

Piotr Czech

Katedra Budowy Pojazdów Samochodowych, Wydział
Transportu, Politechnika Śląska

WYKORZYSTANIE METOD CZASOWO-CZĘSTOTLIWOŚCIOWYCH DO BUDOWY DESKRYPTORÓW USZKODZEŃ KÓŁ ZĘBATYCH DLA RADIALNYCH SIECI NEURONOWYCH

Streszczenie – W artykule przedstawiono wyniki prób budowy aplikacji opartej na sieci neuronowej typu RBF, służącej do diagnozowania uszkodzenia zębów kół przekładni w postaci pęknięcia u podstawy zęba. W celu przeprowadzenia prawidłowego procesu uczenia sieci niezbędne jest pozyskanie z badanego obiektu licznego zbioru danych wejściowych dla sieci. Przeprowadzone badania oparto na danych otrzymanych ze zidentyfikowanego modelu przekładni zębatej pracującej w układzie napędowym, co umożliwiło pozyskanie niezbędnej liczby danych. W doświadczeniach sprawdzono przydatność różnych zestawów deskryptorów uszkodzeń zębów zbudowanych w oparciu o sygnały drganiowe przetworzone za pomocą metod czasowo-częstotliwościowych, tj. krótkoczasowa transformata Fouriera oraz transformata Wignera-Ville'a.

1 Wprowadzenie

Następujący w ostatnich latach bardzo duży rozwój układów pomiarowych i komputerów umożliwia tworzenie coraz doskonalszych systemów diagnostycznych. W pracy [2] zaproponowano wykorzystanie do tego celu sygnałów drganiowych oraz metod sztucznej inteligencji.

Obecnie w literaturze można spotkać cały szereg metod przetwarzania i analizy sygnału zarówno w dziedzinie czasu, jak i częstotliwości oraz w obu dziedzinach jednocześnie [1-3,5,6,13,14]. Dla sygnałów zmiennych czasowo w sensie amplitudowym i częstotliwościowym, czyli sygnałów niestacjonarnych, w diagnostyce stosuje się szczególnie metody umożliwiające analizę w obu dziedzinach jednocześnie. Do grupy tych metod należy krótkoczasowa transformata Fouriera (STFT), definiowana jako [3]:

$$STFT(b, f) = \int_{-\infty}^{+\infty} w(t-b) \cdot x(t) \cdot e^{-j2\pi ft} dt \quad (1)$$


gdzie:

$w(t-b)$ – przesuwana w dziedzinie czasu funkcja okna,

b – zadane przesunięcie okna czasowego.

Sygnał czasowy zostaje podzielony na mniejsze części, a następnie dla każdej z nich oblicza się FFT. Zestawienie obok siebie wyznaczonych widm tworzy mapę czasowo-częstotliwościową [14]. Jak podaje Autor [13], STFT można również traktować jako grzebień równocześnie pracujących filtrów.

W metodzie tej zastosowanie szerokiego okna zwiększa rozdzielczość w dziedzinie częstotliwości, zaś zmniejsza w dziedzinie czasu [3]. Dla wąskiego okna efekt jest odwrotny (rys. 1).



Rys. 1. Wpływ wielkości okna na rozdzielczość w dziedzinie czasu i częstotliwości dla STFT

Wady tej pozbawiona jest transformata Wignera–Ville'a (WVD) [3]:

$$WVD(t, f) = \int_{-\infty}^{+\infty} w(\tau) \cdot x\left(t + \frac{\tau}{2}\right) \cdot x^*\left(t - \frac{\tau}{2}\right) \cdot e^{-j2\pi f\tau} d\tau \quad (2)$$

gdzie:

$x^*(t)$ – czasowy sygnał zespolony, sprzężony z $x(t)$,

$w(\tau)$ – symetryczna funkcja wagowa, podobna do funkcji okna w STFT.

Porównania metody STFT z WVD pod względem zalet i wad dokonano w [14].

W niniejszym opracowaniu przedstawiono sposób wykorzystania krótkoczasowej transformaty Fouriera oraz transformaty Wignera-Ville'a. Stworzone za ich pomocą deskryptory uszkodzeń zębów kół przekładni posłużyły jako dane wejściowe dla klasyfikatorów neuronowych.

Obecnie coraz częściej wibroakustyczne symptomy uszkodzenia analizuje się za pomocą metod sztucznej inteligencji [2,3]. Metody te

pozwalają modelować dowolne nieliniowości, charakteryzując się odpornością na zakłócenia oraz zdolnością do uogólniania wiedzy [3,7-12,15].

W przedstawionych badaniach wykorzystano radialne sieci neuronowe, w których jako funkcję aktywacji neuronów wykorzystuje się funkcję o symetrii kołowej. W odróżnieniu od neuronów sigmoidalnych, które reprezentują w przestrzeni wielowymiarowej hiperpłaszczyznę separującą przestrzeń na dane klasy, neurony radialne reprezentują hipersferę dokonującą separacji kołowej wokół punktu centralnego [12]. Sieć radialna ma strukturę warstwową składającą się z warstwy wejściowej, ukrytej i wyjściowej [7-9,12]. Warstwa ukryta zbudowana jest z neuronów radialnych, które najczęściej posiadają jako funkcję aktywacji funkcję Gaussa [12]. Neurony w warstwie wyjściowej posiadają liniową lub logistyczną warstwę aktywacji. Rola neuronów w tej warstwie sprowadza się do sumowania wagowego sygnałów z warstwy ukrytej [8,9]. Podstawowym problemem w projektowaniu tego typu sieci jest odpowiedni dobór liczby i rodzajów funkcji bazowych (neuronów w warstwie ukrytej) [12]. Zbyt mała liczba powoduje słabą jakość dopasowania do wzorców, a zbyt duża utratę zdolności do uogólniania wiedzy przez sieć. Należy określić wartości punktów centralnych, które umiejscawiają funkcje bazowe wewnątrz przestrzeni rozpiętej na danych wejściowych oraz wartości wag połączeń między neuronami w warstwie ukrytej z warstwą wyjściową [8,9].

We wstępnym etapie badań poszukiwano optymalnej pod względem minimalnego błędu klasyfikacji liczby neuronów w warstwie ukrytej. Prowadzono eksperymenty metodą polegającą na zwiększaniu liczby neuronów radialnych, aż do osiągnięcia liczby równej ilości wzorców uczących. Ponieważ różnice w wartości błędu klasyfikacji były niewielkie, w niniejszej pracy przyjęto liczbę neuronów w warstwie ukrytej sieci radialnej równą liczbie wzorców uczących. Z punktu widzenia matematycznego w [8] założenie takie określa się przewymiarowaniem. Występujące małe różnice w wielkości błędu dla optymalnej i maksymalnie złożonej sieci radialnej mogą wynikać z wielkości wzorców. Jak podano w [9] wstępny dobór liczby funkcji radialnych (neuronów ukrytych) dla każdego problemu jest sprawą indywidualną, mającą wpływ na dokładność odwzorowania wzorców. Równocześnie Autor pisze, że wraz ze wzrostem wymiaru wzorców, wymagana liczba funkcji radialnych wzrasta. Zastosowane w pracy założenie pozwoliło znacząco skrócić czas potrzebny na znalezienie minimalnej struktury sieci zdolnej do wykonywania prawidłowej klasyfikacji. W badaniach skupiono się natomiast na doborze odpowiedniego charakteru funkcji bazowej separującej optymalnie przestrzeń danych. Zmieniając współczynnik γ określano kształt funkcji i wielkość pola recepcyjnego, dla którego wielkość funkcji jest

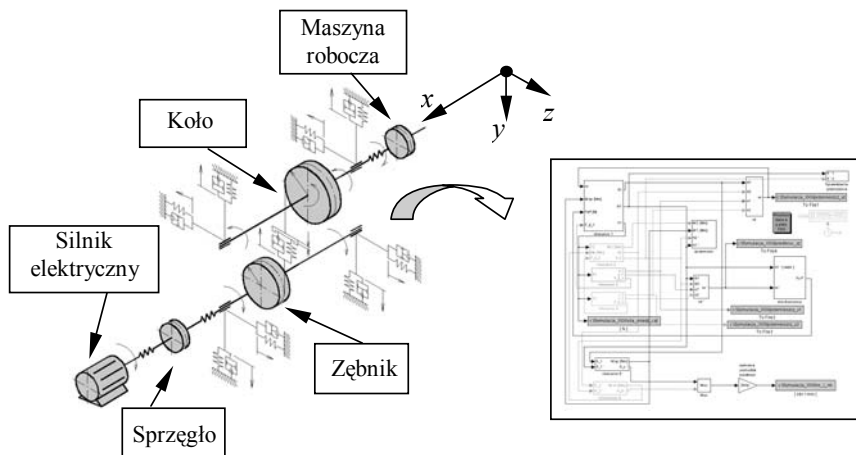
niezerowa. Współczynnik ten powinien być tak dobrany, aby pola recepcyjne wszystkich funkcji bazowych pokrywały cały obszar danych wejściowych, przy dopuszczalnym tylko nieznacznym nachodzeniu na siebie dwóch sąsiednich pól recepcyjnych [8].

2 Obiekt badań

Obiekt badań stanowiła przekładnia zębata o zębach prostych o liczbie zębów zębника i koła odpowiednio 16 i 24.

W przeprowadzonych doświadczeniach wykorzystano sygnały drganiowe pochodzące z modelu dynamicznego przekładni zębatej pracującej w układzie napędowym. Model został opracowany na Wydziale Transportu Politechniki Śląskiej [4,5]. Zrealizowany w środowisku Matlab–Simulink, uwzględnia charakterystykę napędowego silnika elektrycznego, jednostopniowej przekładni zębatej, sprzęgieł oraz maszyny roboczej. Opis zjawisk zachodzących w zazębieniu jest zgodny z modelem Müllera.

Na rys. 2 przedstawiono w sposób poglądowy model zaimplementowany w środowisku Matlab–Simulink.



Rys. 2. Model dynamiczny przekładni zębatej w układzie napędowym

Przyjęty układ współrzędnych zakładał pokrywanie się osi „x” z kierunkiem osi wałów, osi „y” z kierunkiem siły normalnej, osi „z” zgodnie z kierunkiem siły stycznej w zazębieniu. W modelu zębnik i koło traktowane są jako bryły sztywne o znanych momentach bezwładności, a pozostałe masy elementów przekładni zostały zredukowane do mas skupionych w środkach łożysk. Dodatkowe założenie ustalało niezerowe momenty bezwładności w kierunku osi obrotu łożysk. Uwzględniono

również uproszczony model silnika asynchronicznego, uwzględniającego charakterystykę mechaniczną oraz moment bezwładności wirnika. Model symulacyjny umożliwiał również uwzględnienie w obliczeniach odchyłek cyklicznych i losowych występujących w zazębieniu. Odchyłka kinematyczna na podziałce koła, należąca do grupy wskaźników płynności pracy, ma duży wpływ na dynamikę przekładni. Składa się ona z części okresowej (cyklicznej), wynikającej np. z odchyłki kąta zarysu, oraz części losowej, spowodowanej np. losowymi odchyłkami podziałki zasadniczej. W modelu odchyłkę okresową odwzorowano poprzez dobór wartości i kierunku pochylenia powierzchni modelujących zazębienie zębniaka i koła. Składowe losowe odwzorowano w postaci różnic wysokości kolejnych sprężyn w palisadzie, które reprezentują sprężystość par zębów stykających się niepracującymi bokami, zgodnie z modelem Müllera. Odchyłki losowe mogą mieć różne wartości dla różnych zębów zębniaka i koła. Z uwagi na charakter niniejszej publikacji oraz ograniczenia liczebności stron zrezygnowano z dokładniejszego opisu stosowanego w doświadczeniach modelu przekładni zębatej.

3 Sposób budowy deskryptorów uszkodzeń zębów kół przekładni

Odpowiedni dobór i przygotowanie danych wzorcowych, które mają posłużyć do procesu uczenia klasyfikatorów opartych na metodach sztucznej inteligencji, warunkuje poprawność działania finalnego systemu diagnostycznego [2,3,7-12,15].

Ponieważ zestaw wzorców musi zawierać dużą liczbę przykładów uczących założono, że nie ma możliwości pozyskania z badań na obiekcie rzeczywistym wystarczającej liczby danych. W celu pozyskania niezbędnego do dalszych badań ciągu uczącego, zdecydowano się skorzystać z modelu dynamicznego przekładni zębatej pracującej w układzie napędowym.

W modelu symulacyjnym zaadaptowano uszkodzenie zęba w postaci pęknięcia w stopie jako procentową zmianę sztywności zazębienia w stosunku do nieuszkodzonej przekładni. Ponieważ w literaturze nie znaleziono dokładnych danych na temat wpływu inicjacji i rozwoju szczeliny u podstawy zęba na zmianę sztywności zazębienia, ustalono następujące pięć klas stopnia uszkodzenia, w postaci zmniejszenia sztywności zazębienia w stosunku do nieuszkodzonej przekładni o wartość:

- 0-19% - klasa 1,
- 20-39% - klasa 2,
- 40-59% - klasa 3,
- 60-79% - klasa 4,
- 80-100% - klasa 5.

Konieczność pozyskania wystarczającej i obejmującej wszystkie klasyfikowane wzorce uszkodzeń zębów kół przekładni dla systemów opartych na metodach sztucznej inteligencji, 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 co jeden procent przy zmianie sztywności w zakresie od 0 do 100% w stosunku do nieuszkodzonej przekładni dla uszkodzenia w postaci pęknięcia w stopie zęba. Dodatkowo w celu zwiększenia reprezentatywności ciągu uczącego, symulacje powtórzono dla następujących parametrów:

1) seria pierwsza:

- „błąd cykliczny” dla zębniaka: $0 \mu\text{m}/\text{długość podziałki}$ (stan nominalny),
- „błąd cykliczny” dla koła: $0 \mu\text{m}/\text{długość podziałki}$ (stan nominalny),
- „błędy losowe” - maksymalny błąd wykonania zębniaka: $0 \mu\text{m}$ (stan nominalny),
- „błędy losowe” - maksymalny błąd wykonania koła: $0 \mu\text{m}$ (stan nominalny),

2) seria druga:

- błąd cykliczny dla zębniaka: $-7 \mu\text{m}/\text{długość podziałki}$,
- błąd cykliczny dla koła: $5 \mu\text{m}/\text{długość podziałki}$,
- błędy losowe - maksymalny błąd wykonania zębniaka: $\pm 4,5 \mu\text{m}$,
- błędy losowe - maksymalny błąd wykonania koła: $\pm 4,5 \mu\text{m}$,

3) seria trzecia:

- błąd cykliczny dla zębniaka: $-14 \mu\text{m}/\text{długość podziałki}$,
- błąd cykliczny dla koła: $10 \mu\text{m}/\text{długość podziałki}$,
- błędy losowe - maksymalny błąd wykonania zębniaka: $\pm 9 \mu\text{m}$,
- błędy losowe - maksymalny błąd wykonania koła: $\pm 9 \mu\text{m}$.

W pierwszej serii zasymulowano pracę bezbłędną przekładni zębatej. Seria druga i trzecia zakładała pracę przekładni o zwiększonych błędach cyklicznych i losowych. Celem zwiększenia i zróżnicowania liczby wzorców serię drugą i trzecią przeprowadzono pięciokrotnie, przy różnych wartościach błędów losowych. Otrzymanych 1111 symulacji stanowiło podstawę uzyskania wzorców klas stopnia pęknięcia u podstawy zęba.

Ze względu na czasochłonność procesu pozyskiwania wzorca klas, przyjęto do analiz dane z modelu przekładni zębatej pracującej przy prędkości obrotowej wału koła $n=1800 \text{ obrót./min}$ oraz obciążeniu $2,58 \text{ MPa}$.

W badaniach za sygnał bazowy, poddawany ekstrakcji cech, przyjęto prędkość drgań poprzecznych wału koła.

Otrzymane z modelu sygnały drganiowe poddano działaniu pięciu filtrów:

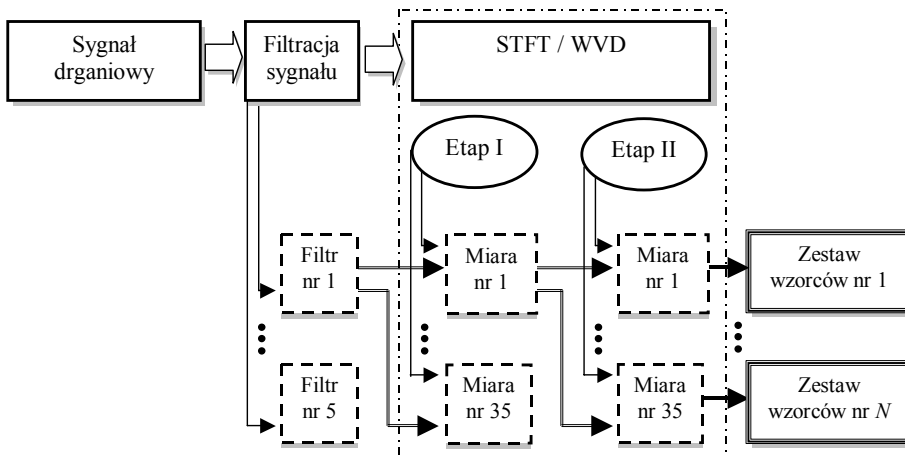
- dolnoprzepustowy w zakresie 6 kHz,
- dolnoprzepustowy w zakresie 12 kHz,
- umożliwiający uzyskanie sygnałów resztkowych,
- umożliwiający uzyskanie sygnałów różnicowych,
- pasmowoprzepustowy w zakresie 0,5-1,5 częstotliwości ząbienia.

Sygnały resztkowe otrzymano poprzez usunięcie z widma pasm częstotliwości zawierających składowe obrotowe wałów kół i ich harmoniczne oraz składowe częstotliwości ząbienia i jej harmoniczne. Sygnał różnicowy otrzymano podobnie jak sygnał resztkowy, lecz usunięte pasma wokół częstotliwości ząbienia i ich harmonicznych są szersze i obejmowały wstęgi boczne związane z częstotliwościami obrotowymi kół zębatych [6].

Otrzymane sygnały drganiowe wykorzystano do budowy wzorców uszkodzeń zębów kół. W tym celu z przefiltrowanych sygnałów stworzono rozkłady czasowo-częstotliwościowe wykorzystując do tego celu krótkoczasową transformatę Fouriera (STFT) oraz transformatę Wignera-Ville'a (WVD).

W celu opisu charakteru zmian rozkładów STFT oraz WVD w zależności od stopnia uszkodzenia zębów kół przyjęto dwuetapowy sposób postępowania.

Na rys. 3 przedstawiono schematycznie sposób postępowania przy budowie wzorców uszkodzeń zębów kół przy wykorzystaniu do tego celu transformaty STFT lub WVD.



Rys. 3. Sposób budowy deskryptorów klas uszkodzeń zębów kół
przekładni

W etapie I dla kolejnych częstotliwości wyznaczono miary statystyczne. Sprawdzono przydatność 34 estymat, które są szeroko opisywane 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) [2]. Postępowanie takie miało na celu opis charakteru zmian w dziedzinie czasu, dla kolejnych częstotliwości wyznaczonych zgodnie z założoną częstotliwością próbkowania.

W etapie II z tak otrzymanych charakterystyk częstotliwościowych wyodrębniono zakresy:

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

Zakresy częstotliwości $f \in \langle i \cdot f_z - f_o, i \cdot f_z \rangle$ oraz $f \in \langle i \cdot f_z, i \cdot f_z + f_o \rangle$ podzielono na 9, 6 oraz 3 podzakresy, co dało odpowiednio podzakresy o długościach $\Delta f \cong 30$ Hz, $\Delta f \cong 65$ Hz oraz $\Delta f \cong 150$ Hz. Celem podziału na podzakresy o trzech wariantach liczebności było sprawdzenie wpływu ich wielkości na wynik klasyfikacji.

W każdej wydzielonej części tak otrzymanych widm opisano charakter zmienności rozkładu z wykorzystaniem 34 miar. Wektor składający się z wyznaczonej miary w każdej z części widma, stanowił dane wejściowe dla klasyfikatora neuronowego. Całą procedurę budowy wzorców klas uszkodzeń powtórzono dla sygnałów drganiowych otrzymanych przy użyciu kolejnych filtrów. W wyniku przeprowadzonych obliczeń zbudowano po 17340 zestawów wzorców klas stopnia uszkodzenia zębów kół przekładni dla STFT oraz WVD. Każdy z zestawów wzorców miał wymiar $m \times n$, gdzie m stanowił liczbę przypadków, zaś n liczbę wejść sieci. Liczbę przypadków stanowiła liczba przeprowadzonych symulacji, równa 1111. W zależności od sposobu budowy wzorców liczba wejść sieci była równa 192, 144 lub 96.

Każdy z zestawów wzorców podzielono na część wykorzystywaną w procesie uczenia (556 przypadków) oraz testowania (555 przypadków).

Liczba zestawów wzorców była zbyt duża, by sprawdzić działania sieci neuronowych uczonych z ich pomocą, dlatego postanowiono wybrać najlepsze warianty zestawów wzorców dla zastosowanych kolejnych pięciu filtrów oraz trzech sposobów podziału na podzakresy. Eksperyment wyboru najlepszych zestawów wzorców podzielono na trzy etapy. Kryterium wyboru stanowiła wartość błędu testowania sieci.

W pierwszym etapie za miarę opisującą zmiany charakterystyk STFT lub WVD w czasie dla kolejnych częstotliwości założono wartość skuteczną. W wyniku przeprowadzenia etapu wyznaczono najlepsze miary opisujące przebieg zmian w dziedzinie częstotliwości dla sposobów budowy wzorców wykorzystujących kolejne filtry oraz podział wybranych zakresów częstotliwości na 9, 6 i 3 podzakresy.

W drugim etapie badań dla wybranych wcześniej miar opisujących przebiegi w dziedzinie częstotliwości sprawdzano przydatność 34 miar do opisu zmiany charakterystyki STFT lub WVD w czasie. Etap drugi polegał więc na sprawdzeniu przyjętego we wcześniejszym etapie założenia dotyczącego wyboru wartości skutecznej za miarę opisującą charakterystyki w dziedzinie czasu. W tym etapie eksperymentu badania przeprowadzono również przy wykorzystaniu w procesie budowy wzorców pięciu filtrów i trzech sposobów podziału wybranych zakresów częstotliwości na podzakresy.

W etapie trzecim eksperymentu spośród najlepszych wyników etapu 1 i 2 wybrano najlepsze warianty stosowanych miar do opisu zmian w dziedzinie czasu i częstotliwości charakterystyk uzyskanych z analizy STFT oraz WVD. Wyboru dokonano dla różnych wariantów klasyfikatorów uczonych na wzorcach zbudowanych przy użyciu pięciu filtrów oraz przy podziale na 3, 6 oraz 9 podzakresów.

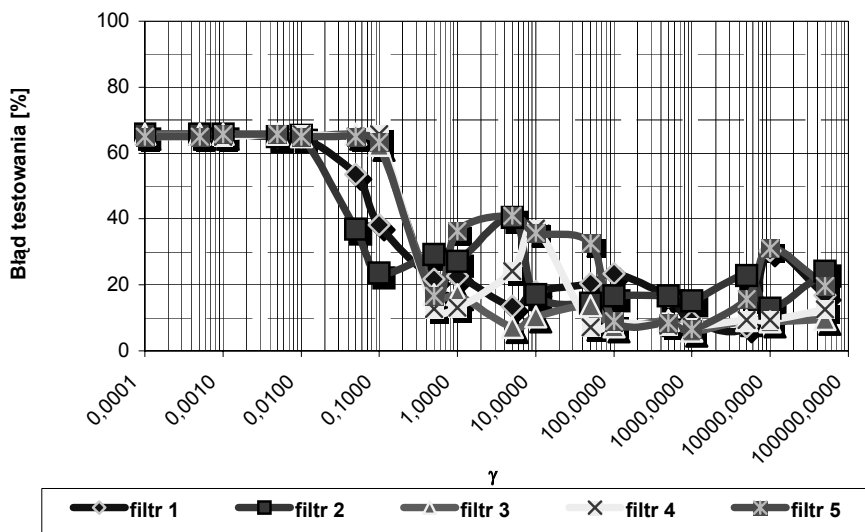
4 Wyniki badań

Na podstawie przeprowadzonych trójetapowych badań ustalono rodzaj estymat wykorzystywanych w procesie budowy wzorców klas uszkodzeń (tabela 1), dla których klasyfikatory neuronowe wykazywały największą zgodność z wzorcem.

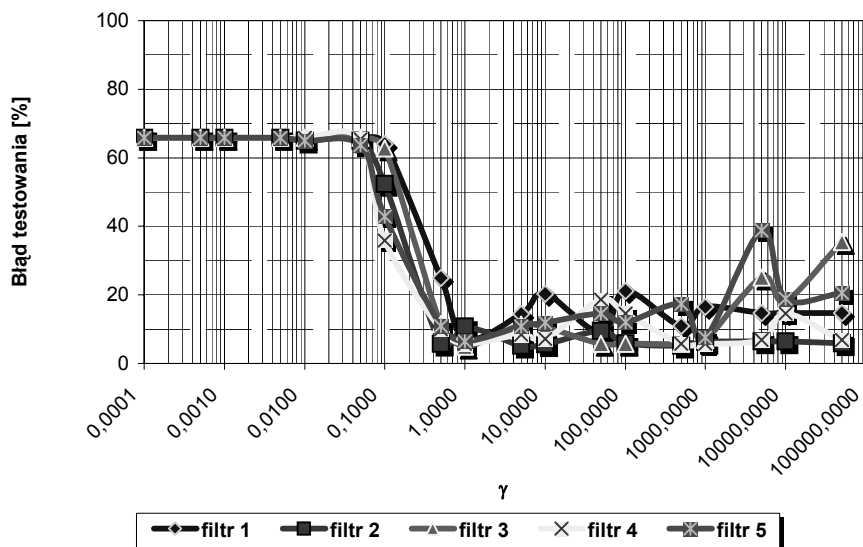
Tabela. 1. Wybrane estymaty wykorzystywane w procesie budowy deskryptorów uszkodzeń zębów kół przekładni

Lp	Liczba podzakresów	Nr filtru	Nazwa miary opisującej charakter zmian w dziedzinie	
			czasu	częstotliwości
1	9	1	pozycyjny współczynnik zmienności	pozycyjny współczynnik zmienności
2		2	wartość skuteczna	współczynnik kształtu
3		3	kwartyl 3	współczynnik kształtu
4		4	odchylenie przeciętne	wartość skuteczna

5		5	odchylenie ćwiartkowe	kwartył 3
6	6	1	kwartył 3	mediana
7		2	odchylenie przeciętne	kwartył 1
8		3	dyskryminanta X4	średnia harmoniczna
9		4	wartość skuteczna	odchylenie ćwiartkowe
10		5	wartość skuteczna	średnia harmoniczna
11		3	1	wartość skuteczna
12	2		wartość skuteczna	współczynnik luzu
13	3		średnia arytmetyczna	odchylenie ćwiartkowe
14	4		wartość międzyszczytowa	kwartył 3
15	5		kwartył 3	średnia geometryczna



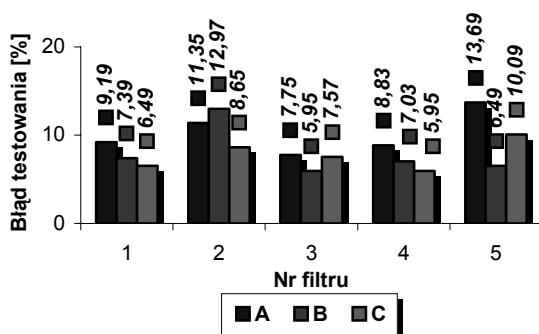
Rys. 4. Dobór współczynnika γ dla klasyfikatora typu RBF uczonego z wykorzystaniem deskryptorów otrzymanych przy wykorzystaniu STFT



Rys. 5. Dobór współczynnika γ dla klasyfikatora typu RBF uczonego z wykorzystaniem deskryptorów otrzymanych przy wykorzystaniu WVD

Dla każdego rodzaju z zastosowanych filtrów oraz sposobu podziału na podzakresy poszukiwano optymalnej wartości współczynnika γ .

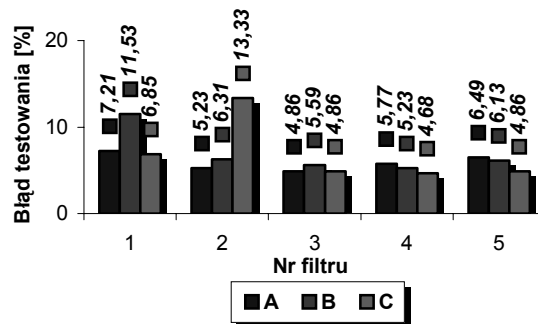
Przykładowe wyniki uzyskane przy wykorzystaniu sieci typu RBF oraz danych wejściowych otrzymanych przy podziale rozkładów STFT na 3 podzakresy przedstawiono na rys. 4, natomiast dla danych otrzymanych przy podziale rozkładów WVD na 9 podzakresów pokazano na rys. 5.



Rys. 6. Najlepsze uzyskane wyniki dla klasyfikatorów neuronowych typu RBF uczonego na wzorcach uzyskanych z analizy STFT; A - liczba podzakresów = 9, B - liczba podzakresów = 6, C - liczba podzakresów = 3

Uzyskane z eksperymentu charakterystyki mają charakter wielomodalny, co uniemożliwiło wyciągnięcie wniosków dotyczących wyboru optymalnego współczynnika γ zarówno w przypadku wykorzystania deskryptorów utworzonych z wykorzystaniem analizy STFT, jak również WVD.

Najlepsze uzyskane wyniki sieci neuronowych typu RBF wykorzystujących w procesie uczenia dane otrzymane z rozkładów STFT przedstawiono na rys. 6, natomiast dla rozkładów WVD pokazano na rys. 7.



Rys. 7. Najlepsze uzyskane wyniki dla klasyfikatorów neuronowych typu RBF uczonych na wzorcach uzyskanych z analizy WVD; A - liczba podzakresów = 9, B - liczba podzakresów = 6, C - liczba podzakresów = 3

W przypadku deskryptorów zbudowanych w oparciu o rozkłady STFT, najmniejszym poziomem błędów charakteryzowały się klasyfikatory uczone na wzorcach otrzymanych przy podziale na 3 podzakresy. Najlepszym filtrem okazał się filtr nr 3 i 4, dla którego poziom błędów testowania wynosił 5,95%. Najwyższe wartości błędów testowania uzyskiwały sieci RBF wykorzystujące podział na 9 podzakresów. W tym przypadku błąd sięgał 14%. W przypadku wyboru najmniej odpowiedniego w procesie tworzenia wzorców filtru, największą liczbą pomyłek charakteryzowały się klasyfikatory RBF uczone z wykorzystaniem wzorców otrzymanych przy użyciu filtru nr 2.

Dla klasyfikatorów RBF wykorzystujących deskryptory otrzymane z rozkładów WVD przy zastosowaniu filtru nr 3, 4 i 5 błędy testowania otrzymano na zbliżonym poziomie wynoszący 4,68÷6,49%. Najniższą wartość błędów testowania, wynoszącą 4,68%, odnotowano dla wzorców otrzymanych z sygnału różnicowego przy podziale na 3 podzakresy, natomiast najwyższa wartość błędów wynosząca 13,33% została zarejestrowana dla klasyfikatora wykorzystującego filtr nr 2 i podział na 3 podzakresy.

Zróźnicowanie w uzyskanych najlepszych wynikach dla danych filtrów oraz sposobów podziału wybranych zakresów częstotliwości uniemożliwiło dokonanie jednoznacznego wyboru najlepszego wariantu budowy deskryptorów uszkodzeń zębów kół przekładni dla klasyfikatorów neuronowych RBF.

Uzyskane w eksperymentach wyniki pokazują, iż możliwe jest zbudowanie klasyfikatora neuronowego RBF diagnozującego stopień pęknięcia u podstawy zębów kół przekładni. Przeprowadzone doświadczenia oparto na sygnałach drganiowych otrzymanych z modelu dynamicznego przekładni. Kolejnym etapem jaki należy przeprowadzić jest zbadanie, czy zaproponowany sposób budowy klasyfikatorów neuronowych będzie równie przydatny dla sygnałów drganiowych pochodzących z rzeczywistej przekładni.

Literatura

- [1] Cempel C.: *Diagnostyka wibroakustyczna maszyn*, Państwowe Wydawnictwo Naukowe, Warszawa, 1989.
- [2] Czech P., Łazarz B., Wojnar G.: *Wykrywanie lokalnych uszkodzeń zębów kół przekładni z wykorzystaniem sztucznych sieci neuronowych i algorytmów genetycznych*, Biblioteka Problemów Eksploatacji, ITE Radom, 2007.
- [3] Korbicz J., Kościelny J., Kowalczyk Z., Cholewa W. (praca zbiorowa): *Diagnostyka procesów, Modele, Metody sztucznej inteligencji, Zastosowania*, Wydawnictwa Naukowo-Techniczne, Warszawa, 2002.
- [4] Łazarz B.: *Zidentyfikowany model dynamiczny przekładni zębatej jako podstawa projektowania*, Biblioteka Problemów Eksploatacji, ITE Radom, 2001.
- [5] Łazarz B., Wojnar G., Czech P.: *Wibrometria laserowa i modelowanie – narzędzia współczesnej diagnostyki przekładni zębatych*, Biblioteka Problemów Eksploatacji, ITE Radom, 2007.
- [6] Madej H.: *Wykorzystanie sygnału resztkowego drgań w diagnostyce przekładni zębatych*, Diagnostyka Vol. 26, 2002.
- [7] Nałęcz M., Duch W., Korbicz J., Rutkowski L., Tadeusiewicz R.: *Sieci neuronowe, Biocybernetyka i Inżynieria Biomedyczna*, tom 6, Akademicka Oficyna Wydawnicza EXIT, Warszawa, 2000.
- [8] Osowski S.: *Sieci neuronowe do przetwarzania informacji*, Oficyna Wydawnicza Politechniki Warszawskiej, Warszawa, 2000.
- [9] Osowski S.: *Sieci neuronowe w ujęciu algorytmicznym*, Wydawnictwa Naukowo-Techniczne, Warszawa, 1996.

- [10] Rutkowska D., Piliński M., Rutkowski L.: *Sieci neuronowe, algorytmy genetyczne i systemy rozmyte*, Wydawnictwo Naukowe PWN. Warszawa-Łódź, 1997.
- [11] Tadeusiewicz R.: *Sieci neuronowe*, Akademicka Oficyna Wydawnicza, Warszawa, 1993.
- [12] Witkowska D.: *Sztuczne sieci neuronowe i metody statystyczne, Wybrane zagadnienia finansowe*, Wydawnictwo C.H. Beck, Warszawa, 2002.
- [13] Zieliński T. P.: *Od teorii do cyfrowego przetwarzania sygnałów*, AGH Kraków, 2002.
- [14] 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.
- [15] Żurada J., Barski M., Jędruch W.: *Sztuczne sieci neuronowe*, Wydawnictwo Naukowe PWN, Warszawa, 1996.

APPLICATION OF THE TIME-FREQUENCY METHODS FOR SETTING UP THE TOOTH FAULTS MODEL OF GERBOX ASSEMBLY FOR RADIAL NEURAL NETWORK

Summary – The paper presents results of an experiment, aimed at application of RBF (Radial Basis Function) neural network for classification of the cracking degree of a tooth root. The basic problem involved in application of an artificial neural network, is to appropriately select the input data. It was decided to verify feasibility of one of the most popular, and currently most dynamically developing tools for analysing nonstationary signals – the Short Time Fourier Transform (STFT) and the Wigner-Ville Distribution (WVD). The later finds it applications for analysing transient process signals, which often the outcome of changeability of parameters and nonlinearities in time. An identified toothed gear model in the drive system has been used in the experiment. The model was used to simulate the effect of cracking degree at the tooth root on transverse acceleration of pinion shaft vibrations.