

## WYKORZYSTANIE SIECI NEURONOWYCH DO IDENTYFIKACJI PĘKNIĘCIA STOPY ZĘBA

Bogusław ŁAZARZ, Piotr CZECH

Katedra Budowy Pojazdów Samochodowych, Wydział Transportu, Politechnika Śląska  
ul. Krasińskiego 8, 40-019 Katowice, e-mail: [łazarz@polsl.katowice.pl](mailto:łazarz@polsl.katowice.pl), [pczech@polsl.katowice.pl](mailto:pczech@polsl.katowice.pl)

### Streszczenie

W opracowaniu przedstawiono wyniki eksperymentu mającego na celu próbę zastosowania sztucznej sieci neuronowej jako klasyfikatora stopnia podcięcia zęba w przekładni zębatej. Klasyfikator neuronowy oparto na sztucznej sieci neuronowej typu SVM z jądrem radialnym. Dane wejściowe do klasyfikatora stanowiła macierz złożona z miar statystycznych. Zidentyfikowany model przekładni zębatej stanowiska FZG posłużył do generacji zbioru uczącego i testującego zastosowanego w eksperymencie.

Słowa kluczowe: diagnostyka, przekładnie zębate, sztuczne sieci neuronowe.

### AN IDENTIFICATION OF THE DEGREE OF THE TOOTH ROOT CRACKING USING THE ARTIFICIAL NEURAL NETWORK

#### 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. Neural Networks were based on the Support Vector Machine and the radial basis function kernel has been chosen in the experiments. 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 application of a variety of processing methods.

Keywords: diagnostics, gear faults, neural network.

## 1. WSTĘP

Szybki i wielokierunkowy rozwój metodologii diagnostycznej w ostatnich latach spowodował powstanie nowych metod stosowanych w systemach lokalizacji uszkodzeń oraz rozpoznawania stanu obiektów [12,29,33]. Zaczęto interesować się zastosowaniem sztucznej inteligencji w diagnozowaniu stanu urządzeń [1,2,11,4]. Jedną z metod należącą do tej grupy są sztuczne sieci neuronowe, które znajdują zastosowanie

w coraz to nowych obszarach wiedzy. Sieci neuronowe należą do wyrafinowanych technik modelowania, zdolnych do odwzorowania nadzwyczaj złożonych funkcji z dużą liczbą zmiennych niezależnych [25,31].

Zasada działania sztucznych sieci neuronowych oparta jest na egzekwowaniu wiedzy, w którą została ona zaopatrzona w procesie uczenia [25,31]. W procesie tym zostają pokazane kolejno dane, które sieć w procesie uczenia uogólnia. Nauczona sztuczna sieć neuronowa korzysta ze swojej wiedzy na zasadzie asocjacji, podobnie jak dzieje się to w mózgu człowieka [24].

Sztuczna sieć neuronowa składa się z połączonych ze sobą elementów, zwanych

neuronami. Aby doszło do uczenia każdemu z neuronów muszą zostać pokazane dane uczące, od których jakości zależą późniejsze efekty otrzymane w wyniku działania sieci neuronowych.

W literaturze można spotkać się z wieloma typami sztucznych sieci neuronowych [24,25,31]. Struktury sieci neuronowe można podzielić ze względu na typ problemu do jakiego zostały one użyte. Należą do nich następujące zadania [31]:

- klasyfikacji → podział na kategorie według kryteriów,
- klasteryzacji → klasyfikacja bezwzorcowa,
- aproksymacji → zadania regresyjne,
- prognozowania → przewidywanie zjawisk w przyszłości na podstawie danych retrospekcyjnych.

Ze względu na sposób uczenia sztuczne sieci neuronowe dzielą się na samoorganizujące (uczone bez nauczyciela) oraz na uczone z nauczycielem. Zasada nauki z nauczycielem opiera się na fakcie, że w trakcie procesu uczenia, sieci oprócz danych wejściowych (symptomów) zostaje pokazany stan jej wyjść. Proces uczenia opiera się w tym przypadku na minimalizacji błędu między uzyskaną z sieci neuronowej wartością na wyjściu, a jej wartością oczekiwaną [25,31].

Zgodnie ze sposobem przepływu danych w sieciach neuronowych można je podzielić na sieci jednokierunkowe i sieci ze sprzężeniem zwrotnym (rekurencyjne) [25,31]. W sieciach jednokierunkowych informacja przebiega od wejść sieci do jej wyjść, natomiast w sieciach ze sprzężeniem zwrotnym stan wyjść neuronów może być źródłem danych wejściowych podawanych na wcześniejsze warstwy sieci.

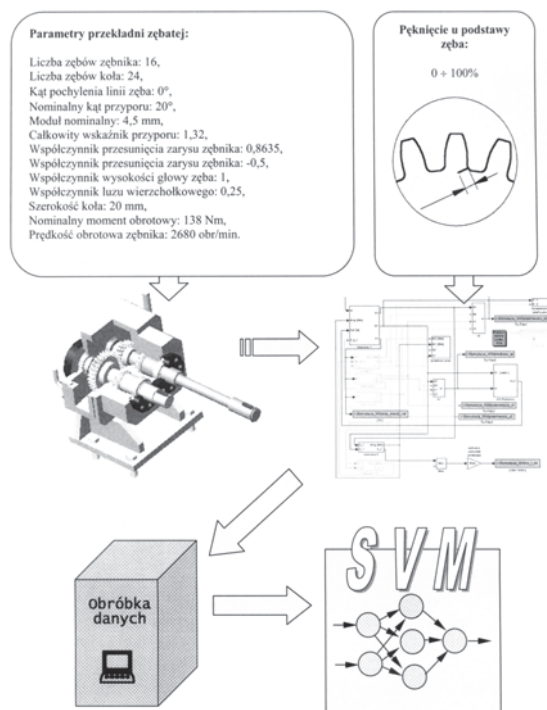
W przeprowadzonym eksperymencie postanowiono sprawdzić, czy miary statystyczne pozwolą dobrze określić związki między sygnałami diagnostycznymi (symptomami) a stanem maszyny roboczej [3,11,29,33,34] oraz czy można je z powodzeniem stosować w zadaniach klasyfikacji i regresji w sieciach neuronowych.

## 2. OBIEKT BADAŃ

Celem eksperymentu była próba zastosowania klasyfikatora neuronowego, dla którego miary statystyczne stanowiły dane wejściowe.

W badaniach posłużono się zidentyfikowanym modelem przekładni zębatej pracującej w układzie mocy krążącej [15]. Model ten posłużył do generacji sygnałów będących podstawą otrzymania danych wejściowych dla klasyfikatora neuronowego.

Schemat przeprowadzonego eksperymentu przedstawia rysunek 1.



Rys. 1. Metodologia przeprowadzania eksperymentu

Parametry badanej przekładni:

- koła zębate o zębach prostych,
- liczba zębów zębnika:  $z_1 = 16$ ,

- liczba zębów koła:  $z_2 = 24$ ,
- współczynnik przesunięcia zarysu zębnika:  $x_1 = 0,8635$ ,
- współczynnik przesunięcia zarysu koła:  $x_2 = -0,5$ ,
- nominalny kąt przyporu:  $\alpha = 20^\circ$ ,
- moduł nominalny:  $m_n = 4,5$  mm,
- całkowity wskaźnik przyporu:  $\varepsilon_\alpha = 1,32$ ,
- współczynnik wysokości głowy zęba:  $h_{a0} = 1$ ,
- współczynnik luzu wierzchołkowego:  $c_0 = 0,25$ ,
- szerokość koła:  $b = 20$  mm,
- nominalny moment obrotowy:  $M = 138$  Nm,
- prędkość obrotowa zębnika:  $n = 2680$  obr/min.

Zidentyfikowany model przekładni posłużył do symulacji przyspieszeń poprzecznych drgań wału zębnika przy różnym stopniu rozwoju pęknięcia u podstawy zęba [16]. Symulowanie pęknięcia zęba u podstawy polegało na obniżeniu jego sztywności o ustaloną wartość w stosunku do sztywności zęba nieuszkodzonego.

Symulacje zostały podzielone na trzy serie:

- 1) seria pierwsza:
  - odchyłka cykliczna dla zębnika:  $0 \mu\text{m}$ /długość podziałki,
  - odchyłka cykliczna dla koła:  $0 \mu\text{m}$ /długość podziałki,
  - odchyłka losowa  $\rightarrow$  maksymalny błąd wykonania zębnika:  $0 \mu\text{m}$ ,
  - odchyłka losowa  $\rightarrow$  maksymalny błąd wykonania koła:  $0 \mu\text{m}$ ,
- 2) seria druga:
  - odchyłka cykliczna dla zębnika:  $-7 \mu\text{m}$ /długość podziałki,
  - odchyłka cykliczna dla koła:  $5 \mu\text{m}$ /długość podziałki,
  - odchyłka losowa  $\rightarrow$  maksymalny błąd wykonania zębnika:  $\pm 4,5 \mu\text{m}$ ,
  - odchyłka losowa  $\rightarrow$  maksymalny błąd wykonania koła:  $\pm 4,5 \mu\text{m}$ ,
- 3) seria trzecia:
  - odchyłka cykliczna dla zębnika:  $-14 \mu\text{m}$ /długość podziałki,
  - odchyłka cykliczna dla koła:  $10 \mu\text{m}$ /długość podziałki,
  - odchyłka losowa  $\rightarrow$  maksymalny błąd wykonania zębnika:  $\pm 9 \mu\text{m}$ ,
  - odchyłka losowa  $\rightarrow$  maksymalny błąd wykonania koła:  $\pm 9 \mu\text{m}$ .

W pierwszej serii pomiarowej zasymulowano pracę bezbłędną przekładni zębatej. Seria druga i trzecia to wyniki dla przekładni wykonanej dokładnie oraz przekładni z kołami zębatymi z podwyższoną wartością błędów wykonania.

W celu sprawdzenia powtarzalności wyników serię drugą i trzecią powtórzono pięciokrotnie przy różnych błędach losowych.

Każdą symulację przeprowadzono dla uszkodzenia zęba w postaci podcięcia jego podstawy w zakresie od 0 do 100%. W sumie otrzymano 1111 symulacji.

### 3. MIARY DIAGNOSTYCZNE


Diagnostyka wibroakustyczna wykorzystuje jako źródło informacji o stanie badanego obiektu parametry dynamiczne generowane w trakcie powstania i propagacji uszkodzenia [3,29,32,33,34].

W eksperymencie za źródło informacji przyjęto sygnał czasowy przyspieszeń poprzecznych drgań wału zębniaka [17].

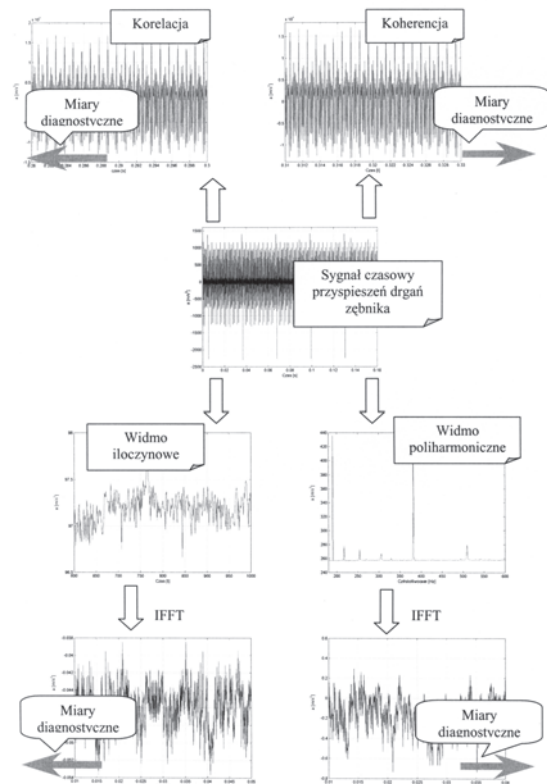
Za miary określające wystąpienie i stopień uszkodzenia przyjęto miary statystyczne (miary położenia, miary zróżnicowania, miary asymetrii i kurtozy) [5,6,7,9,14,18,21,22,23,28,32,34,36]. Użyte miary należą zarówno do estymat prostych (miar punktowych) oraz estymat specjalnych (dyskryminant) [3].

W badaniach wyznaczono następujące miary:

- wartość skuteczną (RMS),
- wartość szczytową (peak),
- maksimum,
- minimum,
- średnią arytmetyczną (moment centralny rzędu pierwszego),
- średnią geometryczną,
- średnią harmoniczną,
- odchylenie standardowe (obciążone, nieobciążone),
- wariacje obciążoną (moment centralny rzędu drugiego),
- wariacje nieobciążoną (moment centralny rzędu drugiego),
- kwartył pierwszy,
- kwartył drugi (mediana),
- kwartył trzeci,
- odchylenie ćwiartkowe,
- pozycyjny współczynnik zmienności,
- odchylenie przeciętne,
- współczynnik zmienności (obciążony, nieobciążony),
- momenty centralne rzędu 3 ÷ 10,
- współczynnik skupienia (kurtozę, kurtozę standaryzowaną),
- współczynnik asymetrii (standaryzowany),
- współczynnik kształtu,
- współczynnik impulsowości,
- współczynnik luzu,
- współczynnik szczytu,
- dyskryminantę X0 (FM0),
- dyskryminantę X4 (FM4, NA4, NB4),
- dyskryminantę X6 (M6A),
- dyskryminantę X8 (M8A),
- dyskryminantę X10 (M10A),
- energię sygnału,
- bilans energetyczny.



Rys. 2. Metodologia wyznaczania miar diagnostycznych (I)



Rys. 3. Metodologia wyznaczania miar diagnostycznych (II)

Poszczególne miary były wyznaczone dla sygnałów czasowych przyspieszeń poprzecznych drgań wału zębniaka (rys. 2 i 3) [17].

Uzyskane z symulacji sygnały poddano dalszej obróbce uzyskując sygnały czasowe [7,18,21,22,23,32,36]:

- z widma przyspieszeń drgań w całym zakresie częstotliwości (nr porz. 1),
- z widma przyspieszeń drgań w zakresie od 0 do 6 kHz (nr porz. 2),
- z widma przyspieszeń drgań w zakresie od 0 do 6 kHz sygnału różnicowego (nr porz. 3),
- z widma przyspieszeń drgań w zakresie od 0 do 6 kHz z sygnału resztkowego (nr porz. 4),
- z widma przyspieszeń drgań w zakresie od  $\frac{1}{2}f_z$  do  $\frac{3}{2}f_z$  (nr porz. 5),
- z widma obwiedni przyspieszeń drgań w całym zakresie częstotliwości (nr porz. 6),
- z widma obwiedni przyspieszeń drgań w zakresie od 0 do 6 kHz (nr porz. 7),
- z widma obwiedni przyspieszeń drgań w zakresie od 0 do 6 kHz sygnału różnicowego (nr porz. 8),
- z widma obwiedni przyspieszeń drgań w zakresie od 0 do 6 kHz z sygnału resztkowego (nr porz. 9),
- z widma obwiedni przyspieszeń drgań w zakresie od  $\frac{1}{2}f_z$  do  $\frac{3}{2}f_z$  (nr porz. 10),
- z widma poliharmonicznego przyspieszeń drgań w zakresie od 0 do 6 kHz (nr porz. 11),
- z widma poliharmonicznego przyspieszeń drgań w zakresie od 0 do 6 kHz sygnału różnicowego (nr porz. 12),
- z widma poliharmonicznego przyspieszeń drgań w zakresie od 0 do 6 kHz z sygnału resztkowego (nr porz. 13),
- z widma iloczynowego przyspieszeń drgań w zakresie od 0 do 6 kHz (nr porz. 14),
- z widma iloczynowego przyspieszeń drgań w zakresie od 0 do 6 kHz sygnału różnicowego (nr porz. 15),
- z widma iloczynowego przyspieszeń drgań w zakresie od 0 do 6 kHz z sygnału resztkowego (nr porz. 16),
- korelacji sygnału czasowego uzyskanego z widma przyspieszeń drgań w zakresie od 0 do 6 kHz (nr porz. 17),
- korelacji sygnału czasowego uzyskanego z widma przyspieszeń drgań w zakresie od 0 do 6 kHz sygnału różnicowego (nr porz. 18),
- korelacji sygnału czasowego uzyskanego z widma przyspieszeń drgań w zakresie od

0 do 6 kHz z sygnału resztkowego (nr porz. 19),

- kowariancji sygnału czasowego uzyskanego z widma przyspieszeń drgań w zakresie od 0 do 6 kHz (nr porz. 20),
- kowariancji sygnału czasowego uzyskanego z widma przyspieszeń drgań w zakresie od 0 do 6 kHz sygnału różnicowego (nr porz. 21),
- kowariancji sygnału czasowego uzyskanego z widma przyspieszeń drgań w zakresie od 0 do 6 kHz z sygnału resztkowego (nr porz. 22).

Sygnał resztkowy otrzymano usuwając z jego widma pasma zawierające składowe obrotowe wałów kół oraz składowe częstotliwości zazębienia i jej harmonicznych.

Sygnał różnicowy otrzymano poprzez dodatkowe usunięcie z widma wokół częstotliwości zazębienia wstęg bocznych związanych z częstotliwościami obrotowymi kół zębatych [18,22,23].

#### **4. DOBÓR DANYCH WEJŚCIOWYCH, TYPU I ARCHITEKTURY SZTUCZNEJ SIECI NEURONOWEJ UŻYTEJ W EKSPERYMENCIE**

W przeprowadzonym eksperymencie postanowiono sprawdzić przydatność wykorzystania metody sztucznej inteligencji w diagnozowaniu stopnia podcięcia zęba w przekładni zębatych.

W literaturze można spotkać udane eksperymenty mające na celu wykorzystanie metod sztucznej inteligencji w diagnostyce stanu maszyn [1,2,4,8,10,11,13,28,35,36].

Podstawowym problemem w przypadku zastosowania sztucznych sieci neuronowych jest dobór danych wejściowych, w których będą zapisane niezbędne dane umożliwiające sieci prawidłową klasyfikację obiektów.

W eksperymencie za dane wejściowe do sieci neuronowej zostały wybrane miary statystyczne uzyskane z przebiegów przyspieszeń poprzecznych drgań wału zębniaka.

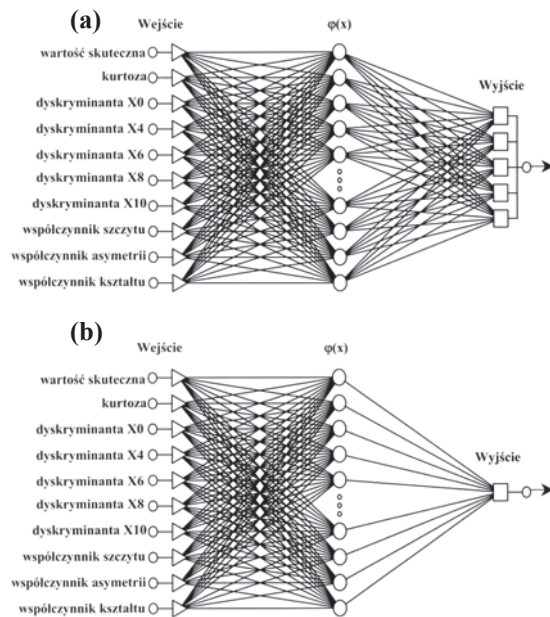
Korzystając z tych miar podjęto próbę utworzenia zbioru parametrów diagnostycznych, które mogłyby być wykorzystane do klasyfikacji stopnia podcięcia zęba [29].

Przestrzeń klasyfikacyjna reprezentowana była przez macierz utworzoną z wyznaczonych miar, które charakteryzowały się największą wrażliwością:

- wartość skuteczną,
- kurtozę,
- dyskryminantę X0,
- dyskryminantę X4,
- dyskryminantę X6,
- dyskryminantę X8,

- dyskryminantę X10,
- współczynnik szczytu,
- współczynnik asymetrii,
- współczynnik kształtu.

W badaniach wykorzystano sztuczną sieć neuronową typu SVM (Support Vector Machine) [19,26,27]. Sieć ta należy do sieci jednokierunkowych. Sieci te mają najczęściej budowę dwuwarstwową i posiadają warstwę ukrytą i wyjściową (rys. 4).



Rys. 4. Struktura sztucznej sieci neuronowej typu SVM w zadaniu: (a) klasyfikacji, (b) regresji

Za funkcję aktywacji  $\phi(x)$  w tym typie sieci można przyjąć:

- funkcję liniową,
- funkcję wielomianową,
- funkcję radialną,
- funkcję sigmoidalną.

W eksperymencie badawczym jako funkcję aktywacji przyjęto funkcję radialną.

Sieci neuronowe typu SVM wymagają uczenia z nauczycielem [25,31]. Do algorytmów uczenia tego typu sieci neuronowych należą strategie „jeden przeciw wszystkim”, „jeden przeciw jednemu” oraz ich kombinacje [26,27].

Problem klasyfikacji wzorców nie separalnych liniowo sprowadza się do określenia takiej optymalnej hiperpłaszczyzny, która zminimalizuje prawdopodobieństwo wystąpienia błędu klasyfikacji na zbiorze uczącym z możliwie najszerszym marginesem separacji.

W celu zmniejszenia błędu zmieniano następujące współczynniki sieci SVM:

- szerokości marginesu błędu uczenia i testowania sieci ( $\epsilon$ ),
- kosztu (C),

- wartości gamma.

Szerokość marginesu błędu określa dopuszczalną odchyłkę, dla której wyniki o mniejszej odchyłce nie są traktowane jako błąd.

Parametr kosztu jest parametrem sterującym złożonością sieci SVM. Określa on wagę z jaką traktujemy błędy testowania sieci w stosunku do ustalonego marginesu separacji.

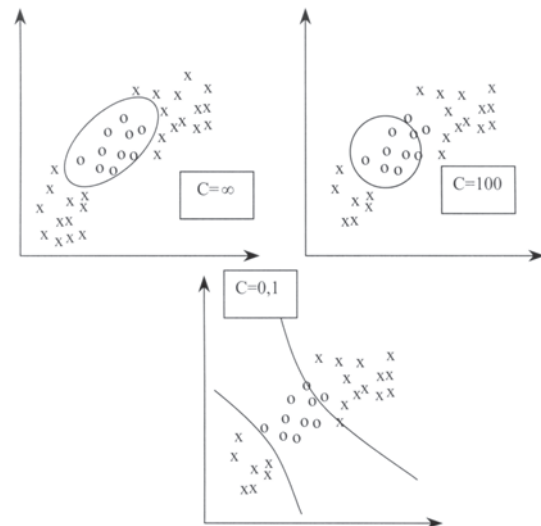
Parametr gamma określony jest dla radialnej funkcji jądra z zależności:  $\gamma = \frac{1}{\sigma^2}$ .

Optymalizację sieci SVM można przeprowadzać następujący sposób:


- optymalizując za każdym razem wszystkie parametry sieci ( $\epsilon$ , C,  $\gamma$ ),
- zakładając współczynnik tolerancji błędów na stałym poziomie optymalizując pozostałe parametry sieci (C,  $\gamma$ ),
- zakładając współczynnik C i  $\gamma$  optymalizując współczynnik tolerancji.

W pracy wybrano optymalizację współczynników C i  $\gamma$  przy założonym współczynniku tolerancji błędów  $\epsilon$ . Optymalizowano parametry sieci SVM poszukując najmniejszej wartości błędu dla stałej wartości współczynników  $\epsilon$  i  $\gamma$  zmieniając wartość współczynnika C. Następnie dla sieci charakteryzującej się najmniejszym błędem dla ustalonego współczynnika C, poszukiwano wartość współczynnika  $\gamma$ , dla której sieć popeliła najmniej błędów.

Wpływ wielkości współczynnika kosztu w sieciach SVM został zilustrowany na rysunku 5. Natomiast wpływ wielkości szerokości marginesu błędu uczenia i testowania dla sieci SVM oraz wpływ współczynnika  $\sigma$  na rozwiązywanie problemów regresyjnych przedstawia rysunek 6.



Rys. 5. Wpływ współczynnika kosztu na proces klasyfikacji wzorców



Rys. 6. Wpływ wielkości szerokości marginesu błęd oraz wpływu współczynnika  $\sigma$  na rozwiązywanie problemów regresyjnych

W eksperymencie postanowiono sprawdzić działanie sieci typu SVM jako klasyfikatora oraz w zadaniu regresyjnym.

W zadaniu klasyfikacji podzielono zakres stopnia pęknięcia podstawy zęba na pięć klas:

- 0 ÷ 20 %,
- 21 ÷ 40 %,
- 41 ÷ 60 %,
- 61 ÷ 80 %,
- 81 ÷ 100 %,

do których nauczona sztuczna sieć neuronowa miała klasyfikować przypadki z uszkodzeniami kół zębatych.

W zadaniu aproksymacji postanowiono sprawdzić działanie sztucznej sieci neuronowej w rozpoznawaniu konkretnych wartości stopnia pęknięcia podstawy zęba.

## 5. WYNIKI EKSPERYMENTU

Użycie sztucznej sieci neuronowej jako klasyfikatora wymaga stosowania takich miar na wejście, w których będą zapisane niezbędne dane umożliwiające sieci prawidłową klasyfikację obiektów [29]. Eksperyment miał dostarczyć informacji dotyczących możliwości zastosowania miar statystycznych do nauki klasyfikatora neuronowego. Dane takie muszą charakteryzować w sposób kompletny, pełny i jednoznaczny badane zjawisko. Chcąc określić stopień podcięcia zęba, klasyfikator musi posiadać wystarczającą wiedzę, która pozwoli mu odróżnić poszczególne poziomy uszkodzeń.

Najlepszą miarą lub zespołem miar byłyby estymaty, których wartości zmieniałyby się w całym zakresie poziomu uszkodzenia. Sieć nauczona na takich danych wejściowych, wykorzystując swoje możliwości uogólniania wiedzy potrafiłaby określić dokładnie stopień uszkodzenia zębów przekładni pracujących w zmiennych warunkach pracy (obciążenie, prędkość obrotowa) oraz dla różnych klas dokładności wykonania przekładni.

Przeprowadzone analizy wybranych miar pokazują, że żadna z nich nie jest wrażliwa w całym zakresie zmian uszkodzenia i nie może

być użyta samodzielnie jako miara określająca dokładnie stopień podcięcia zęba.

Badania wykazały, że miary przekładni bezbłędnie wykonanej (seria 1) wykazują wrażliwość w szerszym zakresie uszkodzenia w postaci wielkości podcięcia zęba. Przykładowo dla przekładni bezbłędnie wykonanej kurtoza z sygnału resztkowego wykazuje wrażliwość od 20% uszkodzenia, gdy natomiast dla przekładni z błędami cyklicznymi i losowymi wrażliwość tej estymaty obniża się do 50% i 75% uszkodzenia dla przyspieszeń drgań zębniaka uzyskanych odpowiednio w serii 2 i 3 (rys. 7). Innym przykładem jest bilans energetyczny, którego wrażliwość na propagację podcięcia zęba dla przekładni bezbłędnie wykonanej obejmuje cały przedział stopnia uszkodzenia, natomiast jest praktycznie niewrażliwy dla przekładni wykonanych z błędami cyklicznymi i losowymi (rys. 8).

Z przeprowadzonego eksperymentu wynika konieczność dalszych badań mających na celu znalezienie miar, które dostarczyłyby informacji diagnostycznej o powstałym uszkodzeniu w stopniu umożliwiającym zastosowanie ich jako danych wejściowych dla sztucznych sieci neuronowych.


Kolejne badania mające na celu znalezienie miar odpowiednich jako dane wejściowe dla sztucznych sieci neuronowych powinny objąć poszukiwanie odpowiednich miar sygnałów na podstawie analizy cepstrum, bispectrum, transformaty falkowej lub Wignera-Ville'a itp.

Wyniki eksperymentu użycia sztucznej sieci neuronowej typu SVM w zadaniu klasyfikacji przedstawiono w tabeli 1.


Tabela składa się z dziewięciu kolumn, w których kolejno przedstawiono numer porządkowy obróbki sygnału przyspieszeń drgań, wartości współczynników  $\epsilon$ ,  $\gamma$ ,  $C$ , złożoność sieci (SV), ilość błędów w czasie procesu uczenia sieci i jej procentową wartość, ilość błędów w czasie procesu testowania sieci i jej procentową wartość.

Na podstawie wyników można zauważyć zależność pomiędzy złożonością sieci neuronowej, czyli ilością wektorów podtrzymujących (SV), a ilością popełnianych przez sieć błędów w czasie testowania. Jest to zależność odwrotnie proporcjonalna.

Najmniejszy procent błędów testowania uzyskano dla wybranych miar statystycznych otrzymanych z kowariancji sygnału różnicowego (czasowego) uzyskanego z widma przyspieszeń drgań w zakresie od 0 do 6 kHz (nr porz. 21) wynoszący 7,2072 % otrzymano dla sieci o 227 wektorach podtrzymujących. Równocześnie sieć ta uzyskała wartość błędów uczenia na poziomie 4,1367 %.



Rys. 7. Zależność kurtozy sygnału reszkowego od stopnia podcięcia zęba



Rys. 8. Wpływ stopnia podcięcia zęba na bilans energetyczny

Z badań wynika również iż wielkość błędu uczenia maleje, gdy błąd testowania zaczyna już rosnać. Wynika to z faktu, że sieć zaczyna się uczyć na pamięć (przeuczenia sieci). Stąd też wynika fakt uzyskania znacznie lepszych wyników dla procesu uczenia niż późniejszej weryfikacji w procesie testowania sieci.

Wyniki eksperymentu z użyciem sieci typu SVM w zadaniach regresyjnych okazały się

niewystarczające do tego typu zadania. Sztuczna sieć neuronowa uczona na podstawie wybranych miar uzyskiwała błąd testowania na poziomie 50%, który można przyjąć za wynik losowy.

Dalsze eksperymenty z użyciem sztucznych sieci neuronowych w tego typu zadaniach powinny objąć poszukiwanie innych danych wejściowych i/lub próbę zastosowania innego typu sieci neuronowej.

Tabela 1. Wyniki eksperymentu

Nr porz.	$\epsilon$	$\gamma$	C	SV	Błąd uczenia		Błąd testowania	
					Ilość	%	Ilość	%
1	0,1	20	52000	313	64	11,5108	84	15,1351
2	0,1	10	66000	313	89	16,0072	105	18,9189
3	0,1	20	77000	308	24	4,3165	76	13,6937
4	0,1	3	90000	306	85	15,2878	109	19,6396
5	0,1	10	20000	391	13	2,3381	216	38,9189
6	0,1	70	30000	356	57	10,2518	98	17,6577
7	0,1	100	2000	436	89	16,0072	112	20,1802
8	0,1	20	30000	262	26	4,6763	52	9,3694
9	0,1	30	6000	302	34	6,1151	61	10,991
10	0,1	10	3000	364	63	11,3309	177	31,8919
11	0,1	40	30000	261	60	10,7914	71	12,7928
12	0,1	80	30000	225	40	7,3741	61	10,991
13	0,1	100	18000	233	35	6,295	70	12,6125
14	0,1	50	30	552	6	1,8791	409	73,6937
15	0,1	50	3	552	7	1,259	414	74,5946
16	0,1	0,01	3	546	197	35,4317	385	69,3694
17	0,1	30000	600	292	9	1,6187	47	8,4685
18	0,1	5000	300	282	18	3,2374	46	8,2883
19	0,1	100	15000	247	40	7,1942	74	13,3337
20	0,1	3000	300	360	30	5,3957	77	14,2342
21	0,1	1000	30000	227	23	4,1367	40	7,2072
22	0,1	100	30000	301	43	7,7338	101	18,1982

## LITERATURA

- [1] Adameczyk J., Krzyworzeka P., Łopacz H.: Systemy synchronicznego przetwarzania sygnałów diagnostycznych. Collegium Columbinum, Kraków 1999.
- [2] Bartelmus W., Zimroz R., Batra H.: Gearbox vibration signal pre-processing and input values choice for neural network training. AI-METH 2003 – Artificial Intelligence Methods. 5÷7.11.2003 r.
- [3] Cempel C.: Diagnostyka wibroakustyczna maszyn, Państwowe Wydawnictwo Naukowe, Warszawa 1989.
- [4] Chen D., Wang W. J.: Classification of wavelet map patterns using multi-layer neural networks for gear fault detection. Mechanical Systems and Signal Processing (2002) 16 (4).
- [5] Decker H. J.: Gear Crack Detection Using Tooth Analysis. NASA/ TM-2002-211491. 2002.
- [6] Dempsey P. J., Zakrajsek J. J.: Minimization load effects on NA4 gear vibration diagnostic parameter. NASA/TM-2001-210671, 2001.
- [7] Donovan M., Krishnappa G.: Some examples of signal analysis techniques to diagnose faults in machines. 6<sup>th</sup> International Congress on Sound and Vibration. Denmark 1999.
- [8] Giurgiutiu V., Cuc A., Goodman P.: Review of vibration-based helicopters health and usage monitoring methods. 55<sup>th</sup> Meeting of the Society for Machinery Failure Prevention Technology. Virginia Beach 2001.
- [9] Han T., An J., Yang B.: Feature extraction of vibration signal for machinery condition monitoring. 3<sup>rd</sup> Asia Pacific Conference on System Integrity and Maintenance. 2002.
- [10] James C., Limmer J. D.: Model-based condition index for tracking gear wear and fatigue damage. Wear 241 (2000). USA 2000.
- [11] Korbowicz J., Kościelny J., Kowalczyk Z., Cholewa W.: Diagnostyka procesów. Modele. Metody sztucznej inteligencji.



- Zastosowania, Wydawnictwo Naukowo-Techniczne, Warszawa 2002.
- [12] Kościelny J.: Diagnostyka zautomatyzowanych procesów przemysłowych, Akademicka Oficyna Wydawnicza EXIT, Warszawa 2001.
- [13] Kwak J., Ha M., Chung J., Park H., Chang H.: Grinding Fault Diagnosis Based on Neural Network. 3<sup>rd</sup> Asia Pacific Conference on System Integrity and Maintenance. 2002.
- [14] Luszniwicz A., Słaby T.: Statystyka. Teoria i zastosowania, Wydawnictwo C.H.Beck, Warszawa 2003.
- [15] Łazarz B.: Zidentyfikowany model dynamiczny przekładni zębatej jako podstawa projektowania. Biblioteka Problemów Eksploatacji, Katowice-Radom 2001.
- [16] Łazarz B.: Modelowanie lokalnych uszkodzeń kół zębatych do celów diagnostycznych. Diagnostyka vol. 26, 2002.
- [17] Łazarz B., Wojnar G.: Modelowanie lokalnych uszkodzeń łożysk tocznych w przekładni zębatej do celów diagnostycznych. V Krajowa Konferencja Diagnostyka Techniczna Urządzeń i Systemów DIAG' 2003.
- [18] Madej H., Czech P., Konieczny Ł.: Wykorzystanie dyskryminant bezwymiarowych w diagnostyce przekładni zębatych, Diagnostyka nr 28, 2003.
- [19] Mangasarian O. L.: Lagrangian Support Vector Machines, Journal of Machine Learning Research, 2001.
- [20] Martin H. R.: Statistical Moment Analysis as a Means of Surface Damage Detection. Proceedings of the 7<sup>th</sup> International Modal Analysis Conference, Society of Experimental Mechanics, Schenectady, NY 1989.
- [21] McClintic, Lebold M., Maynard K., Byington C., Campbell R.: Residual and difference feature analysis with transitional gearbox data. 54<sup>th</sup> Meeting of the Society for Machinery Failure Prevention Technology. Virginia Beach 2000.
- [22] McClintic, Lebold M., Maynard K., Byington C., Campbell R.: Review of vibration analysis methods for gearbox diagnostics and prognostics. 54<sup>th</sup> Meeting of the Society for Machinery Failure Prevention Technology. Virginia Beach 2000.
- [23] Mosher M., Pryor A. H., Huff E. M.: Evaluation of standard gear metrics in helicopter flight operation. 56<sup>th</sup> Meeting of the Society for Machinery Failure Prevention Technology. Virginia Beach 2002.
- [24] Nałęcz M., Duch W., Korbowicz J., Rutkowski L., Tadeusiewicz R.: Sieci neuronowe. Biocybernetyka i Inżynieria Biomedyczna 2000, Akademicka Oficyna Wydawnicza EXIT, Warszawa 2000.
- [25] Osowski S.: Sieci neuronowe do przetwarzania informacji, Oficyna Wydawnicza Politechniki Warszawskiej, Warszawa 2000.
- [26] Osowski S.: Sieci neuronowe SVM w zastosowaniu do problemów regresji, Przegląd Elektrotechniczny nr 86, 2002.
- [27] Osowski S.: Zastosowanie sieci SVM do klasyfikacji wzorców, Przegląd Elektrotechniczny nr 78, 2002.
- [28] Padovese L. R.: Using acoustical noise for fault classification in gearbox. 15<sup>th</sup> Brazilian Congress of Mechanical Engineering. Sao Paulo, 1999.
- [29] Radkowski S.: Wibroakustyczna diagnostyka uszkodzeń niskoenergetycznych, Biblioteka Problemów Eksploatacyjnych, Warszawa-Radom 2002.
- [30] Stewart R. M.: Some Useful Data Analysis Techniques for Gearbox Diagnostics. Report MHM/R/10/77, Machine Health Monitoring Group, Institute of Sound and Vibration Research, University of Southampton 1977.
- [31] Tadeusiewicz R.: Sieci neuronowe, Akademicka Oficyna Wydawnicza, Warszawa 1993.
- [32] Wang W.: Early detection of gear tooth cracking using the resonance demodulation technique. Mechanical Systems and Signal Processing (2001) 15 (5). 2001.
- [33] 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.
- [34] Wilk A., Łazarz B., Madej H.: Diagnostyka wibroakustyczna przekładni zębatych. V Krajowa Konferencja Diagnostyka Techniczna Urządzeń i Systemów. Diag 2003. Ustroń 2003.
- [35] Yang H., Mathew J., Ma L.: Intelligent diagnosis of rotating machinery faults - a review. 3<sup>rd</sup> Asia Pacific Conference on System Integrity and Maintenance. 2002.
- [36] Zakrajsek J. J., Townsend D. P., Lewicki D., G. Decker H. J., Handschuh R. F.: Transmission diagnostic research at NASA Lewis Research Center. Report Documentation Page NASA TM-106901, 1995.



Dr hab. inż. Bogusław ŁAZARZ jest adiunktem 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



Mgr inż. Piotr CZECH jest doktorantem w Katedrze Budowy Pojazdów Samochodowych Wydziału Transportu Politechniki Śląskiej. Zajmuje się wykorzystaniem sieci neuronowych w diagnostyce przekładni zębatych.

*Publikacja powstała w wyniku realizacji pracy 5T07B 02425*