

Piotr CZECH

ENTROPIA DYSKRETNEJ TRANSFORMATY FALKOWEJ I RADIALNE SIECI NEURONOWE JAKO NARZĘDZIA DIAGNOSTYKI NIESZCZELNOŚCI ZAWORU WYLOTOWEGO W SILNIKU ZS

Streszczenie. W przypadku diagnozowania silnika spalinowego metodami drganiowymi nie można zapominać o występowaniu wielu źródeł drgań, co jest przyczyną wzajemnego zakłócania symptomów uszkodzeń. Ze względu na konieczność analizy sygnałów niestacjonarnych i impulsowych w niniejszym artykule wykorzystano dyskretną transformatę falkową (DWT). Na podstawie sygnałów zdekomponowanych za jej pomocą wyznaczono wartość entropii, która stanowiła podstawę do budowy wzorców stanów pracy silnika, przeznaczonych do uczenia sieci neuronowych. Z przeprowadzonych badań wynika, że istnieje możliwość wykorzystania radialnych sztucznych sieci neuronowych do oceny nieszczelności zaworu wylotowego w silniku ZS.

ENTROPY OF DISCRETE WAVELET TRANSFORM AND RADIAL NEURAL NETWORKS AS A DIAGNOSIS TOOL OF DIESEL ENGINE EXHAUST VALVE FAULT

Summary. In case of diagnosing combustion engines by vibration methods, the presence of numerous sources of vibration cannot be neglected, which are the reason for reciprocal interference of symptoms of fault. Owing to the necessity of analyzing non-stationary and impulse signals, a discrete wavelet transform (DWT) has been applied in this study. Based on the signals' decomposition performed by means of the transform, the value of entropy was determined, which served as a basis in the construction of the states of engine operation intended for teaching neural networks. As results from the research, there is a possibility of using radial neural networks to assess the diesel engine exhaust valve fault.

1. WPROWADZENIE

Silniki spalinowe są klasycznymi maszynami wirującymi, w których drgania i hałas są nośnikami informacji o ich stanie technicznym [3, 9, 11, 12]. Do podstawowych układów silnika spalinowego należy układ rozrządu. Zużycie eksploatacyjne części składowych tego układu (wałek rozrządu, popychacze, dźwignie zaworowe, sprężyny zaworowe, zawory

dolotowe, zawory wylotowe) może w istotny sposób wpłynąć na pracę, osiągi i niezawodność całego silnika.

Wskutek działania strumienia gazów spalinowych ulegają zużyciu przyłgnie gniazda zaworu oraz grzybka zaworu. W fazie otwarcia zaworu wylotowego prędkość gazów dochodzi do 600 m/s, ich temperatura zaś wynosi nawet 1000°C. Łączne działanie powtarzających się uderzeń przy zamykaniu zaworu, erozyjnego wpływu gazów spalinowych oraz korozyjnego działania płomienia ma wpływ na ostateczne zużycie elementów [6].

Należy mieć również na uwadze, że mogące wystąpić w układach przenoszenia napędu nadwyżki sił dynamicznych, powinny kompensować stworzone do tego celu specjalne elementy [4, 5].

W artykule podjęto próbę diagnozowania stanu zaworu wylotowego w silniku ZS przy wykorzystaniu do tego celu sygnałów drganiowych oraz metod sztucznej inteligencji.

2. EKSPERYMENT BADAWCZY

Celem badań była próba oceny stanu technicznego zaworu wylotowego silnika spalinowego. Obiekt badań stanowiła wysokoprężna jednostka napędowa zabudowana w pojeździe samochodowym. Oprócz normalnego stanu eksploatacyjnego, zasymulowano dwa stany zużycia zaworu wylotowego pierwszego cylindra. Uszkodzenia symulowano poprzez wykonanie poprzecznych nacięć grzybka zaworu o różnych wielkościach (rys. 1).



Rys. 1. Zasymulowane uszkodzenie zaworu wylotowego
Fig. 1. Simulated engine exhaust valve fault

Za sygnał diagnostyczny przyjęto sygnały drganiowe zmierzone na głowicy silnika w pobliżu zaworów wylotowego i dolotowego. Przyspieszenia drgań głowicy silnika ZS rejestrowano w kierunku pionowym z wykorzystaniem czujników piezoelektrycznych. Równocześnie dokonywano rejestracji sygnału odniesienia (położenie wału korbowego), który umożliwił analizę kolejnych cykli roboczych silnika. Do rejestracji sygnałów wykorzystano klasyczny tor pomiarowy. Sygnały rejestrowano z częstotliwością próbkowania wynoszącą 65 536 Hz, a następnie analizowano w środowisku Matlab-Simulink. Pomiaru wykonywano dla biegu jałowego przy prędkości obrotowej ok. 2000 obr./min.

Przykładowe, zarejestrowane na zaworach wylotowym i dolotowym, sygnały drganiowe pokazano na rys. 2.

W kolejnym kroku sygnały drganiowe zdekomponowano przy wykorzystaniu do tego celu dyskretnej transformaty falkowej (DWT). Analiza falkowa polega na dekompozycji sygnału i przedstawieniu go w postaci liniowej kombinacji funkcji bazowych, zwanych falkami [1].

Cechami odróżniającymi tę metodę analizy sygnału od innych są wielostopniowa dekompozycja sygnału, zmienna rozdzielczość w dziedzinie czasu i częstotliwości oraz możliwość stosowania funkcji bazowych innych niż funkcje harmoniczne [7]. Dyskretną transformatę falkową sygnału $x(t)$ wyznacza się jako iloczyn skalarny $x(t)$ 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 oraz sumę detali na kolejnych poziomach:

$$x(t) = a_k + \sum_{l=1}^k d_l, \quad (2)$$

gdzie:

d_l – detal sygnału, składnik wielkoczęstotliwościowy sygnału,

a_k – aproksymacja sygnału, reprezentacja małoczęstotliwościowa sygnału.



Rys. 2. Sygnał drganiowy: a) zawór wylotowy, b) zawór wlotowy

Fig. 2. Vibration signal: a) exhaust valve, b) inlet valve

Wraz ze zwiększeniem poziomu dekompozycji sygnału udział detali maleje, co powoduje, że wraz ze zmniejszeniem rozdzielczości maleje zawartość szczegółów w aproksymacji sygnału [1, 7].

Dyskretna transformata falkowa daje możliwości dekompozycji i selektywnej rekonstrukcji (syntezy) sygnału w całym przedziale analizy. Można ją przyrównać do filtracji sygnału ze stałą, względną szerokością pasma [1, 7].


Zgodnie z definicją DWT przebieg czasowy drgań można rozłożyć na zadaną liczbę poziomów dekompozycji. W przeprowadzonych doświadczeniach sygnały drganiowe zostały poddane dekompozycji na dziesięciu poziomach. Przykładowe przebiegi drganiowe oraz ich dekompozycje na składowe nisko- i wysokoczęstotliwościowe, zrealizowane z użyciem filtracji falkowej w przypadku poprawnej pracy silnika oraz przy uszkodzonym zaworze wylotowym silnika ZS, przedstawiono na rys. 3, 4 i 5.

Po przeprowadzeniu dekompozycji i rekonstrukcji sygnału, na każdym z poziomów osobno, dokonano opisu charakteru zmian amplitudy przebiegów czasowych za pomocą wartości entropii sygnału:


$$E = -\sum_i s_i^2(t) \cdot \log(s_i^2(t)), \quad (3)$$

gdzie


$s(t)$ – analizowany sygnał.



Rys. 3. Sygnał drganiowy silnika: a) bez uszkodzeń, b) z uszkodzonym zaworem wylotowym
Fig. 3. Vibration signal of engine: a) without faults, b) with exhaust valve fault



Rys. 4. Aproksymacja sygnału drganiowego silnika: a) bez uszkodzeń, b) z uszkodzonym zaworem wylotowym (5. poziom dekompozycji)
Fig. 4. Vibration approximations of engine: a) without faults, b) with exhaust valve fault (5th level of decomposition)



Rys. 5. Detale sygnału drganiowego silnika: a) bez uszkodzeń, b) z uszkodzonym zaworem wylotowym (5. poziom dekompozycji)
Fig. 5. Vibration details of engine: a) without faults, b) with exhaust valve fault (5th level of decomposition)

Uzyskane wyniki wskazują na możliwość rozróżniania stanów pracy silnika przy wykorzystaniu do tego celu obliczonej entropii aproksymacji i detali sygnału na kolejnych poziomach dekompozycji.

W kolejnym kroku podjęto próbę użycia sztucznych sieci neuronowych do klasyfikacji różnych stanów zużycia zaworu wylotowego silnika ZS. W przeprowadzonych badaniach

zastosowano sztuczne sieci neuronowe typu RBF (Radial Basis Function) [2, 8, 10]. Radialne sieci neuronowe są używane jako klasyfikatory neuronowe dzielące zbiór danych na ustaloną liczbę kategorii wyjściowych. Mają budowę trójwarstwową (warstwy wejściowa, ukryta oraz wyjściowa). Liczba neuronów wyjściowych jest równa liczbie kategorii klasyfikacji. Wykorzystując ten typ sieci, należy odpowiednio dobrać współczynnik wygładzający γ . Reprezentuje on odchylenie radialne funkcji Gaussowskich i jest miarą zasięgu neuronów w warstwie ukrytej [8, 10].

Sieć neuronowa miała za zadanie sklasyfikować zarejestrowany sygnał drganiowy do jednej z trzech klas, odpowiadających normalnemu stanowi eksploatacyjnemu oraz dwóm stanom charakteryzującym się uszkodzeniem zaworu wylotowego silnika ZS.

Do eksperymentów wybrano po 200 przebiegów czasowych dla każdej z klas, które następnie podzielono na dwie równe części, przeznaczone do uczenia i testowania działania sieci neuronowych.

W eksperymentach, mających na celu budowę poprawnie działającego klasyfikatora neuronowego typu RBF, sprawdzono działanie sieci dla 86 różnych wartości współczynnika γ .

Najlepsze uzyskane w eksperymentach wyniki przedstawiono w tab. 1.

Tabela 1

Najlepsze uzyskane wyniki

Lp.	Sygnał zmierzony w pobliżu zaworu	Sygnał	Współczynnik γ	Błąd klasyfikacji, %
1	wylotowego	aproksymacji	500; 600; 700; 900	0
2	wlotowego	aproksymacji	0,5; 0,6; 0,7; 0,8; 0,9; 1; 30; 90; 100; 500; 600; 700; 800; 900; 1000; 50000	0
3	wylotowego	detali	0,5; 0,6; 0,7; 60; 80; 300; 400; 500; 600; 700; 900; 1000	0
4	wlotowego	detali	600	0

3. PODSUMOWANIE

Przeprowadzone badania potwierdziły możliwość budowy poprawnie działającego systemu diagnostycznego, który wykorzystuje klasyfikator neuronowy. Użycie radialnych sieci neuronowych z odpowiednio dobraną wartością współczynnika γ pozwoliło uzyskać bezbłędną klasyfikację.

Równocześnie, na podstawie przeprowadzonych doświadczeń, potwierdzono kluczową rolę doboru odpowiedniego sposobu wstępnego przetwarzania danych, przeznaczonych do uczenia sieci neuronowych. Uzyskane wyniki potwierdziły przydatność wykorzystania do tego celu dyskretnej transformaty falkowej oraz obliczonej na jej podstawie entropii.

Efektywność systemów OBD, które umożliwiają wykrywanie uszkodzeń mechanicznych silnika, maskowanych przez elektroniczne urządzenia sterujące współczesnych pojazdów samochodowych, może być podniesiona przez opracowanie systemów wykorzystujących radialne sztuczne sieci neuronowe.

Bibliografia

1. Batko W., Ziółko M.: Zastosowanie teorii falek w diagnostyce technicznej. Wydawnictwo AGH, Kraków 2002.
2. Czech P., Łazarz B., Wojnar G.: Wykrywanie lokalnych uszkodzeń zębów kół przekładni z wykorzystaniem sztucznych sieci neuronowych i algorytmów genetycznych. Wydawnictwo ITE, Radom 2007.
3. Dąbrowski Z., Madej H.: Masking mechanical damages in the modern control systems of combustion engines. *Journal of KONES*, Vol. 13, No. 3/2006.
4. Grega R., Homišin J.: Využitie nanomateriálov v oblasti ladenia torzne kmitajúcich mechanických sústav. 51. Medzinárodná vedecká konferencia katedier časti a mechanizmov strojov, 08-10.9.2010, Košice – Slovenský raj, s. 43-48.
5. Grega R., Kaššay P., Krajňák J.: Impact of pneumatic flexible coupling on effective vibration value within the mechanical systems. *Transactions of the Universities of Košice*, No. 3, 2009, s. 5-8.
6. Janecki J., Gołąbek S.: Zużycie części i zespołów pojazdów samochodowych. Wydawnictwa Komunikacji i Łączności, Warszawa 1984.
7. Korbicz J., Kościelny J., Kowalczyk Z., Cholewa W.: Diagnostyka procesów. Modele. Metody sztucznej inteligencji. Zastosowania. Wydawnictwa Naukowo-Techniczne, Warszawa 2002.
8. Osowski St.: Sieci neuronowe do przetwarzania informacji. Oficyna Wydawnicza Politechniki Warszawskiej, Warszawa 2000.
9. Shirazi F.A., Mahjoob M.J.: Application of discrete wavelet transform (DWT) in combustion failure detection of IC engines. 5th International Symposium on Image and Signal Processing and Analysis, ISPA 2007.
10. Tadeusiewicz R., Lula P.: Wprowadzenie do sieci neuronowych. StatSoft, Kraków 2001.
11. Wu J.D., Liu C.H.: Investigation of engine fault diagnosis using discrete wavelet transform and neural network. *Expert Systems with Applications*, No. 35, 2008.
12. Yang W. X.: Establishment of the mathematical model for diagnosing the engine valve faults by genetic programming. *Journal of Sound and Vibration*, No. 293, 2006.

Recenzent: Dr hab. Rajmund Michalski,
prof. nzw. Instytutu Podstaw Inżynierii Środowiska PAN