

Piotr CZECH

Politechnika Śląska, Gliwice

WYKORZYSTANIE ALGORYTMÓW GENETYCZNYCH DO DOBORU WEJŚĆ KLASYFIKATORA USZKODZEŃ ZĘBÓW KÓŁ PRZEKŁADNI OPARTEGO NA SIECI NEURONOWEJ PNN ORAZ KRÓTKOCZASOWEJ TRANSFORMACIE FOURIERA

Słowa kluczowe

Diagnostyka przekładni zębatych, metody sztucznej inteligencji, sztuczne sieci neuronowe, algorytmy genetyczne, krótkoczasowa transformata Fouriera.

Streszczenie

W artykule przedstawiono wyniki prób mających na celu budowę klasyfikatora lokalnych uszkodzeń zębów kół przekładni, opartego na sztucznych sieciach neuronowych. W badaniach wykorzystywano probabilistyczne sieci neuronowe (PNN). Dodatkowo podjęto próbę wykorzystania algorytmów genetycznych do celów wyboru wejść klasyfikatora neuronowego.

Badania oparto na sygnałach drganiowych otrzymanych z modelu dynamicznego przekładni pracującej w układzie napędowym.

W artykule zaproponowano sposób budowy deskryptorów lokalnych uszkodzeń zębów kół wykorzystując do tego celu sygnały drganiowe poddane odpowiedniej filtracji oraz przetwarzaniu z użyciem krótkoczasowej transformaty Fouriera (STFT).

Wprowadzenie

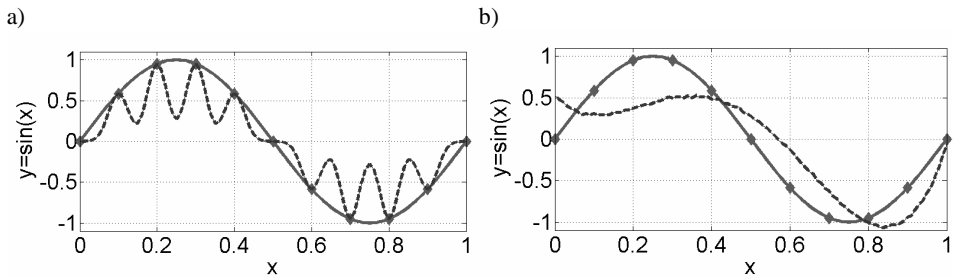
Następujący w ostatnich latach dynamiczny rozwój układów pomiarowych i komputerów umożliwia tworzenie coraz doskonalszych systemów diagnostycznych. W pracy [3] zaproponowano wykorzystanie do tego celu sygnałów drganiowych oraz metod sztucznej inteligencji.

Obecnie w literaturze można spotkać cały szereg metod przetwarzania i analizy sygnału zarówno w dziedzinie czasu, jak i częstotliwości oraz w obu dziedzinach jednocześnie [6, 11, 12, 16, 23, 26, 29, 32]. W niniejszym opracowaniu przedstawiono sposób wykorzystania krótkoczasowej transformaty Fouriera, należącej do metod przetwarzania sygnałów w obu dziedzinach. Stworzone za jej pomocą deskryptory uszkodzeń zębów kół przekładni posłużyły jako dane wejściowe dla klasyfikatorów neuronowych.

W badaniach wykorzystano klasyfikatory neuronowe oparte na probabilistycznych sieciach neuronowych PNN [5, 28]. Inspiracją do stworzenia tego typu sieci były sieci o radialnych funkcjach bazowych RBF, które są szeroko opisywane w literaturze [2, 9, 11, 19+21, 28]. Sieci PNN wykorzystuje się jako klasyfikatory neuronowe, dzielące zbiór danych na ustaloną liczbę kategorii wyjściowych. Posiadają budowę trójwarstwową: warstwa wejściowa, ukryta oraz wyjściowa. W przeciwieństwie do sieci RBF, w których stosuje się grupowanie danych i przyjęcie liczby neuronów ukrytych równą liczbie klastrów danych [2, 20, 21], w sieci PNN liczba neuronów ukrytych równa jest liczbie wszystkich próbek uczących [5, 28]. Liczbę neuronów wyjściowych przyjmuje się równą liczbie kategorii klasyfikacji. Każdy neuron radialny modeluje funkcję Gaussa wycelowaną nad jednym wzorcem uczącym. Neurony wyjściowe sumują wartości z wyjść neuronów ukrytych należących do klasy odpowiadającej danemu neuronowi wyjściowemu. Wartości wyjść sieci są proporcjonalne do estymatorów jądrowych funkcji gęstości prawdopodobieństwa dla różnych klas. Po zastosowaniu normalizacji zapewniającej sumowanie do jedności stanowią oszacowanie prawdopodobieństwa przynależności do poszczególnych klas. Wykorzystując ten typ sieci należy odpowiednio dobrać współczynnik wygładzający γ [5, 28]. Reprezentuje on odchylenie radialne funkcji gaussowskich i jest miarą zasięgu neuronów w warstwie ukrytej. Podobnie jak w sieciach RBF musi on być tak określony, aby funkcje gaussowskie odpowiednio na siebie nachodziły [28]. Zbyt mała wartość powoduje utratę własności generalizowania wiedzy przez sieć, a zbyt duża uniemożliwia prawidłowy opis szczegółów (rys. 1). Wartość współczynnika γ dobiera się na drodze eksperymentalnej [28].

Do największych zalet sieci typu PNN należy duża szybkość ich uczenia, natomiast do wad ich złożoność [5, 28].

W przedstawionych badaniach dodatkowo postanowiono wykorzystać algorytmy genetyczne do wyboru zmiennych wejściowych, a w konsekwencji do redukcji liczby wejść i złożoności sieci. Funkcją celu w tym zadaniu stanowiła minimalizacja błędu klasyfikacji.



Rys. 1. Przykład dopasowania wartości wyjściowych sieci radialnej (--) do wzorcowego sygnału (-), (a) $\gamma < \gamma_{opt}$, (b) $\gamma > \gamma_{opt}$

Algorytmy genetyczne (AG) należą do najpopularniejszych algorytmów ewolucyjnych stanowiąc najbardziej znaną metodę optymalizacji stochastycznej [1, 7, 8, 10, 11, 17, 19, 20, 22, 24, 25, 28, 30]. Do najważniejszych zalet algorytmów genetycznych należy prowadzenie poszukiwań w wielu punktach jednocześnie. Poszukiwane rozwiązanie nazywa się osobnikiem, a cały zbiór możliwych rozwiązań populacją. Każdy osobnik posiada stałą liczbę chromosomów, w których parametry zadania reprezentowane są przez sekwencję zakodowanych genów. Najczęściej spotykanym sposobem kodowania jest kod bialleliczny, nazywany również binarnym.

Do cech odróżniających algorytmy genetyczne od konwencjonalnych technik optymalizacyjnych należą [7]:

- operowanie na ciągach kodowych,
- działanie na całej populacji, a nie na pojedynczych punktach,
- poszukiwanie metodą próbkowania,
- losowe reguły wyboru.

Sposób działania algorytmu genetycznego można przedstawić następująco:

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

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

Metody stosowane jako operatory genetyczne zostały szeroko opisane w [1, 7, 8, 10, 11, 17, 19, 20, 22, 24, 25, 28, 30]. Do najważniejszego operatora genetycznego należy operator krzyżowania, zwany również operatorem rekombinacji [7, 19, 30]. Jego zadanie polega na rekombinacji łańcuchów genów poprzez wymianę segmentów łańcuchów pomiędzy chromosomami osobników rodzicielskich [7, 17, 25]. Autorzy [10] piszą, iż głównym celem operatora krzyżowania jest wymiana informacji między ciągami, tak aby wykorzystując najlepsze cechy ciągów rodziców, zbudować jeszcze lepsze ciągi potomstwa. Jak wskazuje [7] w wyniku działania selekcji oraz operatora krzyżowania może zostać utracony potencjalnie użyteczny materiał genetyczny. Zastosowanie operatora mutacji chroni przed tym zjawiskiem. Jednocześnie autor przypisuje temu operatorowi drugorzędną rolę. Operator mutacji jest różnorodnie definiowany w literaturze. Zgodnie z [17], należy go rozumieć jako wprowadzenie pewnej dodatkowej zmienności w populacji. W pozycji [20] Autor pisze, że podstawowym celem stosowania operatora mutacji jest zabezpieczenie algorytmu przed przedczesnym zakończeniem, jak również przed wystąpieniem na danej pozycji we wszystkich chromosomach tej samej wartości. Autor w [7] podaje, iż mutacja polega na zachodzącej z niewielkim prawdopodobieństwem, przypadkowej zmianie wartości elementu ciągu kodowego. W programowaniu ewolucyjnym operator krzyżowania zwykle nie występuje, zaś najważniejszą rolę pełni operator mutacji [19, 22]. Zgodnie z [24, 25] w klasycznym algorytmie genetycznym prawdopodobieństwo wystąpienia krzyżowania przyjmuje się zwykle w przedziale $\langle 0.5, 1 \rangle$, natomiast mutacji $\langle 0, 0.1 \rangle$. Autor [20] podaje zaś, iż krzyżowanie stosuje się z prawdopodobieństwem na poziomie $\langle 0.6, 1 \rangle$, mutacji zaś podaje się zwykle nie więcej niż $1 \div 5\%$ bitów w całej populacji chromosomów. Efekt mutacji jest ściśle skorelowany z długością chromosomu [8]. Autor pisze, że im dłuższy chromosom, tym większa jest oczekiwana liczba genów zmutowanych. Efekt krzyżowania w ogóle nie zależy od długości chromosomu [8].

Dla każdej generacji dokonywana jest selekcja najlepiej przystosowanych osobników. Najczęściej stosowaną metodą wyboru jest selekcja z wykorzystaniem koła ruletki [1, 7, 8, 10, 11, 17, 19, 20, 22, 24, 25, 28, 30]. W metodzie tej każdemu osobnikowi w populacji wyznacza się prawdopodobieństwo jego wyboru jako stosunek wartości jego przystosowania do sumy wartości przystosowania wszystkich osobników w populacji. Na tej podstawie budowane jest koło ruletki, w której każdemu osobnikowi przypisuje się pole o wielkości proporcjonalnej do prawdopodobieństwa jego wyboru. Poprzez wielokrotne uruchomienie koła ruletki dokonuje się wyboru osobników.

W eksperymentach zakładano liczbę populacji oraz epok na poziomie 100.

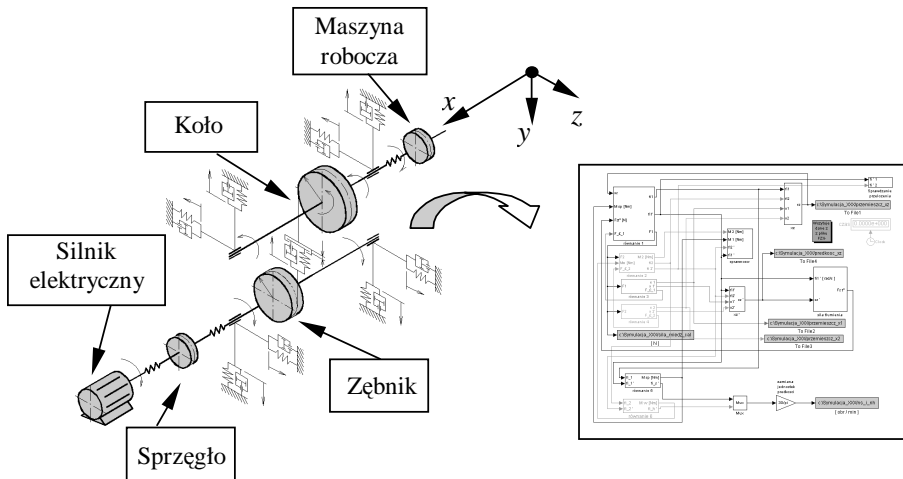
Przykład zastosowania algorytmów genetycznych do celów diagnostyki stanu obiektów technicznych można znaleźć w [11, 13, 27].

1. Obiekt badań

Obiektem badań była przekładnia zębata o zębach prostych o liczbie zębów zębnika 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 [15]. 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 [18].

Na rysunku nr 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 umożliwił 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 [4]. 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 zębownika 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 [4,18]. Odchyłki losowe mogą mieć różne wartości dla różnych zębów zębownika i koła.

Dokładny opis zastosowanego w badaniach modelu (założenia, równania, identyfikację) można znaleźć w [15]. Z uwagi na charakter niniejszej publikacji oraz ograniczenia liczebności stron zrezygnowano z dokładniejszego opisu stosowanego w doświadczeniach modelu przekładni zębatej.

2. Sposób budowy wzorców klas 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, 5, 9, 10, 11, 19, 20, 21, 24, 25, 28, 30].

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 [15].

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:

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

Konieczność pozyskania wystarczającej i obejmującej wszystkie klasyfikowane wzorce uszkodzeń zębów kół przekładni dla systemów opartych na me-

todach 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 powtórzone dla następujących parametrów:

◆ seria pierwsza:

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


◆ seria druga:

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

◆ seria trzecia:

- błąd cykliczny dla zębniaka: $-14 \mu\text{m}$ /długość podziałki,
- błąd cykliczny dla koła: $10 \mu\text{m}$ /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. Zgodnie z Polską Normą PN-90 M-88522 odpowiadało to pracy przekładni w odpowiednio 5 i 6 klasie dokładności wykonania. Przykładowy rozkład błędów losowych w 5 klasie wykonania dla zębniaka i koła przedstawiono na rysunku 3.



Rys. 3. Przykładowy rozkład błędów losowych: (a) zębniak, (b) koło

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 $n = 1800$ obr./min oraz obciążeniu $Q = 2,58$ MPa.

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

Otrzymane z modelu sygnały drganiowe poddano działaniu pięciu filtrów (dolnoprzepustowych w zakresie 6 i 12 kHz, umożliwiających uzyskanie sygnałów resztkowych i różnicowych, w zakresie 0,5÷1,5 częstotliwości zazębienia). Sygnały resztkowe otrzymano poprzez usunięcie z widma pasm częstotliwości zawierających składowe obrotowe wałów kół i ich harmoniczne oraz składowe częstotliwości zazębienia i jej harmoniczne. 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.

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).

Transformata STFT należy do metod, które pozwalają na równoczesną analizę w dziedzinie czasu i częstotliwości. Stosowana jest do sygnałów zmiennych czasowo w sensie amplitudowym i częstotliwościowym, czyli sygnałów niestacjonarnych [32]. Definiowana jest następująco [11]:

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

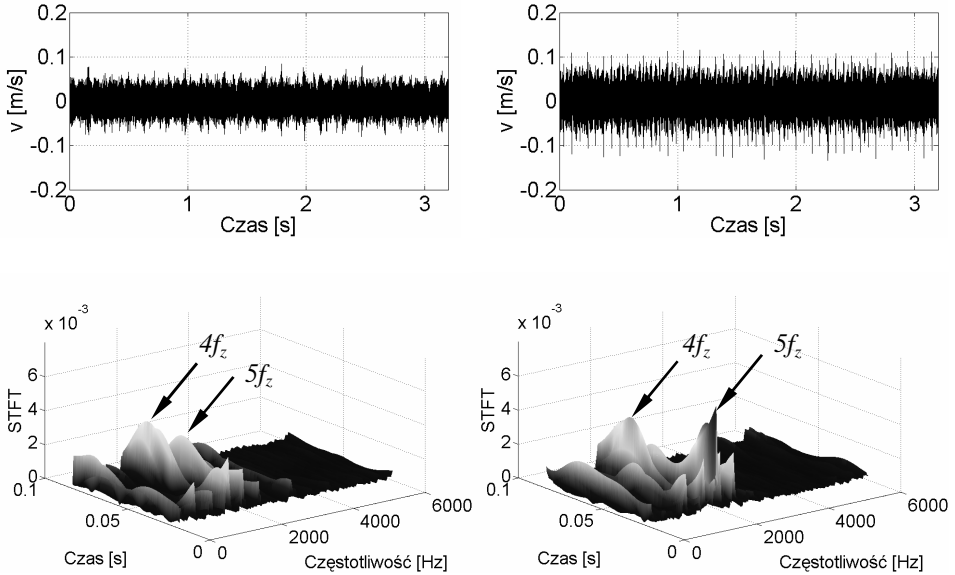
gdzie:

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

b – zadane przesunięcie okna czasowego.

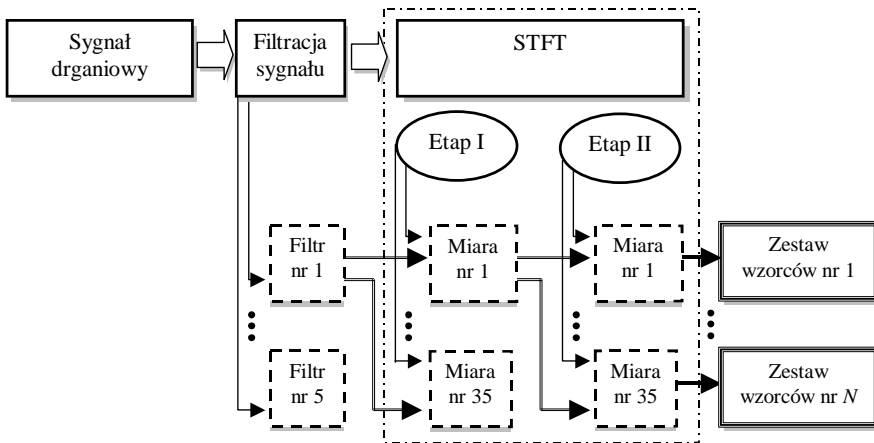
Sygnał czasowy zostaje podzielony na mniejsze części, a następnie dla każdej z nich oblicza się szybką transformatę Fouriera. Zestawienie obok siebie wyznaczonych widm tworzy mapę czasowo-częstotliwościową [32]. Jak podaje autor [31], STFT można również traktować jako grzebień równocześnie pracujących filtrów. W metodzie tej zastosowanie szerokiego okna zwiększa rozdzielczość w dziedzinie częstotliwości, zaś zmniejsza w dziedzinie czasu. Dla wąskiego okna efekt jest odwrotny. W badaniach wykorzystywano okno Hanninga, które zapobiegało wystąpieniu efektu przecieku [14].

Przykładowy rozkład czasowo-częstotliwościowy sygnałów drganiowych otrzymany poprzez zastosowanie analizy STFT przedstawiono na rysunku 4.



Rys. 4. Sygnały czasowe i ich rozkłady STFT: (a) nieuszkodzonego koła, (b) koła z pęknięciem u podstawy zęba

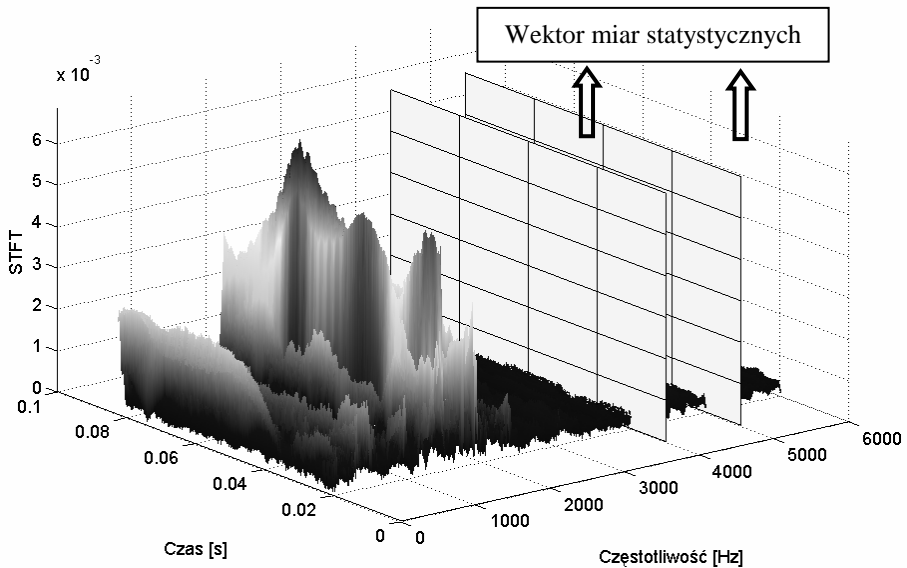
Na rysunku 5 przedstawiono schematycznie sposób postępowania przy budowie wzorców uszkodzeń zębów kół przy wykorzystaniu do tego celu krótko-czasowej transformaty Fouriera.



Rys. 5. Sposób budowy zestawów wzorców

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

Na etapie I dla kolejnych częstotliwości wyznaczono miary statystyczne (rys. 6). 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) [3]. Postępowanie takie miało na celu opis charakteru zmian w dziedzinie czasu, dla kolejnych częstotliwości wyznaczonych zgodnie z założoną częstotliwością próbkowania.



Rys. 6. Sposób pozyskiwania danych wejściowych dla klasyfikatorów neuronowych

Na etapie II z tak otrzymanych charakterystyk częstotliwościowych wyodrębniono zakresy:

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

Zakresy częstotliwości $f \in \langle i \cdot f_z - f_o, i \cdot f_z \rangle$ 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 z użyciem kolejnych filtrów.

W wyniku przeprowadzonych obliczeń zbudowano 17340 zestawów wzorców klas stopnia uszkodzenia zębów kół przekładni. 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).

Ponieważ liczba zestawów wzorców była zbyt duża, aby możliwe było sprawdzenie działania sieci neuronowych nauczonych za ich pomocą, 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.

Na pierwszym etapie za miarę opisującą zmiany charakterystyki STFT 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.

Na drugim etapie badań dla wybranych na etapie 1 miar opisujących przebiegi w dziedzinie częstotliwości sprawdzano przydatność 34 miar do opisu zmiany charakterystyki STFT w czasie. Etap drugi polegał więc na sprawdzeniu przyjętego na wcześniejszym etapie założenia dotyczącego wyboru wartości skutecznej za miarę opisującą charakterystyki w dziedzinie czasu. W tej fazie eksperymentu badania przeprowadzono również przy wykorzystaniu w procesie budowy wzorców pięciu filtrów i trzech sposobów podziału wybranych zakresów częstotliwości na podzakresy.

Na etapie trzecim eksperymentu spośród najlepszych uzyskanych wyników etapów nr 1 i 2 wybrano najlepsze warianty stosowanych miar do opisu zmian w dziedzinie czasu i częstotliwości charakterystyk uzyskanych z analizy STFT. Wyboru dokonano dla różnych wariantów klasyfikatorów uczonych na wzor-

cach zbudowanych z użyciem pięciu filtrów oraz przy podziale na 3, 6 oraz 9 podzakresów.

Dla każdego z wariantów budowy wzorców klas uszkodzeń zębów kół przekładni dobierano dla sieci PNN wartość współczynnika γ . Poszukiwano klasyfikatorów charakteryzujących się jak najniższą wartością błędu klasyfikacji.

3. Wyniki eksperymentu

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.

Wybrane miary były opisane zależnościami:

a) wartość skuteczna

$$x_{RMS} = \sqrt{\frac{1}{T} \int_0^T x^2(t) dt}$$

b) średnia arytmetyczna

$$\bar{x} = \frac{1}{T} \int_0^T x(t) dt$$

c) średnia geometryczna

$$\bar{x}_{geo} = \left(\prod_{i=1}^N x_i \right)^{\frac{1}{N}}$$

d) średnia harmoniczna

$$\bar{x}_{har} = \frac{N}{\sum_{i=1}^N \frac{1}{x_i}}$$

e) energia sygnału

$$x_e = \frac{1}{T} \int_0^T x^2(t) dt$$

f) wartość międzyszczytowa

$$x_{p-p} = \frac{1}{2} \left(\max_{0 < t < T} (x(t)) - \min_{0 < t < T} (x(t)) \right)$$

g) dyskryminanta x4

$$dys_x4 = \frac{\frac{1}{T} \int_0^T (x(t) - \bar{x})^4 dt}{\left(\frac{1}{T} \int_0^T (x(t) - \bar{x})^2 dt \right)^2}$$

h) współczynnik kształtu

$$WK = \frac{x_{RMS}}{\frac{1}{T} \int_0^T |x(t)| dt}$$

i) współczynnik luzu

$$WL = \frac{x_{P-P}}{\left(\frac{1}{T} \int_0^T \sqrt{|x(t)|} dt \right)^2}$$

j) odchylenie przeciętne

$$\sigma_{przec} = \frac{1}{N} \sum_{i=1}^N |x_i - \bar{x}|$$

k) odchylenie ćwiartkowe

$$\sigma_{\acute{c}w} = \frac{1}{2} (Kw_3 - Kw_1) [-]$$

gdzie: Kw_3 – kwartył 3, Kw_1 – kwartył 1

l) pozycyjny współczynnik zmienności

$$PWZ = 100 \left(\frac{\sigma_{\acute{c}w}}{Kw_2} \right) [\%]$$

gdzie: Kw_2 – kwartył 2 (mediana).


Kwartyly, nazywane również percentylami, charakteryzują wartość mierzalną, która dzieli uporządkowany zbiór wszystkich wartości na 25% i 75% – kwartył 1, oraz 75% i 25% – kwartył 3. Kwartył 2 (mediana) określa wartość, poniżej i powyżej której znajduje się jednakowa liczba obserwacji.

Przeprowadzone badania pozwoliły na budowę klasyfikatorów neuronowych, których błąd testowania nie przekraczał 15% (rys. 7).

Najniższe wartości błędu testowania uzyskano dla sieci PNN uczonej z wykorzystaniem danych otrzymanych z sygnału resztkowego i różnicowego. Dla tych wariantów klasyfikatorów wartość błędu wynosiła 4,50÷5,95%. Duży wzrost błędu testowania odnotowano natomiast dla klasyfikatorów uczonych na wzorcach otrzymanych z wykorzystaniem filtra dolnoprzepustowego w zakresie 6 kHz (8,11÷12,43%). Uzyskane charakterystyki nie wykazały znacznego wpływu sposobu podziału na podzakresy na otrzymywaną wartość błędu.

Tabela 1. Estymaty wykorzystywane w procesie budowy wzorców 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	kwartyl 3
6	6	1	kwartyl 3	mediana
7		2	odchylenie przeciętne	kwartyl 1
8		3	dyskryminanta x4	średnia harmoniczna
9		4	wartość skuteczna	odchylenie ćwiartkowe
10		5	wartość skuteczna	średnia harmoniczna
11	3	1	wartość skuteczna	energia sygnału
12		2	wartość skuteczna	współczynnik luzu
13		3	średnia arytmetyczna	odchylenie ćwiartkowe
14		4	wartość międzyszczytowa	kwartyl 3
15		5	kwartyl 3	średnia geometryczna



Rys. 7. Najlepsze uzyskane wyniki dla klasyfikatorów neuronowych typu PNN, A – liczba podzakresów = 9, B – liczba podzakresów = 6, C – liczba podzakresów = 3

Ponieważ założeniem badań było opracowanie klasyfikatora neuronowego charakteryzującego się jak najmniejszym błędem w procesie diagnozowania uszkodzeń zębów kół przekładni, to podjęto dodatkowe próby mające na celu dobór danych wejściowych przy wykorzystaniu do tego celu algorytmów genetycznych. W tym celu wejścia sieci zakodowano jako łańcuch zer i jedynek, gdzie 1 oznaczało, że dane wejście ma zostać, a 0, że nie. W ten sposób uzyskane łańcuchy chromosomów poddawano działaniu operacji krzyżowania i mutacji. Selekcji najlepiej przystosowanych osobników, to znaczy zestawu wejść, dokonywano z wykorzystaniem metody koła ruletki. W badaniach założono, że


efektem tego postępowania będzie uzyskanie dla każdego wariantu sposobu budowy zestawu wzorców niższej wartości błędu testowania.

W wyniku przeprowadzenia doświadczeń z wykorzystaniem algorytmów genetycznych do doboru wejść sieci neuronowych PNN, uzyskano architektury sieci o znacznie mniejszej złożoności. Liczbę wejść klasyfikatorów neuronowych przed i po procesie ich doboru przedstawiono w tabeli 2.

Tabela 2. Liczba wejść klasyfikatorów PNN przed i po zastosowaniu algorytmów genetycznych

Lp.	Liczba podzakresów	Nr filtru	Liczba wejść klasyfikatora PNN	
			przed zastosowaniem algorytmów genetycznych	po zastosowaniu algorytmów genetycznych
1	9	1	192	126
2		2	192	153
3		3	192	31
4		4	192	77
5		5	192	38
6	6	1	144	87
7		2	144	106
8		3	144	50
9		4	144	63
10		5	144	36
11	3	1	96	30
12		2	96	52
13		3	96	22
14		4	96	25
15		5	96	28

Najlepsze uzyskane poziomy błędów testowania dla sieci neuronowych typu PNN z wejściami dobranymi z użyciem algorytmów genetycznych przedstawiono na rysunku 8.



Rys. 8. Najlepsze uzyskane wyniki dla klasyfikatorów neuronowych typu PNN z dobranymi wejściami przy użyciu algorytmów genetycznych, A – liczba podzakresów = 9, B – liczba podzakresów = 6, C – liczba podzakresów = 3

Również w tej części przeprowadzonych badań najmniejszym poziomem błędu odznaczały się sieci neuronowe wykorzystujące dane otrzymane z sygnału różnicowego i resztkowego (filtr nr 3 i 4). Niezależnie od liczby zastosowanych podzakresów błęd testowania dla sygnałów różnicowych wyniósł 4,86%, co było najniższą wartością błędu. Niewielkie różnice w otrzymanych wartościach błędu testowania pomiędzy tymi filtrami przemawiają za wyborem filtra różnicowego, jako najwłaściwszego do stosowania przy budowie wzorców z wykorzystaniem analizy STFT.

W przypadku trzech sposobów podziału na podzakresy różnice w wielkości błędu klasyfikatorów wykorzystujących wzorce otrzymane z danego filtru są niewielkie.

Dla większości zestawów wzorców wykorzystanych w eksperymencie błąd testowania uzyskany po zastosowaniu w procesie optymalizacji liczby wejść algorytmów genetycznych zmniejszył się. Szczególnie znaczącą poprawę procesu klasyfikacji uszkodzeń zębów kół przekładni można zauważyć dla sieci neuronowych uczonych na danych otrzymanych z użyciem filtru dolnoprzepustowego w zakresie 6 kHz. Poprawa w wartości uzyskiwanego błędu testowania sięgała nawet 45%. Fakt ten można uznać za potwierdzenie przydatności stosowania algorytmów genetycznych w procesie budowy klasyfikatorów typu PNN.

Równocześnie należy zauważyć przypadki, w których otrzymano gorsze rezultaty niż dla sieci bez dobranych wejść. Różnice w wartości błędu były jednak niewielkie. Pokreślić tutaj należy, iż sieci neuronowe o mniejszych architekturach uczy się i eksploatuje łatwiej niż te o bardzo złożonych strukturach. Dlatego też w procesie budowy klasyfikatorów neuronowych powinno się brać również pod uwagę złożoność architektury sieci.

Podsumowanie

W artykule przedstawiono eksperyment mający na celu budowę klasyfikatora rodzaju i stopnia uszkodzenia zębów kół przekładni przy wykorzystaniu do tego celu probabilistycznej sieci neuronowej.

System diagnostyczny oparto na danych pochodzących z sygnałów drgań poprzecznych wału koła poddanych odpowiedniej filtracji oraz przetwarzaniu z użyciem krótkoczasowej transformaty Fouriera (STFT). Wystarczająco zróżnicowana i liczna baza wiedzy została pozyskana ze zidentyfikowanego modelu dynamicznego przekładni zębatej pracującej w układzie napędowym.

W przeprowadzonych eksperymentach sprawdzono przydatność zastosowania algorytmów genetycznych w celu doboru wejść sztucznych sieci neuronowych. Wyniki uzyskane w doświadczeniu wykazały, że dla większości analizowanych przypadków, po zastosowaniu w procesie optymalizacji liczby wejść algorytmów genetycznych, błąd klasyfikacji uległ zmniejszeniu.

Można równocześnie przypuszczać, że zwiększenie liczby populacji oraz epok wpłynęłoby na jeszcze większą poprawę uzyskiwanych wyników. Przeprowadzenie takich eksperymentów wymagałoby jednak znacznych nakładów czasowych.

Nakłady czasowe spowodowały również ograniczenie badań do pracy przekładni zębatej przy jednej prędkości obrotowej wałów i jednej wartości obciążenia. Uzyskanie założonej liczby przypadków stanowiących dane dla sieci neuronowych wymagało wielokrotnego (1111) przeprowadzenia procesu symulacji pracy przekładni zębatej przy użyciu zidentyfikowanego modelu dynamicznego. Każda symulacja wymaga dużego nakładu czasowego. Sprawdzenie zaproponowanych sposobów budowy klasyfikatorów przekładni pracującej przy różnych prędkościach obrotowych i różnych obciążeniach wymaga dalszych badań.

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.

Bibliografia

1. Arabas J.: Wykłady z algorytmów ewolucyjnych. Wydawnictwa Naukowo-Techniczne. Warszawa 2001.
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. Czech P.: Wykrywanie uszkodzeń przekładni zębatych za pomocą metod sztucznej inteligencji. Rozprawa doktorska. Katowice 2006.
4. Dąbrowski Z., Radkowski St., Wilk A.: Dynamika przekładni zębatych. Badania i symulacja w projektowaniu eksploatacyjnie zorientowanym. ITeE. Radom 2000.
5. Gatety E.: Sieci neuronowe. Prognozowanie finansowe i projektowanie systemów transakcyjnych. WIG-Press. Warszawa 1999.
6. Giurgiutiu V., Cuc A., Goodman P.: Review of vibration-based helicopters health and usage monitoring methods. 55th Meeting of the Society for Machinery Failure Prevention Technology. Virginia Beach 2001, s. 635÷645.
7. Goldberg D. E.: Algorytmy genetyczne i ich zastosowania. Klasyka informatyki. Wydawnictwa Naukowo-Techniczne. Warszawa 2003.
8. Gwiazda T.: Algorytmy genetyczne. Zastosowania w finansach. Wydawnictwo Wyższej Szkoły Przedsiębiorczości i Zarządzania im. L. Koźmińskiego. Warszawa 1998.

9. Hu Y. H., Hwang J. N.: Handbook of neural network signal processing. CRC Press 2002.
10. Knosala R., Ćwikła G., Grabowik C., Gwiazda A., Kalinowski K., Kampa A., Kopeć A., Paszek A., Piłot T., Pondo K., Wal T.: Zastosowanie metod sztucznej inteligencji w inżynierii produkcji. Wydawnictwa Naukowo-Techniczne. Warszawa 2002.
11. Korbicz J., Kościelny J., Kowalczyk Z., Cholewa W. (praca zbiorowa): Diagnostyka procesów. Modele. Metody sztucznej inteligencji. Zastosowania. Wydawnictwa Naukowo-Techniczne. Warszawa 2002.
12. Krishnappa G., Donovan M.: Some examples of signal analysis techniques to diagnose faults in machines. 6th International Congress on Sound and Vibration. Copenhagen, Denmark 1999, s. 2923÷2936.
13. Liang Z., Lindsay B., Asoke N.: Fault detection using genetic programming. Mechanical Systems and Signal Processing 19 (2005), s. 271÷289.
14. Lyons R. G.: Wprowadzenie do cyfrowego przetwarzania sygnałów. Wydawnictwa Komunikacji i Łączności. Warszawa 2000.
15. Łazarz B.: Zidentyfikowany model dynamiczny przekładni zębatej jako podstawa projektowania. Studia i Rozprawy. Instytut Technologii Eksploatacji. Katowice–Radom 2001.
16. Madej H., Wilk A., Łazarz B.: The application of time-frequency analysis in diagnostics of local damages of toothed gears. 6th International Conference on Rotor Dynamics. IFToMM. Sydney 2002, s. 706÷713.
17. Michalewicz Z.: Algorytmy genetyczne + struktury danych = programy ewolucyjne. Wydawnictwa Naukowo-Techniczne. Warszawa 2003.
18. Müller L.: Przekładnie zębate. Dynamika. Wydawnictwa Naukowo-Techniczne. Warszawa 1986.
19. Nałęcz M., Duch W., Korbicz J., Rutkowski L., Tadeusiewicz R.: Sieci neuronowe. Biocybernetyka i Inżynieria Biomedyczna, tom 6. Akademicka Oficyna Wydawnicza EXIT. Warszawa 2000.
20. Osowski St.: Sieci neuronowe do przetwarzania informacji. Oficyna Wydawnicza Politechniki Warszawskiej. Warszawa 2000.
21. Osowski St.: Sieci neuronowe w ujęciu algorytmicznym. Wydawnictwa Naukowo-Techniczne. Warszawa 1996.
22. Pawlak M.: Algorytmy ewolucyjne jako narzędzie harmonogramowania produkcji. Wydawnictwo Naukowe PWN. Warszawa 1999.
23. Radkowski St.: Wibroakustyczna diagnostyka uszkodzeń niskoenergetycznych. Biblioteka Problemów Eksploatacji. Warszawa-Radom 2002.
24. Rutkowska D.: Inteligentne systemy obliczeniowe. Algorytmy genetyczne i sieci neuronowe w systemach rozmytych. Problemy współczesnej nauki. Teoria i zastosowania. Akademicka Oficyna Wydawnicza PLJ. Warszawa 1997.

25. Rutkowska D., Piliński M., Rutkowski L.: Sieci neuronowe, algorytmy genetyczne i systemy rozmyte. Wydawnictwo Naukowe PWN. Warszawa-Łódź 1997.
26. Samuel P., Pines D.: A review of vibration-based techniques for helicopter transmission diagnostics. *Journal of Sound and Vibration* 282 (2005), s. 475÷508.
27. Samanta B.: Artificial neural networks and genetic algorithms for gear fault detection. *Mechanical Systems and Signal Processing* 18 (2004), s. 1273÷1282.
28. Tadeusiewicz R., Lula P.: Wprowadzenie do sieci neuronowych. StatSoft. Kraków 2001.
29. 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.
30. Zieliński J. S.: Inteligentne systemy w zarządzaniu. Teoria i praktyka. Wydawnictwo Naukowe PWN. Warszawa 2000.
31. Zieliński T. P.: Cyfrowe przetwarzanie sygnałów. Od teorii do zastosowań. Wydawnictwa Komunikacji i Łączności. Warszawa 2005.
32. 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.

Recenzent:
Stanisław OSOWSKI

The use of genetic algorithms in the task of choosing inputs for PNN neural network classifier of faults of gear-tooth which used inputs from STFT analysis

Key words

Diagnostic testing of toothed gears, artificial intelligent methods, PNN, genetic algorithms, short time Fourier transform.

Summary

The present paper presents the results of an experimental application of probabilistic neural network as a classifier of the degree of cracking root of the tooth in a gear wheel.

The input data for the classifier was in a form of matrix composed of statistical measures, obtained from short time Fourier transform. The model of gearbox was used in order to create a base of knowledge.

In the experiment genetic algorithms was used to check influence of choosing inputs for neural classifier on diagnostic error.