

Piotr CZECH

## WYKORZYSTANIE PROBABILISTYCZNYCH SIECI NEURONOWYCH I SYGNAŁÓW DRGANIOWYCH DO DIAGNOZOWANIA USZKODZEŃ WTRYSKIWACZY SILNIKA ZS

**Streszczenie.** W przeprowadzonych badaniach podjęto próbę określenia występującego uszkodzenia wtryskiwaczy w silniku spalinowym samochodu. Za obiekt badań posłużył samochód Ford Mondeo, napędzany silnikiem ZS o pojemności 2,0 [dm<sup>3</sup>]. Do diagnozowania uszkodzenia wykorzystano sygnały drganiowe, generowane przez silnik – wstępnie przetworzone przy wykorzystaniu dyskretnej transformaty falkowej, oraz probabilistyczne sieci neuronowe. W artykule zaproponowano wykorzystanie analizy DWT oraz energii lub entropii, będących podstawą systemu diagnozującego.

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

## APPLICATION OF PROBABILISTIC NEURAL NETWORK AND VIBRATION SIGNALS FOR DIESEL CAR ENGINE FUEL INJECTORS DAMAGE

**Summary.** Conducted tests attempted to determine the occurring damage of fuel injectors in car combustion engine. Test object was Ford Mondeo car powered by diesel engine with capacity of 2.0 [dm<sup>3</sup>]. 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. In this article is proposed using DWT analysis and energy or entropy which are a base for diagnostic system.

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

### 1. WPROWADZENIE

Zadaniem systemu wtryskowego jest przygotowanie parametrów paliwa w sposób umożliwiający poprawną pracę silnika przy zachowaniu maksymalnej ekologiczności. To właśnie kryterium związane z emisją szkodliwych substancji jest obecnie najważniejsze.

Dokładne omówienie zagadnień związanych z budową i działaniem silników spalinowych samochodów, w tym układów wtryskowych, można znaleźć w [6], [7], [16], [17].

Jak podaje literatura branżowa dla serwisów motoryzacyjnych, wiele symptomów nieprawidłowej pracy silnika jest wynikiem złego stanu technicznego wtryskiwaczy. W praktyce warsztatowej najczęstszymi objawami są:

- niestabilna praca na biegu jałowym,
- zwiększona emisja składników toksycznych w spalinach,
- mniejsza moc silnika,
- zła praca katalizatora i sondy lambda,
- utrudniony rozruch,
- sygnalizacja awarii przez lampkę MIL.

## 2. OPIS BADAŃ

Wykorzystując silnik ZS o pojemności 2,0 [dm<sup>3</sup>] samochodu marki Ford Mondeo podjęto próby określenia uszkodzenia wtryskiwacza w postaci braku jego działania. W trakcie badań na hamowni podwozowej rejestrowano sygnały drganiowe przy działającym i wyłączonym wtryskiwaczu. W trakcie eksperymentów mierzono sygnały przyspieszeń drgań głowicy silnika w okolicy zaworów wylotowego i dolotowego 1. cylindra, zaworu wylotowego 4. cylindra oraz na skrzyni biegów. Sygnały rejestrowano na biegach 1, 2, 3, 4 i 5, dla prędkości obrotowej silnika, wynoszących 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  $x(t)$  zostały wstępnie przetworzone przy wykorzystaniu dyskretnej transformaty falkowej [1]:

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

gdzie

$\psi(t)$  – funkcja bazowa.

W wyniku wielopoziomowej dekompozycji sygnału otrzymuje się aproksymacje 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 małoczęstotliwościowa sygnału,

$d_j$  – składnik wieloczęstotliwościowy sygnału.

Celem opisu charakteru zmian zdekomponowanego – przy użyciu analizy DWT – sygnału WA, przyjęto dwie metody.

W pierwszej wykorzystywano entropię sygnału jako miary charakteryzującej zmiany w sygnale  $x_j$ :

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

W drugiej używano energii sygnału do opisu zmian zachodzących w sygnale wibroakustycznym. Zgodnie z definicją dyskretnej transformaty falkowej przyjęto, że całkowita energia sygnału przed dekompozycją jest równa sumie energii aproksymacji i kolejnych detali. Całkowita energia sygnału po dekompozycji na określonej liczbie poziomów wynosi 100 [%]. Wyznaczono, jaki procent tej energii stanowią sygnały aproksymacji i kolejnych detali.

Na podstawie zaproponowanych dwóch metod 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 przeprowadzonych badaniach wykorzystano probabilistyczne sieci neuronowe [2], [5], [8]. W eksperymentach, 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 błędu.


Rysunki 1 i 2 przedstawiają rozkłady liczby przypadków, przy których klasyfikatory, uczone na danych otrzymanych z wykorzystaniem danej falki, osiągały minimalne wartości błędu.

Porównując ze sobą rozkłady otrzymane dla wariantów wykorzystujących w procesie budowy wzorców energię i entropię sygnału można zauważyć, że mają one podobny charakter zmian. Widać, że niezależnie od tego wyboru, dla danych falek otrzymywano niższe wartości, a dla innych wyższe. W przypadku wariantu wykorzystującego entropię sygnału, najlepszą falką wydaje się falka o nazwie dmey. Dla wariantu z energią, kilka falek bazowych charakteryzowało się podobnym poziomem. W przypadku obu wariantów, najgorsze wyniki uzyskiwano dla falek rbio3.1 oraz bior3.1 – dla wariantu z energią.

Osiągane przez klasyfikatory minimalne wartości błędu dla danego badanego wariantu były tak niewielkie (często zerowe), że niemożliwe było określenie wpływu wybranej liczby poziomów dekompozycji sygnału.



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

#### 4. WNIOSKI

Przeprowadzone badania pokazują, że możliwe jest wykorzystanie sygnałów wibroakustycznych do określania stanu technicznego obiektów, w tym elementów silników spalinyowych pojazdów. Podobne wnioski można też znaleźć w literaturze – przykładowo w [2-5], [9], [11], [19].

W eksperymentach z powodzeniem wykorzystano jedną z metod sztucznej inteligencji w postaci probabilistycznych sieci neuronowych [2], [5], [8]. W literaturze można również spotkać wiele innych zastosowań diagnostycznych przy wykorzystaniu do tego celu metod sztucznej inteligencji – przykładowo w [2], [5], [9], [11].

Przeprowadzane na całym świecie badania wskazują, że rozwój dzisiejszych środków transportu uwarunkowany jest zarówno właściwym zaprojektowaniem i wytworzeniem ich elementów składowych, jak i ich odpowiednią późniejszą eksploatacją [2-4], [9-15], [18]. Nie bez znaczenia są tutaj metody umożliwiające wykrywanie wszelkiego rodzaju uszkodzeń, szczególnie w ich wczesnych fazach rozwoju [2], [3], [5], [11], [19].

W przypadku diagnozowania stanu technicznego elementów współczesnych samochodów, szczególnie interesująca wydaje się możliwość rozszerzenia istniejącego systemu OBD ([10], [14]) o funkcje wykorzystujące odpowiednio przetworzone i zinterpretowane sygnały wibroakustyczne.

## 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. Grega R., Homišin J., Kaššay P., Krajňák J.: The analyse of vibrations after changing shaft coupling in drive belt conveyer. Zeszyty Naukowe. Transport. Z. 72. Politechnika Śląska. Gliwice 2011. P. 23-31.
5. Korbicz J., Kościelny J.M., Kowalczyk Z., Cholewa W. (red.): Diagnostyka procesów. Modele. Metody sztucznej inteligencji. Zastosowania. Wydawnictwa Naukowo-Techniczne, Warszawa 2002.
6. Kneba Z., Makowski S.: Zasilanie i sterowanie silników. Wydawnictwa Komunikacji i Łączności, Warszawa 2004.
7. Luft S.: Podstawy budowy silników. Wydawnictwa Komunikacji i Łączności, Warszawa 2006.
8. Lula P., Tadeusiewicz R.: Wprowadzenie do sieci neuronowych. Wydawnictwo StatSoft, Kraków 2001.
9. Madej H., Czech P.: Discrete wavelet transform and probabilistic neural network in IC engine fault diagnosis. Eksploatacja i Niezawodność – Maintenance And Reliability, No. 4, 2010, p. 47-54.
10. Merkisz J., Mazurek S.: Pokładowe systemy diagnostyczne pojazdów samochodowych OBD. Wydawnictwa Komunikacji i Łączności, Warszawa 2007.
11. Mikulski J. (ed.): Modern Transport Telematics. Communications in Computer and Information Science 239 (2011), Springer-Verlag.
12. Młyńczak J.: Analysis of intelligent transport systems (ITS) in public transport of upper Silesia. CCIS 239 (2011), p. 164-171.
13. 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.
14. Rokosch U.: Układy oczyszczania spalin i pokładowe systemy diagnostyczne samochodów. Wydawnictwa Komunikacji i Łączności, Warszawa 2007.

15. 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.
16. Wajand J.A., Wajand J.T.: Tłokowe silniki spalinowe średnio i szybkoobrotowe. Wydawnictwa Naukowo-Techniczne, Warszawa 2005.
17. Wendeker M.: Sterowanie napełnieniem w silniku samochodowym. Lubelskie Towarzystwo Naukowe, Lublin 1999.
18. Węgrzyn T., Piwnik J.: Low alloy welding with micro-jet cooling. Archives of Metallurgy and Materials, z. 2, t. 57, no. 1, 2012.
19. 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.