

Piotr CZECH

## WYKORZYSTANIE PROBABILISTYCZNYCH SIECI NEURONOWYCH I SYGNAŁÓW DRGANIOWYCH DO DIAGNOZOWANIA USZKODZENIA USZCZELKI POD GŁOWICĄ SILNIKA ZS

**Streszczenie.** W przeprowadzonych badaniach podjęto próbę określenia występującego uszkodzenia uszczelki pod głowicą silnika ZS. Za obiekt badań posłużył model samochodu Ford Mondeo, napędzany silnikiem ZS o pojemności 2,0 [dm<sup>3</sup>]. Uszkodzenie uszczelki polegało na przerwaniu mostka pomiędzy 1 i 2 cylindrem. Do diagnozowania uszkodzenia wykorzystano sygnały drganiowe, generowane przez silnik – wstępnie przetworzone przy wykorzystaniu dyskretnej transformaty falkowej, oraz probabilistyczne sieci neuronowe.

**Słowa kluczowe.** Diagnostyka, drgania, probabilistyczne sieci neuronowe, silniki spalinowe ZS, pojazdy samochodowe.

## APPLICATION OF PROBABILISTIC NEURAL NETWORK AND VIBRATION SIGNALS FOR GASKET UNDER DIESEL ENGINE HEAD DAMAGE

**Summary.** Conducted tests attempted to determine the occurring damage in gasket under engine head. Test object was Ford Mondeo car powered by diesel engine with capacity of 2.0 [dm<sup>3</sup>]. Damage of the gasket was a rupture of bridge between 1 and 2 cylinder. In order to diagnose the damage the vibration signals generated by the engine were used – initially processed with the use of discrete wavelet transform and probabilistic neural networks.

**Keywords.** Diagnostics, vibrations, probabilistic neural networks, diesel engines, car vehicles.

### 1. WPROWADZENIE

W przypadku wystąpienia usterki powodującej wzrost temperatury silnika spalinowego, uszkodzeniu w pierwszej kolejności najczęściej ulega uszczelka głowicy silnika, której zadaniem jest zapewnienie szczelności pomiędzy głowicą, a kadłubem silnika. Istotą działania uszczelki jest wyrównanie nierówności na płaszczyznach podziału od strony kadłuba oraz głowicy poprzez jej plastyczne odkształcenie [13, 14].

Uszkodzeniu uszczelki towarzyszy:

- pojawienie się plam oleju na silniku i pod samochodem,
- wystąpienie śladów emulsji olejowej na wyciągniętym bagnecie, korku wlewu oleju lub w zbiorniku wyrównawczym płynu chłodzącego,
- trudności z rozruchem zimnego silnika,
- stale występujące ubytki niewielkich ilości płynu chłodzącego.

Uszczelkom stawiane są wysokie wymagania, które bezpośrednio wynikają z warunków ich pracy, w tym:

- odporność termiczna (możliwość rozruchu silnika przy temperaturze  $-30$  [°C], a równocześnie możliwość wystąpienia temperatur rzędu  $300$  [°C] na niechłodzonych mostkach kadłuba lub głowicy),
- odporność na nagłe wzrosty ciśnienia spalania (efekt „podskakiwania“ uszczelki),
- odporność chemiczna (kontakt z olejem silnikowym, płynem chłodzącym, spalinami i pozostałościami z procesu spalania),
- stabilność kształtu (odporność na wysokie siły ścinające, wytrzymałość na rozerwanie wąskich mostków, kompensacja wynikająca z różnej rozszerzalności cieplnej materiałów elementów systemu),
- duża dokładność grubości uszczelki (zagwarantowanie równomiernego stopnia sprężania),
- dobra przewodność cieplna w uszczelnianej szczelinie oraz między uszczelnianymi elementami.

## 2. OPIS BADAŃ

W silniku ZS o pojemności  $2,0$  [dm<sup>3</sup>] samochodu marki Ford Mondeo zasymulowano uszkodzenie uszczelki głowicy silnika w postaci przerwania mostka pomiędzy sąsiednimi cylindrami.

W trakcie eksperymentów na hamowni podwoziowej mierzono sygnały przyspieszeń drgań głowicy silnika w okolicy zaworów wylotowego i dolotowego 1. cylindra, zaworu wylotowego 4. cylindra oraz na skrzyni biegów. Sygnały rejestrowano w biegach 1, 2, 3, 4 i 5 dla prędkości obrotowej silnika:

- $1500$  [obr/min],
- $2000$  [obr/min],
- $3000$  [obr/min].

Dodatkowo, wykonano pomiary na biegu luzem dla prędkości obrotowej silnika wynoszącej  $1500$  [obr/min] i  $2000$  [obr/min].

Zarejestrowane sygnały wibroakustyczne zostały wstępnie przetworzone przy wykorzystaniu dyskretnej transformaty falkowej. Dyskretną transformatę falkową można zdefiniować jako iloczyn skalarne badanego sygnału  $x(t)$  i ciągu funkcji bazowych  $\psi(t)$ :

$$DWT = \int_{-\infty}^{+\infty} \psi(t) \cdot x(t) dt \quad (1)$$

W wyniku wielopoziomowej dekompozycji sygnału otrzymuje się aproksymację sygnału na danym poziomie  $a_j$  oraz sumę detali na kolejnych poziomach  $d_j$ :

$$x(t) = a_j(t) + \sum_{j=1}^J d_j(t) \quad (2)$$

gdzie:

$a_j$  – reprezentacja małowartościowości sygnału,  
 $d_j$  – składnik wielowartościowości sygnału.

Wraz ze zwiększeniem poziomu dekompozycji sygnału udział detali maleje. Powoduje to, że wraz ze zmniejszeniem rozdzielczości maleje zawartość szczegółów w aproksymacji sygnału [1].

Aby opisać charakter zmian zdekomponowanego przy użyciu analizy falkowej sygnału wibroakustycznego, przyjęto dwie drogi postępowania. Pierwsza, zakłada wykorzystanie entropii sygnału jako miary charakteryzującej zmiany w sygnale. Można ją wyznaczyć z zależności:

$$E_{Sh} = - \sum_j x_j^2(t) \cdot \log(x_j^2(t)) \quad (3)$$

gdzie

$x_j$  – analizowany sygnał wibroakustyczny.

Druga droga postępowania zakłada wykorzystanie energii sygnału do opisu zmian zachodzących w sygnale wibroakustycznym. Przyjęto tutaj, zgodnie z definicją dyskretnej transformaty falkowej, że całkowita energia sygnału przed dekompozycją jest równa sumie energii aproksymacji i kolejnych detali. Całkowitą energię sygnału po dekompozycji na określonej liczbie poziomów przyjęto jako 100[%] i wyznaczono, jaki procent tej energii stanowią sygnały aproksymacji i kolejnych detali.

Na podstawie przyjętych dwóch dróg postępowania, przyjęto dwa typy wzorców wykorzystywanych w procesach uczenia i testowania sieci neuronowych.

Przystępując do budowy wzorców należało określić na ilu poziomach będzie rozkładany sygnał bazowy oraz jaka falka bazowa będzie wykorzystywana. W badaniach postanowiono sprawdzić przydatność różnych falek bazowych. Wykorzystano falki z rodziny: haar, daubechies, biorthogonal, coiflets, symlets, reverse biorthogonal, discrete meyer. W przeprowadzanych eksperymentach sprawdzano przydatność utworzonych zestawów wzorców dla kolejnych poziomów dekompozycji, otrzymując zestawy o różnych rozmiarach.

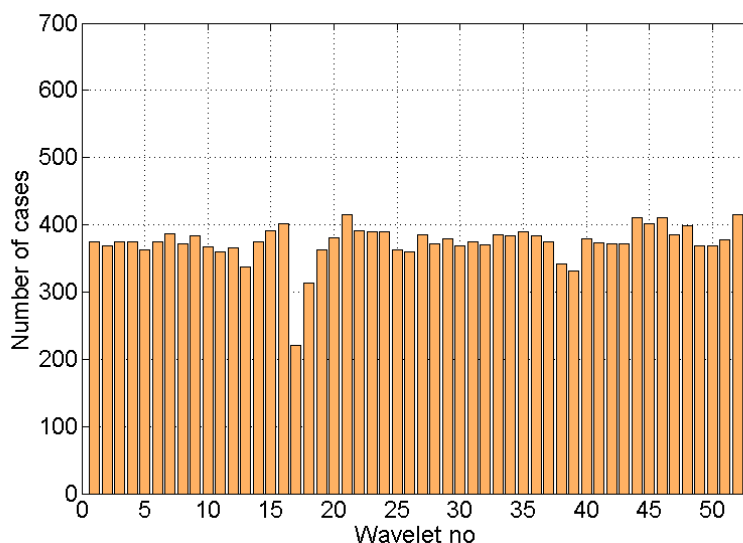
W eksperymentach wykorzystano probabilistyczne sieci neuronowe [2, 7]. Na wybór tego typu sieci wpłynęła jej łatwość i szybkość uczenia. W przeprowadzonych badaniach sieci sprawdzano pod względem poprawności klasyfikacji wzorców, przy różnych parametrach współczynnika  $\gamma$ .

### 3. WYNIKI BADAŃ


W celu określenia najlepszej falki bazowej w procesie budowy wzorców, stworzono kilkadziesiąt grup klasyfikatorów, które uczono na danych pochodzących z sygnałów zarejestrowanych w konkretnym punkcie pomiarowym (4 punkty pomiarowe), dla silnika pracującego na danym biegu (5 biegów), przy określonej prędkości (3 prędkości, a dla biegu luzem – 2). Każdą z 68 grup sprawdzano dla wzorców zbudowanych z wykorzystaniem energii lub entropii sygnału rozłożonego na 10 wariantów liczby poziomów dekompozycji.

W celu określenia najlepszej falki bazowej, wykorzystywanej do budowy deskryptorów, skorzystano z otrzymanych rozkładów liczby przypadków, dla których - przy użyciu danej falki bazowej - klasyfikatory charakteryzowały się minimalną wartością błędów.

Liczbę przypadków, dla których przy wykorzystaniu danej falki w procesie budowy wzorców klasyfikator osiągał wartość minimalną pokazano na rysunkach 1 i 2.



Rys. 1. Rozkład liczby przypadków, dla których błędy klasyfikacji były minimalne – wzorce energia  
 Fig. 1. Arrangement of number of cases in which the classification errors were minimum – models energy

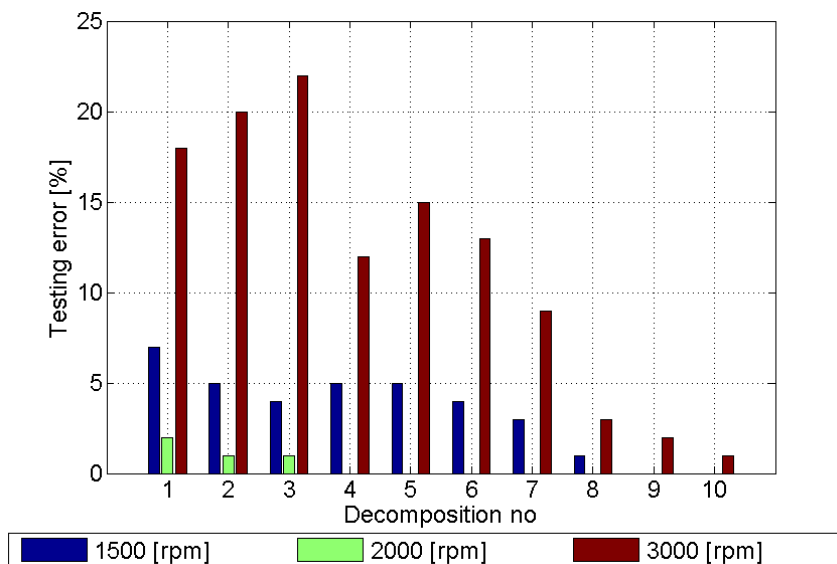


Rys. 2. Rozkład liczby przypadków, dla których błędy klasyfikacji były minimalne – wzorce entropia  
 Fig. 2. Arrangement of number of cases in which the classification errors were minimum – models entropy

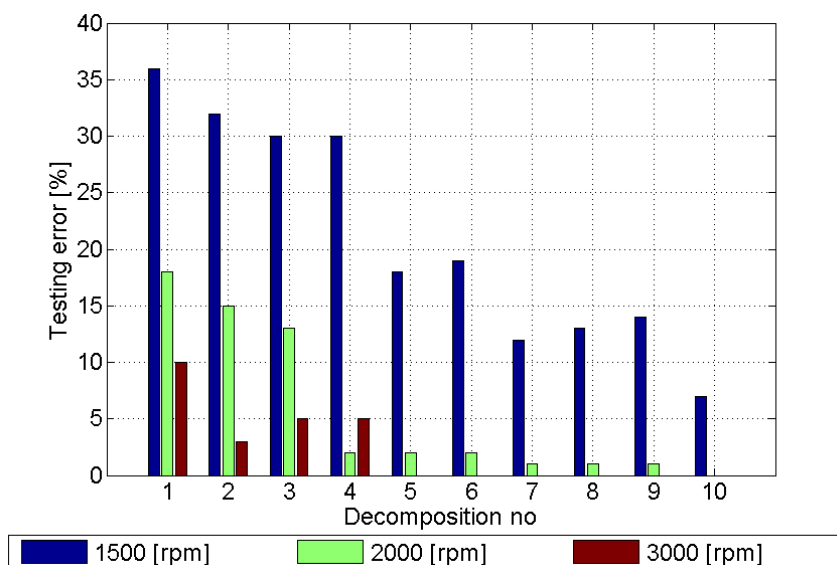
Łączna liczba przypadków, dla których klasyfikatory osiągały minimalne wartości błędów przy wykorzystaniu danych wzorców były na poziomie około 300÷400 – dla energii oraz około 400÷500 – dla entropii. W przypadku wykorzystania w procesie budowy wzorców energii sygnału, za najgorszą falkę zdecydowanie można uznać falkę o nazwie bior3.1, natomiast dla entropii falkę rbio3.1. Wybór najlepszej nie jest już tak oczywisty. W przypadku wykorzystywania entropii, najlepsze wyniki osiągnięto dla falki dmey, natomiast dla energii,

były to falki: bior2.8, bior3.9, rbio3.1, rbio3.3, rbio3.5, rbio3.9, dmey. Co ciekawe, zmieniając w trakcie procesu budowy wzorców energię na entropię, w przypadku falki rbio3.1 uzyskuje się albo jeden z najlepszych, albo najgorszy wariant.

Na podstawie uzyskanych wyników trudno jest jednoznacznie określić wpływ wyboru liczby poziomów dekompozycji w procesie budowy wzorców. Występują jednak przypadki, dla których można zauważyć zmniejszenie występującego błędu wraz ze zwiększeniem rozmiaru wzorców. Takie przykłady zobrazowano na rysunkach 3 i 4.



Rys. 3. Przykładowe najlepsze wyniki uzyskane dla klasyfikatorów PNN – wzorce energia  
Fig. 3. Sample the best results achieved for PNN classifiers – models energy



Rys. 4. Przykładowe najlepsze uzyskane wyniki dla klasyfikatorów PNN – wzorce: entropia  
Fig. 4. Sample the best results achieved for PNN classifiers – models: entropy

Dla większości badanych wariantów udało się uzyskać bezbłędnie lub bliskie bezbłędnie działającym klasyfikatorom.

#### 4. WNIOSKI

W wielu ośrodkach na całym świecie prowadzone są badania dotyczące monitorowania różnych parametrów, związanych z pracą dzisiejszych, skomputeryzowanych środków transportu. Przykłady można znaleźć w [2-4, 8-10, 16]. Rozwój dziedzin związanych z najnowocześniejszymi technologiami nie ogranicza badań podstawowych mających doprowadzić do podobnych, wymiernych efektów przykładowo zwiększenia bezpieczeństwa poprzez zwiększenie trwałości elementów układów napędowych [5, 6, 11, 12, 15].

W artykule przedstawiono wyniki eksperymentów, mających na celu próbę budowy poprawnie działającego klasyfikatora neuronowego, diagnozującego występujące uszkodzenie jednego z elementów silnika spalinowego – uszczelki pod głowicą silnika.

Uzyskane wyniki wskazują na możliwość budowy poprawnie działającego systemu diagnozującego tego typu uszkodzenie, przy wykorzystaniu do tego celu odpowiednio przetworzonych sygnałów drganiowych oraz probabilistycznych klasyfikatorów neuronowych.

#### Bibliografia

1. Białasiewicz J.: Falki i aproksymacje. WNT, Warszawa, 2000.
2. Czech P., Łazarz B., Wojnar G.: Wykrywanie lokalnych uszkodzeń zębów kół przekładni z wykorzystaniem sztucznych sieci neuronowych i algorytmów genetycznych. Biblioteka Problemów Eksploatacji. Instytut Technologii Eksploatacji. Radom 2007.
3. Figlus T.: Diagnozowanie luzu zaworowego silnika na podstawie zmian energetycznych sygnału drganiowego. Maintenance Problems (Problemy Eksploatacji), 1/2009 (72), s. 75-84.
4. Figlus T., Wilk A.: Diagnozowanie stanu mechanizmu rozrządu silnika ZS metodą pomiaru i analizy hałasu. Zeszyty Naukowe Instytutu Pojazdów 3(75)/2009, Politechnika Warszawska, Wydział Samochodów i Maszyn Roboczych, s. 105-114.
5. Grega R., Homišin J., Kaššay P., Krajňák J.: The analyse of vibrations after changing shaft coupling in drive belt conveyer. Zeszyty Naukowe Politechniki Śląskiej, s. Transport, z. 72 / 2011, s. 23-31.
6. Hadryś D., Miros M., Węgrzyn T., Silva A. P.: Wpływ metod spawalniczych w naprawach modelowych elementów energochłonnych stalowego nadwozia pojazdu na wybrane parametry opisujące zderzenie. Aparatura Badawcza i Dydaktyczna, t. 16, nr 3, 2011, s. 109-116.
7. Lula P., Tadeusiewicz R.: Wprowadzenie do sieci neuronowych. Wydawnictwo StatSoft, Kraków 2001.
8. Mikulski J. (ed.): Modern Transport Telematics. Communications in Computer and Information Science 239(2011), Springer-Verlag.
9. Młyńczak J.: Analysis of intelligent transport systems (ITS) in public transport of upper Silesia. CCIS 239(2011), p. 164-171.

10. Puškár M., Bigoš P., Puškárová P.: Accurate measurements of output characteristics and detonations of motorbike high-speed racing engine and their optimization at actual atmospheric conditions and combusted mixture composition. *Measurement*, 45 (2012), p. 1067-1076.
11. Silva A. P., Mateus C. S., Węgrzyn T., Miros M.: High speed machining of aluminium gear box without temperature stabilization. I Scientific Conference „Transport Problems“, Kroczyce 17-19 czerwiec 2009.
12. Urbanský M., Homišin J., Krajňák J.: Analysis of the causes of gaseous medium pressure changes in compression space of pneumatic coupling. *Transactions of the Universities of Košice*, vol. 2/2011, p. 35-40.
13. Wajand J.A., Wajand J.T.: *Tłokowe silniki spalinowe średnio i szybkoobrotowe*. WNT, Warszawa 2005.
14. Węgiel S., Wiśniewski K., Zawadzki J.: Uszczelki głowicy silnika. *Poradnik serwisowy. Kompendium praktycznej wiedzy warsztatowej*, nr 6 / 2004.
15. Węgrzyn T., Piwnik J.: Low alloy welding with micro-jet cooling. *Archives of Metallurgy and Materials*, z. 2, t. 57, nr 1, 2012.
16. Zuber N., Ličen H., Klačnja-Miličević A.: Remote online condition monitoring of the bucket wheel excavator SR1300 – a case study, *Facta Universitatis, Series: Working and Living Environmental Protection*, vol. 1(5), 2008, p. 25-37.