało się, że założenia odnośnie takiego sposobu budowy systemów diagnostycznych są błędne.


Niezależnie od sposobu budowy wzorców błąd testowania na danych pochodzących z rzeczywistej przekładni nie osiągał niższej wartości niż 65%.

Niepowodzenie eksperymentu spowodowało, iż zdecydowano się zmienić założenia odnośnie procesu uczenia i walidacji klasyfikatorów neuronowych. Do uczenia i walidacji klasyfikatorów rodzaju oraz stopnia uszkodzenia zębów kół przekładni postanowiono oprócz danych pochodzących z modelu dynamicznego przekładni dodać część danych pochodzących z badań na obiekcie rzeczywistym przekładni. Tak uczone klasyfikatory testowano na pozostałej części danych otrzymanych z rzeczywistej przekładni zębatej. Wyniki uzyskane dla tak zbudowanych

klasyfikatorów neuronowych diagnozujących rodzaj i stopień uszkodzenia zębów kół przekładni przedstawiono na rys. 5.

Dla wszystkich wariantów przebadanych zestawów wzorców uzyskano niższe wartości błędu testowania niż dla klasyfikatorów neuronowych uczonych tylko na danych pochodzących z modelu przekładni zębatej. Najlepsze rezultaty poprawności diagnozy stanu zębów kół odnotowano dla klasyfikatorów wykorzystujących wzorce otrzymane przy użyciu filtru nr 2. W tym przypadku zarówno dla sieci neuronowych zbudowanych w warstwach ukrytych z neuronów typu sigmoidalnego, jak również tangensoidalnego, najniższy błąd testowania wynosił 20,19%.

**Przeprowadzone badania pokazały, że możliwe jest zbudowanie klasyfikatora neuronowego dwóch rodzajów uszkodzeń zębów kół w różnych stanach zaawansowania dla przekładni pracującej z różnymi prędkościami obrotowymi wałów oraz pod różnym momentem obciążenia.**



Rys. 5. Najlepsze uzyskane wyniki procesu testowania dla klasyfikatorów neuronowych typu MLP zbudowanych w warstwach ukrytych z neuronów typu: a – sigmoidalnego, b – tangensoidalnego

## 5. PODSUMOWANIE

Stosując systemy ekspertowe wykorzystujące metody sztucznej inteligencji, należy pozyskać odpowiednio liczną bazę danych dotyczących diagnozowanych uszkodzeń o różnym typie i stopniu zaawansowania. W literaturze można zauważyć rozwijaną w ostatnich latach tendencję wykorzystywania modeli rzeczywistych obiektów w procesach opracowywania narzędzi diagnostycznych [2, 9, 13, 17, 19, 34]. 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.

Przy wykorzystaniu metod sztucznej inteligencji do celów diagnostycznych, istotnym problemem jest dobór danych, na podstawie których system diagnozowałby stan obiektu. Należy jednak zaznaczyć, że nie istnieją jednak gotowe schematy pozwalające na ich najwłaściwszy wybór, a wręcz literatura wskazuje na konieczność empirycznego podejścia do każdego z przypadków.

W artykule przedstawiono wyniki eksperymentu mającego na celu stworzenie klasyfikatora neuronowego diagnozujące rodzaj i stopień uszkodzeń zębów kół przekładni. Na podstawie uzyskanych wyników można wysunąć tezę o słuszności wykorzystywania modeli obiektów w procesie uczenia sieci neuronowych klasyfikujących uszkodzenia występujące w rzeczywistych obiektach.

Wyniki uzyskane w pracy [9] wskazują na możliwość znacznej poprawy pracy klasyfikatora wykorzystującego dane pochodzące z modelu oraz z rzeczywistej przekładni. Można to uzyskać poprzez zastosowanie podziału zadań w zespole sieci neuronowych. W tym przypadku każda sieć neuronowa odpowiedzialna jest za diagnozowanie jednego rodzaju uszkodzenia zębów kół przekładni pracującej w danym jednym punkcie pracy (przy jednej prędkości i jednym obciążeniu).

Kolejną możliwością poprawy uzyskiwanych wyników jest identyfikacja i uwzględnienia w modelu dodatkowych zjawisk.

### Literatura

- [1] Adamczyk J., Cioch W., Krzyworzeka P.: *Możliwości neuronowej klasyfikacji stanu w zmiennych warunkach pracy obiektu*, ZEM, Z. 2, Vol. 34, Radom, 1999.
- [2] Bartelmus W.: *Mathematical modelling and computer simulations as an aid to gearbox diagnostics*. Mechanical Systems and Signal Processing 15(5)/2001.
- [3] Bartelmus W., Zimroz R.: *Application of self-organised network for supporting condition*

- evaluation of gearboxes*. Artificial Intelligence Methods "AI-METH". Gliwice 2004.
- [4] Batko W., Ziółko M.: *Zastosowanie teorii falek w diagnostyce technicznej*. AGH, Kraków 2002.
- [5] Baydar N., Ball A.: *Detection of gear failures via vibration and acoustic signals using wavelet transform*. Mechanical Systems and Signal Processing 17(4)/2003.
- [6] Białasiewicz J.: *Falki i aproksymacje*. WNT. Warszawa 2000.
- [7] Cempel C.: *Diagnostyka wibroakustyczna maszyn*, Państwowe Wydawnictwo Naukowe, Warszawa 1989.
- [8] 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).
- [9] Czech P.: *Wykrywanie uszkodzeń przekładni zębatych za pomocą metod sztucznej inteligencji*. Rozprawa doktorska. Katowice 2006.
- [10] Czech P., Folega P.: *Doświadczalne wyznaczanie sztywności zębów kół*. Zeszyty Naukowe Politechniki Śląskiej s. Transport, z. 57. Gliwice 2005.
- [11] 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.
- [12] 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).
- [13] Dąbrowski Z., Radkowski St., Wilk A.: *Dynamika przekładni zębatych. Badania i symulacja w projektowaniu eksploatacyjnie zorientowanym*. ITE 2000.
- [14] Dybała J., Radkowski S.: *Geometrical method of selection of features of diagnostic signals*. Mechanical Systems and Signal Processing 21(2)/2007.
- [15] Hu Y. H., Hwang J. N.: *Handbook of neural network signal processing*. CRC Press 2002.
- [16] Kim H., Melhem H.: *Damage detection of structures by wavelet analysis*. Mechanical Systems and Signal Processing 26/2004.
- [17] Korbicz J., Kościelny J., Kowalczyk Z., Cholewa W.: *Diagnostyka procesów. Modele. Metody sztucznej inteligencji. Zastosowania*, Wydawnictwo Naukowo-Techniczne, Warszawa 2002.
- [18] Łazarz B., Czech P.: *Wykorzystanie sieci neuronowej do identyfikacji pęknięcia stopy zęba*, Diagnostyka' 31, 2004.

- [19] Łazarz B.: *Zidentyfikowany model dynamiczny przekładni zębatej jako podstawa projektowania*, Biblioteka Problemów Eksploatacji, Katowice-Radom 2001.
- [20] Łazarz B., Wojnar G.: *Wykorzystanie analizy falkowej w diagnozowaniu lokalnych uszkodzeń kół zębatych*. Diagnostyka '30. 2004.
- [21] Madej H.: *Wykorzystanie sygnału resztkowego drgań w diagnostyce przekładni zębatych*. Diagnostyka Vol. 26, 2002.
- [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 S.: *Sieci neuronowe do przetwarzania informacji*, Oficyna Wydawnicza Politechniki Warszawskiej, Warszawa 2000.
- [24] 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).
- [25] Peng Z. K., Chu F. L.: *Application of the wavelet transform in machine condition monitoring and fault diagnostics*. Mechanical Systems and Signal Processing 18/2004.
- [26] Radkowski S.: *Wibroakustyczna diagnostyka uszkodzeń niskoenergetycznych*, Biblioteka Problemów Eksploatacyjnych, Warszawa-Radom 2002.
- [27] Randall R. B.: *Detection and diagnosis of incipient bearing failure in helicopter gearboxes*. Engineering Failure Analysis 11 (2004).
- [28] 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).
- [29] 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).
- [30] Tadeusiewicz R.: *Sieci neuronowe*, Akademska Oficyna Wydawnicza, Warszawa 1993.
- [31] 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).
- [32] Wilk A., Łazarz B., Madej H.: *Vibration Processing Techniques for Fault Detection in Gearboxes*, Proceedings of DETC'2003 ASME 2003 Design Engineering Technical Conferences and Computers and Information in Engineering Conference Chicago, Illinois, USA, 2003.
- [33] Zheng H., Li Z., Chen X.: *Gear fault diagnosis based on continuous wavelet transform*. Mechanical Systems and Signal Processing 16(2-3)/2002.
- [34] 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.



Dr inż. **Piotr CZECH** jest adiunktem w Katedrze Budowy Pojazdów Samochodowych Wydziału Transportu Politechniki Śląskiej. Rozprawę doktorską pt.: „Wykrywanie uszkodzeń przekładni zębatych za pomocą metod sztucznej inteligencji” obronił

z wyróżnieniem. W pracy naukowej zajmuje się wykorzystaniem metod sztucznej inteligencji (sieci neuronowych, logiki rozmytej, algorytmów genetycznych) oraz metod przetwarzania sygnałów w diagnostyce elementów układów napędowych.



Dr hab. inż. **Bogusław ŁAZARZ** jest profesorem nzw. w Katedrze Budowy Pojazdów Samochodowych Wydziału Transportu Politechniki Śląskiej. Specjalizuje się w zakresie diagnostyki wibroakustycznej przekładni zębatych, modelowania i wspomaganego komputerowo

projektowania układów przeniesienia napędu z przekładnią zębatą oraz metod przetwarzania sygnałów. Członek Polskiego Towarzystwa Diagnostyki Technicznej i Sekcji Podstaw Eksploatacji Komitetu Budowy Maszyn.

*Praca naukowa finansowana ze środków na naukę w latach 2006-2009 jako projekt badawczy 4T07B00230.*