

## **Dr hab. Inż. Maciej Tabaszewski<sup>1</sup>**

Poznan University of Technology  
Institute of Applied Mechanics  
ul. Jana Pawła II 24, 60-965 Poznań, Poland  
e-mail: maciej.tabaszewski@put.poznan.pl

## **Dr hab. inż. Grzegorz. M. Szymański**

Poznan University of Technology  
Institute of Transport  
ul. Piotrowo 3, 60-965 Poznań, Poland  
e-mail: grzegorz.m.szymanski@put.poznan.pl

### **Diagnostyka luzu zaworów silnika spalinowego z wykorzystaniem sygnału drganiowego i metod uczenia maszynowego**

**Słowa kluczowe:** *silnik spalinowy, diagnostyka, drgania, uczenie maszynowe*

**Streszczenie:** Dynamiczny rozwój konstrukcji silników spalinowych generuje potrzebę wprowadzenia strategii eksploatacji jednostek napędowych, opartej na znajomości ich stanu technicznego. W artykule poddano analizie zagadnienia, związane z drganiową diagnostyką luzu zaworów tłokowego silnika spalinowego, istotnego ze względu na efektywność pracy silnika i jego trwałość. Zaproponowano wykorzystanie metod klasyfikacji do oceny poprawności luzu zaworowego. Przeprowadzono i opisano eksperymenty, które miały na celu dostarczenie informacji koniecznych do zbudowania i zweryfikowania zaproponowanych metod. W przeprowadzonych badaniach pozyskano sygnały drganiowe z trójosiowego czujnika przyspieszeń drgań zlokalizowanego na głowicy silnika. Dokonano parametryzacji uzyskanych przebiegów czasowych sygnału drganiowego dla silnika pracującego pod różnym obciążeniem, z różnymi prędkościami obrotowymi oraz z różnymi luzami zaworowymi. Parametryzacja dotyczyła zarówno cech sygnału przyspieszeń drgań, pochodnej przyspieszeń drgań względem czasu jak i obwiedni tej pochodnej. W pierwszym podejściu zbudowano klasyfikator w postaci zbioru drzew binarnych, który przy okazji pozwolił na wyodrębnienie istotnych, ze względu na przyjęte klasy, cech. Dla porównania zbudowano także klasyfikatory w postaci sieci neuronowej jak i algorytmu k – najbliższych sąsiadów z metryką euklidesową. Na podstawie przeprowadzonych badań i analiz zaproponowano metodę oceny luzu zaworowego.

## **1. Wprowadzenie**

Tłokowy silnik spalinowy jest powszechnie stosowany do napędu pojazdów oraz urządzeń stacjonarnych. Zamienia on energię zawartą w paliwie na pracę mechaniczną obracającego się wału korbowego i tak, jak wszystkie urządzenia mechaniczne podlega zużywaniu i starzeniu. Trwałość silnika określona jest właściwościami konstrukcyjnymi i w dużym stopniu zależy od warunków eksploatacji oraz charakteru obciążeń. Wraz z postępującym zaawansowaniem procesów degradacji konstrukcji (oddziaływanie zmiennych temperatur, procesy trybologiczne, kawitacja, korozja chemiczna i elektrochemiczna, starzenie itp.) pogarszają się parametry niezawodności i sprawności. W konsekwencji dochodzi do zużycia i uszkodzenia obiektu lub


---

<sup>1</sup> Corresponding author . tel.: +48 61 665 2390; fax: 48 61 665 2307  
Email address: maciej.tabaszewski@put.poznan.pl

jego wyłączenia z eksploatacji ze względów ekonomicznych lub innych (np. ekologicznych). Już od początków historii silników spalinowych zauważono, że jednym z kluczowych problemów mających wpływ na jego prawidłową pracę jest poprawne ustawienie parametrów regulacyjnych.

Degradacja struktury silnika oraz nieprawidłowo ustawione parametry regulacyjne mogą być przyczyną następujących zjawisk w silniku spalinowym: pogorszenia efektywności pracy silnika spalinowego, zmniejszenia mocy, związanego ze zmniejszeniem sprawności mechanicznej, sprawności cieplnej oraz współczynnika napelnienia, zwiększenie emisji związków toksycznych w spalinach, możliwość uszkodzenia elementów silnika spalinowego.

Na rysunku 1a. przedstawiono różnice w zużyciu paliwa przy zmianie luzu zaworów rozrządu silnika spalinowego, natomiast zmiany prędkości zderzenia przy uwzględnieniu wzniosu krzywki  $h$ ) zaworu z gniazdem zaworowym na rys. 1b. Z danych przedstawionych na rys. 1a wynika, że zmiany luzu zaworowego mogą powodować wzrost zużycia paliwa przez badany silnik spalinowy o ok. 9%, natomiast analiza rys. 1b. pozwala stwierdzić, że wraz ze wzrostem luzu zaworowego (linie: niebieska i zielona rys.1b.) zwiększa się prędkość uderzenia zaworu o gniazdo, powodując dodatkowe niepożądane obciążenia dynamiczne elementów głowicy cylindrów silnika spalinowego.



Rys. 1. a) Przyrost zużycia paliwa w funkcji luzu zaworów, b) zarys krzywki ( linia czerwona), prędkość punktu na krzywce (linia czarna) oraz zmiany prędkości zderzenia zaworu z gniazdem w silniku spalinowym spowodowane zmianami luzów zaworów (pionowe strzałki: zielona i niebieska), OWK – kąt obrotu wału korbowego,  $h$  – wznios krzywki,  $v$  – prędkość punktu na krzywce

Opracowano wiele metod diagnozowania stanu technicznego silników spalinowych. Można je podzielić na metody wykorzystujące procesy robocze (indykowanie, zmiany momentu obrotowego w funkcji obrotu wału korbowego, pomiar ciśnienia i temperatury spalin, ciśnienia w przestrzeni nad i pod tłokiem, parametrów zasilania, zadymienia spalin, itp.) oraz procesy resztkowe (drżania, hałas, procesy termiczne, elektryczne i inne). Na podstawie badań procesów roboczych można wnioskować o ogólnym stanie silnika spalinowego, natomiast procesy resztkowe niosą informacje o stanie poszczególnych podzespołów i par kinematycznych. Dlatego procesy resztkowe wykorzystuje się, jako autonomiczne lub wspomagające metody diagnostyczne. Wszystkie metody oparte na analizie drgań i hałasu dla określenia stanu technicznego obiektu noszą nazwę diagnostyki wibroakustycznej.

Mechanizm rozrządu zaworowego jako jeden z podstawowych mechanizmów wchodzących w skład tłokowych silników spalinowych już z samej zasady swego działania jest źródłem sygnału wibroakustycznego, ponieważ pracy rozrządu zaworowego obejmującego: otwieranie i zamykanie zaworów, współpracę krzywki z popychaczem, kasowanie luzu w łożyskach dźwigni zaworowych i innym towarzyszą zderzenia współpracujących elementów, a te z kolei

wywołują drgania. Wykorzystanie sygnałów drgań do diagnozowania układu rozrządu silnika spalinowego przedstawiono w następujących pracach:

W artykule [12] omówiono opcję zastosowania rozkładu pakietu falek podczas filtrowania sygnału akustycznego silnika spalinowego w celu zdiagnozowania nadmiernego luzu zaworowego. Autorzy przygotowali algorytm umożliwiający wybór wybranych szczegółów i zbliżenie analizy falkowej do komponentów o niskiej częstotliwości, które stanowią hałas, a także do komponentów o wysokiej częstotliwości, zawierających informacje o możliwym powiększeniu luzu zaworowego silnika. Następnie, w oparciu o wybrane komponenty sygnału akustycznego wysokiej częstotliwości, opracowano metodę automatycznego wykrywania powiększonych luzów zaworów, zakładając, że udział energetyczny emitowanego sygnału akustycznego powinien być ustalany podczas otwierania i zamykania poszczególnych zaworów. Autorzy artykułu [13] opisali badania dotyczące diagnostyki stanu zaworów wydechowych w dużych morskich silnikach wysokoprężnych. Badania wykonano na czterocyndrowym 2-suwowym morskim silniku wysokoprężnym o średnicy tłoka 500 mm w Centrum Badawczym MAN B&W Diesel w Kopenhadze w Danii. Eksperymenty obejmowały trzy różne stany zaworu, przy czym dwa dotyczyły sztucznie wywołanych sytuacji przepalenia zaworu. Podstawowymi pomiarami monitorowania były drgania i fale naprężeń strukturalnych, znane również jako emisja akustyczna (AE). Wyniki wykazały, że sygnały AE mają znaczną przewagę nad innymi zaangażowanymi czujnikami, co wskazuje na wrażliwość zarówno na działanie mechaniczne, jak i mechaniczno-płynne spalanie. Zarejestrowane dane zostały wstępnie przetworzone, a funkcje wyodrębnione przy użyciu analizy głównych składników (PCA). Na podstawie szeregu zastosowanych heurystyk i statystyk przeprowadzono poszukiwanie optymalnej podprzestrzeni głównych komponentów. Wybrana przestrzeń cech została wykorzystana do klasyfikacji stanu zaworu wydechowego poprzez zastosowanie zarówno znormalizowanych klasyfikatorów neuronowych ze sprzężeniem zwrotnym, jak i dyskryminatorów liniowych. Natomiast w artykule [28] obliczono rozkłady jądra w kształcie stożka (CKD) sygnałów przyspieszenia drgań pozyskanych z głowicy cylindra w ośmiu różnych stanach mechanizmu rozrządu i przedstawiono je na obrazach szarych. Do dekompozycji danych wielowymiarowych wykorzystano nieujemną faktoryzację macierzy (NMF), a zespół sieci neuronowej (NNE), który ma lepszą zdolność uogólnienia do klasyfikacji niż pojedyncza sieć neuronowa. NNE został wykorzystany do przeprowadzenia inteligentnej diagnozy na podstawie rozkładów czasowo-częstotliwościowych. Na podstawie wyników eksperymentalnych wykazano, że uszkodzenia mechanizmu rozrządu w silniku diesla można dokładnie sklasyfikować za pomocą proponowanej metody. W pracy [31] poddano analizie zagadnienia, związane z drganiową diagnostyką automatycznych kompensatorów luzu zaworów tłokowych silników spalinowych. Opisano i przeprowadzono eksperymenty naukowe, które miały na celu dostarczenie informacji koniecznych do zbudowania i zweryfikowania modeli diagnostycznych umożliwiających ocenę stanu technicznego tych elementów silnika spalinowego, istotnych ze względu na efektywność pracy silnika i jego trwałość. Na podstawie wyznaczonego modelu diagnostycznego opracowano algorytm oceny stanu technicznego automatycznych kompensatorów luzu zaworowego. Natomiast w artykule [32] obliczono rozkłady Wignera-Ville'a (WVD) sygnałów przyspieszenia drgań, które zostały zarejestrowane na głowicy cylindrów w ośmiu różnych stanach rozrządu zaworowego i wyświetlone na obrazach szarych. Do klasyfikacji obrazów czasowo-częstotliwościowych po ich znormalizowaniu zostały bezpośrednio wykorzystane probabilistyczne sieci neuronowe (PNN). W ten sposób diagnostyka uszkodzeń mechanizmu rozrządu została przeniesiona do klasyfikacji obrazów czasowo-częstotliwościowych. Wyniki eksperymentów pokazują, że usterki w zespołach zaworów diesla można dokładnie sklasyfikować za pomocą proponowanych metod.

Zastosowanie różnych technik analizy sygnałów wibroakustycznych do oceny stanu technicznego silników spalinowych przedstawili autorzy prac:

Autorzy pracy [1] wykazali, że sygnały akustyczne pochodzące z silnika spalinowego bogate są w informacje dotyczące parametrów pracy silnika i jego stanu. Niestety, te informacje są złożone i charakteryzują się dużym szumem tła. Na podstawie analizy zmierzonych parametrów wykazali, że można diagnozować niedomagania silnika spowodowane spadkiem stopnia sprężania, zmianami ciśnienia wtrysku, zmianami w układzie wylotowym, zmianą luzu zaworu ssącego i wylotowego. Oceny stanu technicznego silnika przeprowadzili na podstawie analizy zmian wartości skutecznej oraz kurtozy sygnałów akustycznych każdego z cylindrów silnika. Autorzy artykułu [2] stwierdzili, że sygnały akustyczne wywołane przez mechanizmy często muszą być opisywane przez nieliniowe modele w dziedzinie czasu. Natomiast w dziedzinie częstotliwości model liniowy jest w wielu przypadkach wystarczający do opisu kanałów propagacji dźwięku. W pracy dokonali porównania metod obliczeniowych pod względem dokładności, czasu obliczania i możliwości do wykonywania badań w czasie eksploatacji obiektu. W artykule [3] przedstawiono szybką i automatyczną metodę diagnostyki silnika opartą na jednym parametrze emisji akustycznej (AE). Metoda oparta jest na porównaniu drgań i energii AE z wartościami odniesienia w celu ustalenia czy stan silnika jest wadliwy. Metoda została zastosowana w silniku testowym i okazała się zadowalająca. Praca [9] dotyczy monitorowania dużych silników Diesla poprzez analizę zmian prędkości kątowej wału korbowego. Skoncentrowano się na 20-cylindrowym silniku wysokoprężnym z naturalnymi częstotliwościami wału korbowego w zakresie prędkości roboczych. Zmiany prędkości kątowej modelowano na wolnym końcu wału korbowego. Modelowanie obejmowało zarówno zachowania dynamiczne wału korbowego, jak i momenty wzbudzenia. Ponieważ silnik jest bardzo duży, pierwsze tryby skręcania wału korbowego są w zakresie niskich częstotliwości. Wymagany jest model z założeniem elastycznego wału korbowego. Momenty wzbudzenia zależą od krzywej ciśnienia w cylindrze. Ten ostatni modelowano za pomocą modelu fenomenologicznego. Parametry mechaniczne i spalania modelu optymalizowano za pomocą rzeczywistych danych. Zaproponowano zautomatyzowaną diagnozę opartą na systemie wykorzystującym sztuczną inteligencję. Sieci neuronowe wykorzystywano do rozpoznawania wzorców przebiegów prędkości kątowej w normalnych i wadliwych warunkach. Wzory odniesienia wymagane na etapie szkolenia obliczano z modelu, skalibrowanym przy użyciu niewielkiej liczby rzeczywistych pomiarów. Uzyskano obiecujące wyniki. Podczas badań weryfikacyjnych pomyślnie zdiagnozowano uszkodzenie polegające na wycieku paliwa. W pracy [10] wykonano sprzężoną symulację dynamiki tłoka i trybologii silnika (trybodynamiki) przy użyciu quasi-stacyjnych i przejściowych kodów numerycznych do modelowania uderzeń tłoka o ściankę cylindra. Potwierdzenie przydatności proponowanych metod określono na podstawie pomiarów eksperymentalnych wykonanych na jednocylindrowym silniku benzynowym w warunkach laboratoryjnych. Poprzez pomiar przyspieszeń drgań powierzchni bloku silnika. Autorzy artykułu [34] zaproponowano system diagnostyki uszkodzeń silników spalinowych wykorzystujących techniki transformacji pakietów falkowych (WPT) i sztucznej sieci neuronowej (ANN). W artykule [5] omówiono zastosowanie czujnika prądu jonowego do wykrywania rezonansu spalania w silniku wysokoprężnym z bezpośrednim wtryskiem. Zmodyfikowana świeca żarowa służy do pomiaru prądu jonowego oprócz jego głównej funkcji polegającej na podgrzewaniu komory spalania. Dokonano porównania rezonansu spalania określonego na podstawie sygnałów czujnika prądu jonowego, przetwornika ciśnienia w cylindrze i czujnika drgań silnika. Stwierdzono, że sygnał prądu jonowego można wykorzystać do określenia synchronizacji, amplitudy, częstotliwości i czasu trwania rezonansu. Wyjście czujnika może zostać wykorzystane jako sygnał zwrotny do ECU (elektronicznej jednostki sterującej) w celu zminimalizowania drgań i hałasu silnika. Artykuł [8] dotyczy najnowocześniejszych strategii i technik diagnostycznych opartych na sygnałach

wibroakustycznych, które mogą służyć do monitorowania i diagnozowania silników spalinowych (ICE) zarówno na stanowisku badawczym, jak i w warunkach pracy. W tym artykule po raz pierwszy przedstawiono krótkie podsumowanie generowania dźwięku i drgań w ICE w kontekście dalszej dyskusji na temat diagnostyki wibroakustycznej. Przedstawiono również przegląd technik monitorowania i diagnostyki opisanych w literaturze, przy użyciu sygnałów drganiowych i akustycznych.

Na podstawie analizy dotychczasowych dokonań w dziedzinie diagnostyki wibroakustycznej układów silników spalinowych stwierdzono, że: prowadzono badania dotyczące zastosowania parametrów sygnałów drgań do oceny stanu technicznego zespołów silnika spalinowego lub zachodzących w nim procesów, badania dotyczyły zagadnień metodycznych (np. ustalenia warunków pracy silnika w trakcie pomiarów drgań, wyboru punktów pomiarowych) oraz zagadnień modelowania (budowania modeli diagnostycznych i ich weryfikacji) w badaniach wykorzystywano zarówno proste metody opisu sygnałów (np. miary punktowe) jak i bardzo zaawansowane techniki przetwarzania sygnałów (np. sztuczne sieci neuronowe, analiza czasowo-widmowa). W analizowanych pracach dotyczących drganiowej diagnostyki silników spalinowych dostrzeżono metody, w których modele diagnostyczne bazowały na odpowiedziach struktury obiektu na wymuszenia impulsowe. Analizy dotyczące odpowiedzi stanowiły w przeprowadzonych badaniach podpowiedź co do optymalnego wyboru punktu pomiarowego jak i ewentualnie zakresu częstotliwości, które powinna objąć analiza.

W niniejszym artykule przedstawiono nowe podejście do identyfikacji luzu zaworowego silnika pracującego z różnym obciążeniem i prędkością obrotową na podstawie odpowiednio przetworzonego sygnału drganiowego. Zaproponowano metodykę identyfikacji klasy luzu zaworowego w oparciu o przyspieszenia drgań bezwzględnych mierzonych na głowicy silnika i systemy uczone pod nadzorem – klasyfikatory. Takie rozwiązanie pozwala oceniać automatycznie prawidłowość luzu zaworowego na pracującym silniku bez poszukiwania matematycznego modelu opisującego związek pomiędzy sygnałem drganiowym a luzem.

Klasyfikatory jako systemy uczone pod nadzorem, mają zastosowanie w bardzo wielu dziedzinach przy przetwarzaniu bardzo dużych zasobów danych i automatyzacji procesu wnioskowania. Nie sposób dokonać pełnego przeglądu zastosowań wspomnianych algorytmów, a nawet dziedzin ich zastosowania. Przykładowo można tylko wspomnieć tak różne obszary jak: przewidywania wyników egzaminów uczniów [6], monitorowanie zmian urbanistycznych [11], klasyfikację chropowatości dróg [15], segmentację defektów jabłek [19], inteligentny system detekcji uszkodzeń maszyn wirnikowych [20], klasyfikację ruchu sieciowego [24], czy przetwarzanie i analizę obrazu [35]. Znanych jest wiele prób wykorzystania uczenia maszynowego także w diagnostyce maszyn i podzespołów w celu określenia stanu technicznego jak i cech stanu. Przykładowo w pracy [16] rozpatrywane jest zastosowanie sieci konwolucyjnej z pewnymi modyfikacjami do klasyfikacji stanu maszyn. Autorzy zpresentowali obiecujące wyniki działania metody na przykładzie sygnałów z łożysk tocznych. W pracy [18] autorzy z powodzeniem zastosowali klasteryzację metodą k-means oraz klasyfikację metodą SVM (Support Vector Machine) w celu oceny stanu zużycia ostrzy maszyny pakującej. W pracy [23] zastosowano statystyczne miary odległości do rozróżnienia stanów uszkodzenia łożysk tocznych. Autorzy pracy [27] wykazali skuteczność metod klasyfikacji w odniesieniu do monitorowania stanu sprężarek tłokowych zaistalowanych w urządzeniach chłodniczych. Wykorzystano tu między innymi sieci neuronowe ale także maszyny do uczenia ekstremalnego (ELM). W pracy dotyczącej diagnostyki turbin wiatrowych [29] stosowano reprezentacje sygnałów czasowych w postaci obrazów, wykorzystywano różne cechy tekstur i dokonywano klasyfikacji za pomocą tych cech. Omówienie wielu metod uczenia maszynowego w kontekście ogólnych zastosowań diagnostycznych można znaleźć także w pozycji [17]. Metody uczenia maszynowego wykorzystywano także w diagnostyce silników

spalinowych tłokowych. W pracy [4] prównano różne metody klasyfikacji wykorzystane do identyfikacji zjawiska wypadania zapłonu. Autorzy pracy [7] dokonywali diagnozy stanu wtryskiwaczy silnika za pomocą sygnału drganiowego, dyskretnej transformaty falkowej i sieci neuronowej. Z kolei w pracy [21] analizowano tymi samymi metodami problem wyłączenia cylindrów silnika. Wiele niesprawności silnika spalinowego identyfikowano także za pomocą metod probabilistycznych [33]. Nie rozważano tutaj jednak problemu nieoptymalnych luzów zaworowych. W pracy [14] zastosowano klasyfikacje do identyfikacji wielu uszkodzeń – między innymi zbyt małego lub dużego luzu zaworowego. Badania zrealizowano z zastosowaniem zaawansowanych metod ekstremalnego uczenia maszynowego. Za anlizy pracy wynika, że trafność klasfikacji uszkodzeń uzyskanych przez badaczy nie przekracza 96%. Wydaje się, że pożądane jest znalezienie prostszej metody klasyfikacji luzu ze względu na możliwość jej łatwej implementacji praktycznej w diagnostyce pokładowej, stąd zdaniem autorów tej pracy konieczne są dalsze poszukiwania i badania w tym kierunku. Istotne jest również to, by mimo prostoty metody zachować wysoką pewność diagnozy.

Proces klasyfikacji można technicznie przeprowadzić wieloma metodami o specyficznych właściwościach i możliwościach. Z pośród szeregu możliwości można wymienić tutaj drzewa klasyfikacyjne, sieci neuronowe, klasyfikatory odległościowe, aproksymacyjne, rozmyte itp. W pracy zastosowano trzy metody, które zdaniem autorów są najprostsze do praktycznej implementacji w pokładowej diagnostyce silnika: drzewo klasyfikacyjne, sztuczne sieci neuronowe MLP i klasyfikator  $k$  – najbliższych sąsiadów.

Zaletą struktury drzewa jest przystępny dla człowieka sposób reprezentacji wiedzy, którą można uzyskać po procesie uczenia. Inną zaletą jest brak wymagań dotyczących założeń na temat związku zmiennej zależnej ze zmiennymi objaśniającymi. Ponadto drzewo pozwala wyłowić automatycznie te miary diagnostyczne, które mają istotne znaczenie w procesie klasyfikacji stanu. Te które nie zostaną wykorzystane przez algorytm nie mają znaczenia w budowie drzewa, a więc w klasyfikacji stanu czy identyfikacji uszkodzeń przeprowadzonych tą metodą. Dodatkowo metoda może być stosowana w zbiorach danych o licznych brakach danych co może mieć znaczenie w przypadku dostępnych baz pochodzących z kilku źródeł.

Innymi metodami klasyfikacji stosowanymi także w diagnostyce silników, są sieci neuronowe Sztuczne sieci neuronowe, wykorzystywane tutaj do klasyfikacji, pozwalają na przetwarzanie informacji w sposób równoległy. W przypadku sztucznej sieci neuronowej podstawowe znaczenie ma optymalizacja struktury sieci (liczba warstw ukrytych czy liczba neuronów w warstwach) co stanowi żmudny proces przeprowadzany przeważnie metodą prób i błędów. Ważny jest także dobór atrybutów wejściowych, co w przypadku drzew klasyfikacyjnych wbudowane jest bezpośrednio w algorytm jego budowy.

Innym klasyfikatorem stosowanym w tej pracy jest klasyfikator  $k$  – najbliższych sąsiadów. Jego zaletą jest niewątpliwie prostota realizacji i łatwość ustalenia w jaki sposób doszło do predykcji danej klasy. Wadami natomiast są konieczność przechowywania dużej ilości danych w pamięci, konieczność optymalizacji doboru parametru  $k$ , miary odległości pomiędzy danymi jak i zbioru atrybutów.


## 2. Metodyka badań

Obiektem badań był jednocylindrowy silnik badawczy SB 3.1 zbudowany na bazie silnika SW 680. Silnik SB 3.1 przeznaczony jest do prac badawczych z zakresu przebiegu spalania oraz oceny innych parametrów pracy silników SW 680 budowanych na licencji firmy Leyland w WSK Mielec. W silniku badawczym zastosowano następujące zespoły z silnika SW 680: korbówód, tłok z pierścieniami, tuleję cylindrową, zawory rozrządu, sterowanie rozrządu, wtryskiwacz, głowicę (wykonaną poprzez przeróbkę głowicy silnika SW 680). Konstrukcja silnika pozwala na: pomiar ciśnienia w cylindrze, regulację stopnia sprężania w zakresie  $\varepsilon =$

14-20, możliwość zmiany początku tłoczenia paliwa w sposób ciągły, możliwość zainstalowania przełącznika drogi tłoka, możliwość zmiany faz rozrządu w sposób ciągły, zmiany wyrównoważenia sił masowych I rzędu.

Badania przeprowadzono dwuetapowo. W pierwszym etapie przeprowadzono testy impulsowe mające na celu identyfikację częstotliwości rezonansowych co zdeterminowało pasmo pomiarowe oraz pozwoliło na wyznaczenie punktów akwizycji drgań na głowicy silnika spalinowego. W etapie drugim badano drgania głowic silnika dla różnych konfiguracji luzu zaworów i nastaw punktu pracy silnika. Na podstawie wyników badań etapu drugiego, opracowano algorytm oceny luzu zaworów w badanym silniku.

Ogólny schemat układu pomiarowego stosowanego do rejestracji sygnałów drganiowych podczas badań uruchomionego silnika przedstawiono na rys. 2.



Rys. 2. Schemat układu pomiarowego stosowanego do pomiarów drgań głowicy w czasie badań uruchomionego silnika

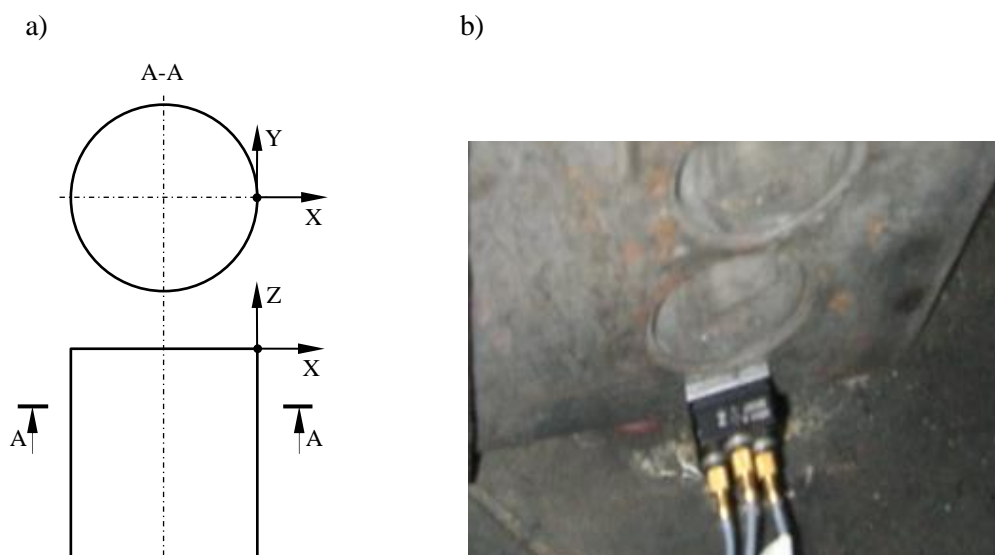
Metodyka badań została opracowana w oparciu o założenia eksperymentu czynnego [22]. Podczas wykonywania eksperymentu zmieniano: luz zaworów, obciążenie silnika spalinowego oraz prędkość obrotową wału korbowego, równocześnie rejestrowano przyspieszenia drgań głowicy silnika.

Pomiary wykonano zgodnie z zasadą trzech uruchomień tzn. każdą serię pomiarów wykonano trzykrotnie, pomiędzy każdą serią pomiarów dokonano wyłączenia silnika z ruchu. Wykorzystano opisaną metodę prowadzenia badań, chcąc uniknąć przypadkowych wartości parametrów charakterystyk sygnałów drganiowych.

Przetworniki drgań typu 4504 firmy Brüel&Kjær wybrano na podstawie wskazówek zawartych w pracy [26, 30] liniowe pasmo przenoszenia wybranych przetworników wynosiło do 18 kHz. Podczas badań rejestrowano sygnały w paśmie 0,1 Hz–25 kHz. Akcelerometry zamocowano na głowicy silnika spalinowego za pomocą kleju. Przy wyborze miejsc pomiarowych do testów impulsowych przyjęto zasadę, że przetwornik powinien znajdować się jak najbliżej miejsca generacji sygnału drgań związanego z pracą zaworów oraz w miejscu dostępnym [25]. Kierunki pomiaru drgań przyjęto następująco: kierunek X równoległy do średnicy cylindra, kierunek Z równoległy do osi cylindra, kierunek Y prostopadły do dwóch pozostałych (rys. 3a). Częstotliwość próbkowania ustawiono na 65536 Hz. Do rejestracji sygnałów drgań zastosowano multianalizator PULSE firmy Brüel&Kjær, który umożliwia rejestrację przebiegów szybkozmiennych równoległe na 6 kanałach z dynamiką do 160 dB.

Orientację przestrzenną przetworników do pomiaru drgań przedstawiono na rys. 3a natomiast miejsce ich mocowania na badanym obiekcie na rys. 3b.





Rys. 3. a). Orientacja kierunków pomiaru drgań na głowicy cylindrów silnika, b) widok przetwornika drgań zamocowanego na głowicy cylindrów silnika

Wybór punktu pomiaru drgań został poprzedzony analizą konstrukcji głowicy, badaniami opisanymi w pracy [26] dotyczącymi określenia wpływu luzu zaworów silnika spalinowego o ZS na wybrane parametry drgań oraz wspomnianymi wcześniej testami impulsowymi, polegającymi na uderzaniu zaworów o gniazda zaworowe. Uderzenia realizowano przez usuwanie, umieszczonej pomiędzy trzonkiem zaworu a dźwigienką, wzorcowej płytki pomiarowej. Powtarzano to kilkakrotnie dla każdego zaworu w celu wyeliminowania błędów przypadkowych oraz wykonania procesu uśredniania. Ważne było ustalenie takiego punktu pomiaru sygnałów drganiowych, który umożliwiłby ocenę uderzenia każdego zaworu. Po wykonaniu analiz wyników testów impulsowych do badań eksploatacyjnych wybrano jeden punkt. Biorąc pod uwagę dynamikę sygnałów zarejestrowanych podczas badań impulsowych zauważono, że kierunek X może nieść najwięcej informacji dotyczącej luzu zaworowego.

Badania pracującego silnika przeprowadzono przy: prędkości obrotowej wału korbowego 700 obr/min, 1000 obr/min, 1200 obr/min, 1500 obr/min, 1700 obr/min, obciążeniu: brak obciążenia zewnętrznego, 22.5 Nm, 45 Nm, 67.5 Nm, 90 Nm., temperaturze cieczy chłodzącej utrzymywano na poziomie 75°C. Dla wymienionych wyżej warunków dokonano rejestracji sygnału przyspieszeń drgań w trzech kierunkach.


Przykładowy fragment rejestracji w kierunku X sygnału drganiowego przedstawiano na rysunku 4.

W przebiegu widocznych jest szereg cykli pracy silnika. Dominującym zjawiskiem są chwilowe zdarzenia związane z samym zapłonem, natomiast zjawiska drganiowe związane z zamknięciem zaworu są trudniej dostrzegalne zwłaszcza dla niewielkich wartości luzu zaworowego.

Przed analizą sygnały drganiowe poddano selekcji kątowej. Oznacza to, że analizowano tylko te fragmenty sygnałów, które były zsynchronizowane czasowo lub kątoowo z procesem zamykania zaworów.

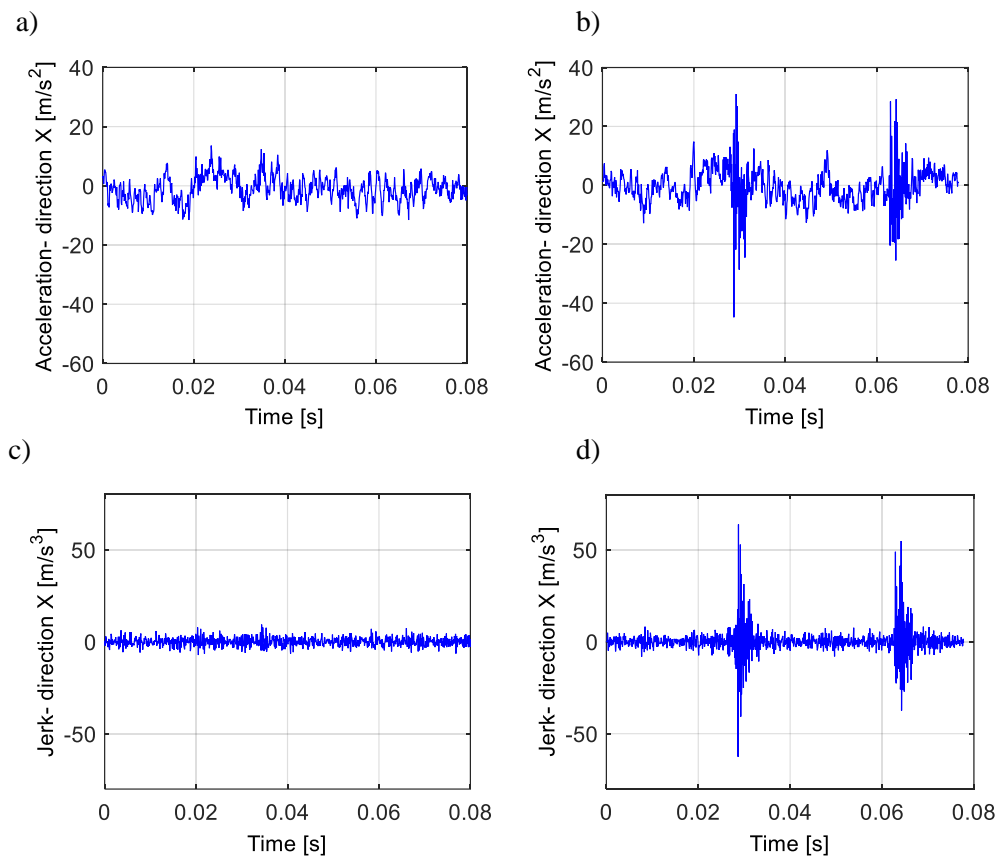
W praktyce można tego dokonać w łatwy sposób dysponując odpowiednimi znacznikami na kole zamachowym, a nawet w oparciu sam sygnał przyspieszeń drgań biorąc pod uwagę próg wartości szczytowej osiąganego podczas zapłonu silnika i odpowiednią bramkę czasową. W ten sposób uzyskano ponad 32 tys. wycinków sygnału czasowego dla różnych obciążeń i prędkości obrotowej silnika.





Rys.4. Przykładowy przebieg przyspieszeń drgań rejestrowanych w kierunku X – fragment rejestracji

Rysunek 5 przedstawia przykładowe wycinki rejestracji dla skrajnych wartości luzu zaworowego 0,3 mm oraz 1,0 mm.



Rys.5. Fragmenty przebiegów czasowych przyspieszeń (rysunki a,b) i pochodnej przyspieszenia drgań (rysunki c,d) związanych z zamykaniem zaworów; rysunek a, c – luz = 0,3 mm; rysunek b, d – luz = 1,0 mm

W przypadku niewielkiego luzu moment zamknięcia zaworu jest praktycznie niewidoczny (rys. 5a), natomiast w przypadku skrajnie dużego luzu łatwo go dostrzec (rys. 5b). Widoczna jest wyraźna odpowiedź układu spowodowana uderzeniem zaworów w gniazdo zaworowe. Najtrudniejsze do analizy są przykłady pośrednie. Należy także zauważyć, że poszczególne fragmenty nawet dla tego samego luzu, różnią się od siebie co widoczne jest już na rysunku 4, a uzyskane zbiory obciążone sporym rozrzutem. Ilustruje to tabela 1 gdzie przedstawiono wartości skuteczne przyspieszeń drgań dla wyciętych fragmentów sygnałów oraz ich odchylenia standardowe.

Konstrukcyjna wartość luzu zaworowego wynosi dla badanego silnika 0,5 mm. Jak wynika z analizy tabeli 1, wobec znacznej dyspersji wyników prawidłowe rozpoznanie luzu zaworowego na podstawie tylko wartości skutecznej jest niemożliwe. Można założyć, że identyfikacja luzu w oparciu same miary amplitudowe może być obciążona znacząco niepewnością. Wobec powyższego wydaje się zasadna ocena sygnałów w świetle wielu miar, a następnie ich selekcja ze względu na największy wkład informacji w detekcji klasy uwzględniającej dany luz zaworowy.

Tab.1. Zestawienie średniej wartości skutecznej i jej odchylenia standardowego mierzonej w pasmie do 6kHz dla różnych kierunków pomiarowych i różnych wartości luzu zaworowego silnika

Luz [mm]	Kierunek X		Kierunek Y		Kierunek Z	
	Średnie rms m/s <sup>2</sup>	Odchylenie standardowe m/s <sup>2</sup>	Średnie rms m/s <sup>2</sup>	Odchylenie standardowe m/s <sup>2</sup>	Średnie rms m/s <sup>2</sup>	Odchylenie standardowe m/s <sup>2</sup>
0,3	9.40	4.32	12.47	4.29	10.43	3.50
0,4	9.10	4.49	12.74	4.01	10.48	3.52
0,5	10.11	4.64	12.99	4.29	12.15	4.45
0,6	8.25	2.59	13.12	3.97	11.01	3.80
0,7	10.43	4.42	13.71	4.29	12.48	4.47
0,8	9.35	2.85	13.59	4.07	12.96	4.48
0,9	11.78	5.51	13.41	4.02	14.05	4.73
1,0	12.33	5.08	14.29	4.40	16.53	5.50


W celu uwypuklenia zjawisk, a także zmniejszenia wpływu niskich częstotliwości wyznaczono także zmianę przyspieszeń w czasie (jerk). Na rysunku 5c i 5d przedstawiono przebiegi tej wielkości odpowiadające zaprezentowanym przebiegom przyspieszeń drgań.

W celu wydobycia najbardziej istotnej informacji z wyizolowanych przebiegów wyznaczono obwiednię sygnałów stosując transformatę Hilberta i wyznaczając magnitudę sygnału analitycznego. Dodatkowo dokonano wygładzenia obwiedni modelem wyrównywania wykładniczego Browna:

$$\begin{cases} \hat{S}_1 = S_1 \\ \hat{S}_t = \alpha S_t + (1 - \alpha) \hat{S}_{t-1} \quad \text{dla } t > 1 \end{cases} \quad (1)$$

gdzie:  $S_t$  – wartości pierwotnych obserwacji,  $\hat{S}_t$  - wartości obserwacji po wygładzeniu,  $\alpha$  - współczynnik wygładzania (tutaj przyjęty arbitralnie jako  $\alpha=0,1$ ) oraz  $t$  – numer obserwacji.

Na rysunkach 6a i 6b przedstawiono uzyskaną obwiednię przebiegów z rysunku 5c i 5d oraz wygładzoną modelem wyrównywania wykładniczego obwiednię (rysunki 6c i 6d).



Rys.6. Obwiednia sygnału pochodnej przyspieszenia dla dwóch skrajnych przypadków luzu zaworowego (rysunki a i b), oraz wygładzona obwiednia (rysunki c i d); rysunek a, c – luz = 0,3 mm; rysunek b, d – luz = 1,0 mm

W celu wytrenowania systemu klasyfikacji w rozróżnianiu klas luzu zaworowego dokonano parametryzacji otrzymanych wycinków przebiegów przyspieszeń drgań, jego pochodnej oraz wygładzonej obwiedni. Uzyskaną obwiednię podzielono na dwa fragmenty odpowiadające okresom czasu, w których następuje zamknięcie pierwszego i drugiego zaworu.

Dla pierwotnego sygnału przyspieszeń, jego pochodnej względem czasu oraz sygnału odfiltrowanego w paśmie powyżej 2000Hz zastosowano miary sygnału takie jak: odcięta średnia ciężkości kwadratu sygnału, momenty zwykłe i centralne rzędu pierwszego i drugiego, momenty unormowane tych samych rzędów, wartość skuteczna sygnału, wartość szczytowa, między szczytowa, wartość średnia, pole powierzchni pod krzywą, współczynnik szczytu, kształtu, impulsowości, kurtoza sygnału. Dla obwiedni zastosowano zliczenie próbek powyżej zadanych poziomów (9 przyjętych poziomów), przy czym obwiednię podzielono na dwa fragmenty związane z zamknięciem pierwszego jak i drugiego zaworu. Analizy takie powtórzono dla trzech rejestrowanych kierunków. Ostatecznie wygenerowano ponad 300 parametrów. Dodatkowo jako atrybuty rozpatrzono informację o obciążeniu silnika oraz jego prędkości obrotowej). Dostępne próbki sygnału pozwoliły na wygenerowanie 32054 wektorów uczących. W porównaniu do liczby parametrów opisujących wektory uczące jest to mało liczny zbiór przykładów, stąd jak opisano dalej, dokonano selekcji cech diagnostycznych redukując wymiar wektorów uczących do 15 parametrów.

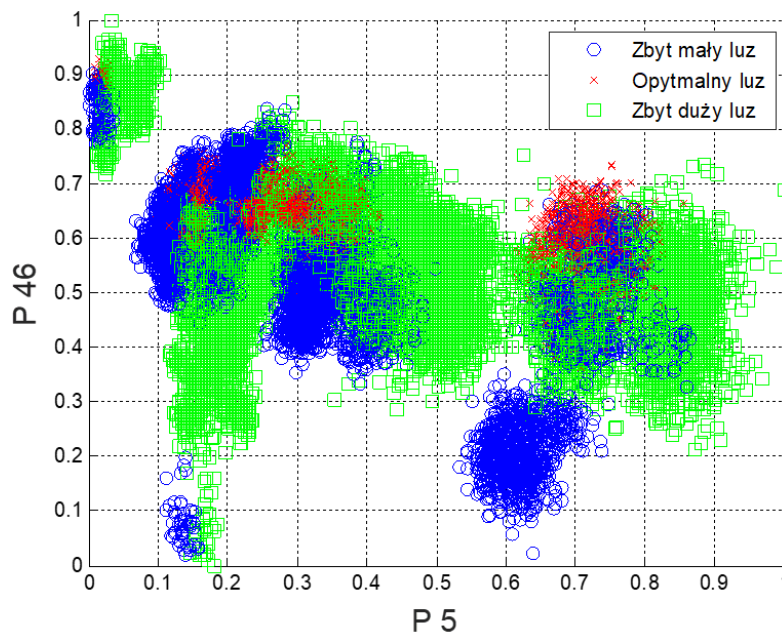
Każdy wektor uczący opatrzono etykietą związaną z luzem, przy czym dokonano podziału danych na trzy klasy: luz zbyt mały (mniejszy od 0,5 mm), luz optymalny (ok. 0,5 mm), luz zbyt duży (ponad 0,5 mm). W tabeli 2 zestawiono licznosci dostępnych przykładów dotyczących

odpowiednich klas. Jak wynika z tabeli liczby przykładów dla poszczególnych klas znacznie się różnią co determinuje sposób oceny wyników błędów klasyfikacji.

Tab. 2. Liczność dostępnych przykładów reprezentujących klasy

Klasa	Liczność przykładów
Zbyt mały luz	8160
Luz optymalny	4016
Zbyt duży luz	19878

Na rysunku 7 przedstawiono przykładową przestrzeń cech utworzoną przez dwa znormalizowane (normalizacja typu min-max) atrybuty oznaczone jako P5 i P46.



Rys. 7. Dostępne przykłady uczące na płaszczyźnie wyznaczonej przez dwa przykładowo wybrane atrybuty

### 3. Analiza danych

W pracy zaproponowano system identyfikacji luzu zaworowego pracującego silnika bazujący na metodach uczenia maszynowego. W tym celu porównano trzy metody: zbiór trzech drzew binarnych typu CART (Classification and Regression Tree) z zastosowaniem strategii OvA – one versus all, klasyfikator  $k$ - najbliższych sąsiadów ( $k$ -Nearest Neighbors), oraz sieć neuronową jednokierunkową MLP (multilayer perceptron) z trzema wyjściami związanymi z każdą z klas. Klasyfikator bazujący na zbiorze trzech drzew uczonych niezależnie rozpoznawać poszczególne klasy dotyczące luzu zaworowego. O przynależności do danej klasy decydowała pozytywna odpowiedź jednego z trzech wytrenowanych klasyfikatorów. Przy takim podejściu możliwe są sytuacje, w których żaden klasyfikator nie daje na wyjściu informacji o przynależności do danej klasy, jak i takie, w których pozytywnie odpowiada więcej niż jedno drzewo. Przyjęto rozwiązanie, w którym brak jednoznacznej klasyfikacji wymusza kolejną. W praktyce, gdy wystąpi taka sytuacja, system rozpoznawania dokona klasyfikacji kolejnych odcinków czasowych pomijając przypadki niepewne. Można również wielokrotnie powtarzać klasyfikację praktycznie w czasie rzeczywistym i podjąć decyzję na podstawie istotnej większości rozpoznań danej klasy. Wobec generacji dużej liczby danych przez pracujący silnik, w relatywnie krótkim

okresie czasu, zignorowanie niepewnych klasyfikacji nie rodzi żadnych problemów w praktyce. Podobny problem występuje także w zaproponowanym rozwiązaniu opartym o sieć neuronową. Tutaj można zastosować podejście, w którym o przynależności do danej klasy decyduje neuron w warstwie wyjściowej, który daje największą wartość wyjścia. Jest mało prawdopodobne, aby na więcej niż jednym wyjściu pojawiła się dokładnie taka sama wartość. Jednak może się zdarzyć, że odpowiedzi na wszystkich wyjściach sieci będą relatywnie na małym poziomie, co może zostać zinterpretowane jako przypadek nierozpoznany. Przyjęto, metodą prób i błędów, że wartość na wyjściu sieci musi przekroczyć próg 0,7, aby można było uznać przypisane danego przypadku do określonej klasy. W przypadku nieprzekroczenia tej wartości na żadnym wyjściu sieci uznaje się, że wystąpił stan nierozpoznany i sposób postępowania jest dokładnie taki sam jak w przypadku zbioru drzew klasyfikacyjnych.

W celu redukcji wymiaru wektorów cech określono, które z cech są najbardziej przydatne do klasyfikacji luzu zaworowego. W tym celu dokonano w pierwszej kolejności klasyfikacji za pomocą omówionego wcześniej klasyfikatora w postaci zbioru drzew klasyfikacyjnych. Jest wiadome, że algorytmy budowy drzewa stosują określoną miarę dobroci podziału i oceniają poszczególne cechy na podstawie tej miary. W zastosowanym algorytmie jako miarę jakości podziału wykorzystano indeks Giniego. Pod uwagę wzięto tylko te miary spośród wszystkich dostępnych, które posłużyły do budowy drzew. Następnie, na podstawie kolejnego kroku analizy, stwierdzono, że niektóre z tych miar są istotnie skorelowane liniowo. Po usunięciu niektórych z nich z zestawu danych i testach nie zauważono istotnego wzrostu błędu klasyfikacji za pomocą zbioru drzew. Finalnie otrzymano zbiór piętnastu cech, którego dalsze zmniejszanie objawiało się mniejszym lub większym wzrostem błędu testowania. Ostateczny zbiór cech zawierał między innymi takie miary jak: wartość skuteczna i współczynnik kształtu sygnału przyspieszeń, momenty zwykłe i centralne rzędu pierwszego i drugiego z sygnału przyspieszeń, wartość średnia i maksymalna, kurtoza z pochodnej sygnału przyspieszeń, liczby zliczeń próbek powyżej określonych poziomów (o małych wartościach) dla obwiedni pochodnej sygnału przyspieszeń i sygnału odfiltrowanego oraz prędkość obrotowa. Zdecydowana większość wybranych przez algorytm budowy drzewa miar dotyczyły kierunków pomiarowych X i Y. Informacja o obciążeniu nie okazała się istotna.

W celach porównawczych, te same cechy zastosowano w przypadku pozostałych klasyfikatorów. Oczywiście można zastosować tutaj także inne metody selekcji cech. Należy się liczyć z tym, że być może wyłoniłyby one inne atrybuty, lepsze dla innych klasyfikatorów. Porównanie jednak wielu możliwości nie było tutaj celem badań.

W klasyfikatorze k- najbliższych sąsiadów zmieniano wartość parametru k w zakresie od 1 do 11 oraz miarę odległości obserwując błąd testowania. Ostatecznie parametr ten przyjęto jako  $k=6$  i metrykę euklidesową.

Podobnie dokonano optymalizacji sieci MLP dokonując porównania błędów na zbiorze testowym. Najlepsze wyniki udało się uzyskać dla sieci z dwoma warstwami ukrytymi z 7 i 6 neuronami sigmoidalnymi w poszczególnych warstwach. Zwiększanie jak i zmniejszanie liczby neuronów skutkowało zwiększaniem błędu uczenia. Do uczenia zastosowano algorytm gradientowy Levenberga – Marquardta.

Za każdym razem ocena błędów klasyfikatorów odbyła się za pomocą powtarzanej metody Hold-Out, przy czym jako zbiór testowy przyjęto arbitralnie 25% przykładów oraz przyjęto 100 powtórzeń testu. Należy zaznaczyć, że metoda ta ma tendencję do przeszacowywania błędu rozpoznawania [26]. Uzyskana wartość odchylenia standardowego podczas powtarzania testu pozwala na określenie jak odporny jest dany algorytm klasyfikacyjny na zmiany danych uczących. Takie rozwiązanie ma także swoje wady gdyż jest mało prawdopodobne, że uda się podczas testów wyczerpać cały zestaw danych.

Ze względu na znaczną różnicę w liczności przedstawicieli różnych klas, w celu porównania metod obliczono błąd ważony klasyfikacji wyrażony wzorem:

$$\varepsilon = \frac{1}{K} \sum_{i=1}^K \frac{\sum_{j=1, j \neq i}^K a_{ij}}{K_i} \quad (2)$$

gdzie:  $K$  – liczba klas,  $K_i$  – liczba elementów w  $i$  – tej klasie,  $a_{ij}$  elementy macierzy rozkładu klas (macierzy pomyłek) z poza przekątnej.

Taka definicja błędu pozwala uwzględnić zróżnicowanie licznosci przykładów z różnych klas.

W tabeli 3 przedstawiono uśrednione wyniki uzyskane podczas testów porównywanych metod, natomiast poniżej macierze rozkładu klas. W przypadku sieci neuronowych jak i klasyfikatora  $k$ -NN zaprezentowano wyniki dla najlepszych klasyfikatorów (o najlepiej dobranej strukturze sieci w przypadku klasyfikatora  $k$ -NN o optymalnym parametrze  $k$  jak i mierze odległości). Ze względu na zróżnicowaną licznosc reprezentantów danej klasy liczbę pomyłek odniesiono do liczby przedstawicieli danej klasy.

Tab.3. Wyniki testowania klasyfikatorów

Metoda	Sredni bład wazony klasyfikacji [%]	Odchylenie standardowe błędu - miara odporności klasyfikatora na zmianę zbioru uczącego [%]	Udział klasyfikacji niepewnych [%]
Zbiór drzew	0,93	0,13	3,14
$k$ -NN ( $k=6$ )	1,98	0,30	0
MLP [7,6]	1,73	0,70	3,27

W tabelach 4-6 zaprezentowano macierze rozkładu klas dla różnych metod identyfikacji klasy.

Tab.4. Macierz rozkładu klas dla zbioru drzew klasyfikacyjnych

Klasy rozpoznane		Klasy rzeczywiste		
		Zbyt mały luz [%]	Optymalny luz [%]	Zbyt duży luz [%]
	Zbyt mały luz	99,4	0,4	0,2
	Optymalny luz	0,1	98,1	0,1
	Zbyt duży luz	0,5	1,5	99,7

Tab. 5. . Macierz rozkładu klas dla klasyfikatora  $k$ -NN ( $k=6$ )

Klasy rozpoznane		Klasy rzeczywiste		
		Zbyt mały luz [%]	Optymalny luz [%]	Zbyt duży luz [%]
	Zbyt mały luz	99,2	1,1	0,4
	Optymalny luz	0,4	96,0	0,8
	Zbyt duży luz	0,4	2,9	98,8

Tab.6. Macierz rozkładu klas dla klasyfikatora w postaci sieci neuronowej [7,6] (7 i 6 neuronów w warstwach ukrytych)

Klasy rozpoznane		Klasy rzeczywiste		
		Zbyt mały luz [%]	Optymalny luz [%]	Zbyt duży luz [%]
	Zbyt mały luz	98,8	0,6	0,7
	Optymalny luz	0,2	97,1	0,4
	Zbyt duży luz	1,0	2,3	98,9

Z porównania klasyfikatorów wynika, że najkorzystniejszym spośród rozpatrywanych rozwiązaniem identyfikacji klasy związanej z luzem zaworowym dla badanego silnika jest zbiór klasyfikatorów binarnych. Klasyfikator  $k$ -NN w zastosowanym algorytmie nie identyfikuje przypadków niepewnych. Tłumaczy to większy błąd klasyfikacji niż w przypadku pozostałych klasyfikatorów. „Trudne” przypadki zostają sklasyfikowane, a nieuznawane za niepewne. Istnieje oczywiście możliwość wprowadzenia algorytmu  $(k,l)$  najbliższych sąsiadów, w którym w przypadku zbyt małej liczby sąsiadów głosujących za daną klasą (mniej niż  $l$ ), klasyfikację uznajemy za niepewną. Jednak wprowadza to kolejny parametr  $l$  do optymalizacji klasyfikatora. W przypadku zbioru drzew jak i sieci, jak wspomniano poprzednio, klasyfikacje niepewne są odrzucane, a decyzja co do przynależności do klasy odbywać się może na podstawie kolejnych próbek sygnału. Po odrzuceniu niepewnych klasyfikacji zbiór drzew pozwala na klasyfikację luzu z dokładnością rzędu 99% pomimo wpływu różnego obciążenia i prędkości obrotowej. W przypadku pozostałych klasyfikatorów wyniki są słabsze (ok. 98%) jednak akceptowalne, zwłaszcza, że dla postawionego problemu można, w krótkim czasie wielokrotnie powtórzyć diagnozę.

Klasyfikator oparty o drzewa klasyfikacyjne cechował się również największą odpornością na zmianę zbioru uczącego mierzoną za pomocą odchylenia standardowego błędu. Wszystkie klasyfikatory popełniają najwięcej błędów w prawidłowym rozpoznaniu luzu optymalnego i najczęściej jest on mylony ze zbyt dużym luzem (odpowiednio 1,5%, 2,9 % i 2,3 % przypadków luzu optymalnego zostało sklasyfikowanych jako luz zbyt duży). Najlepsze wyniki pod tym względem uzyskuje zbiór drzew klasyfikacyjnych. W przypadku tego klasyfikatora najlepiej, z spośród porównywanych metod, identyfikowany był także nadmierny luz zaworowy.

#### 4. Podsumowanie

W wyniku przeprowadzonych analiz można zaproponować metodę klasyfikacji luzu zaworowego silnika w oparciu o sygnały drganiowe mierzone na głowicy. Dla rozpatrywanego silnika udaje się to zrobić z trafnością ok. 99%. Biorąc pod uwagę możliwość wielokrotnego powtórzenia procesu klasyfikacji w czasie prawie rzeczywistym i wybierając najczęściej występującą klasę można podjąć decyzję o klasie luzu zaworowego z dużą dozą pewności. Do określenia tego stanu w przypadku badanego silnika wystarcza 15 parametrów liczbowych nietrudnych do uzyskania. Oczywiście w przypadku innych typów silnika będzie konieczne przeprowadzenie na nowo całego procesu budowy klasyfikatora.

W pracy zaproponowano zastosowanie do rozwiązania przedstawionego problemu zbiorów trzech drzew binarnych wyspecjalizowanych w identyfikacji każdej klasy luzu zaworowego. Takie podejście pozwala osiągnąć relatywnie małe błędy klasyfikacji (dla rozpatrywanego przypadku) jak i automatyzuje dobór składowych wektora uczącego. Dodatkowo drzewo pozwala w prosty sposób wygenerować czytelne dla człowieka reguły, łatwe także do zaimplementowania w systemie, który miałby działać automatycznie.

#### Źródło finansowania

Prezentowane wyniki badań, zostały współfinansowane z subwencji przyznanej przez Ministerstwo Nauki i Szkolnictwa Wyższego 05/52/SBAD/0295 and 02/21/SBAD/3558



## Bibliografia

- 1 Albarbar A, Ball A, Starr A. On acoustic measurement-based condition monitoring of internal combustion engines. *Insight: Non-Destructive Testing and Condition Monitoring* 2008; 50(1): 30–34.
- 2 Albertson F, Bodén H, Gilbert J. Comparison of different methods to couple nonlinear source descriptions in the time domain to linear system descriptions in the frequency domain - Application to a simple valveless one-cylinder cold engine. *Journal of Sound and Vibration* 2006; 291(3–5): 963–985.
- 3 Arroyo J, Muñoz M, Moreno F, Bernal N, et al. Diagnostic method based on the analysis of the vibration and acoustic emission energy for emergency diesel generators in nuclear plants. *Applied Acoustics* 2013; 74(4): 502–508.
- 4 Babu A K, Raj A A, Kumersan G. Misfire detection a multi- cylinder diesel engine: a machine learning approach. *Journal of Engineering Science and Technology* 2016; 11(2): 278–295.
- 5 Badawy T, Shrestha A, Henein N. Detection of Combustion Resonance Using an Ion Current Sensor in Diesel Engines. *Journal of Engineering for Gas Turbines and Power* 2012; 134(5): 052-802.
- 6 Ahmed A B, Elaraby I S. A prediction for Student's Performance Using Decision Tree ID3 Method. *India - World Journal of Computer Application and Technology* 2014; 2(2): 43–47.
- 7 Czech P, Bąkowski H. Diagnosing of car engine fuel injectors damage using dwt analysis and PNN neural networks. *Transport Problems* 2013; 8(3): 85–91.
- 8 Delvecchio S, Bonfiglio P, Pompoli F. Vibro-acoustic condition monitoring of Internal Combustion Engines: A critical review of existing techniques. *Mechanical Systems and Signal Processing* 2018; 99: 661–683.
- 9 Desbazeille M, Randall R B, Guillet F, El Badaoui M, et al. Model-based diagnosis of large diesel engines based on angular speed variations of the crankshaft. *Mechanical Systems and Signal Processing* 2010; 24(5): 1529–1541.
- 10 Dolatabadi N., Theodossiades S., Rothberg S.J., On the identification of piston slap events in internal combustion engines using tribodynamic analysis. *Mechanical Systems and Signal Processing* 2015; 58: 308–324.
- 11 Erbek F S, Özkan C, Taberner M. Comparison of maximum likelihood classification method with supervised artificial neural network algorithms for land use activities. *International Journal of Remote Sensing* 2004; 25(9): 1733–1748
- 12 Figlus T, Liščák Š, Wilk A, Łazarz B. Condition monitoring of engine timing system by using wavelet packet decomposition of a acoustic signal. *Journal of Mechanical Science and Technology* 2014; 28(5): 1663–1671.
- 13 Fog T.L., Hansen L.K., Larsen J., Hansen H.S., et al., On condition monitoring of exhaust valves in marine diesel engines. *Neural Networks for Signal Processing IX, 1999. Proceedings of the 1999 IEEE Signal Processing Society Workshop 1999*; 554–563.
- 14 Gao F, Lv J. Fault Diagnosis for Engine Based on Single-Stage Extreme Learning Machine. *Mathematical Problems in Engineering* 2016; 2016: 1–10.
- 15 Gorges C, Öztürk K, Liebich R. Impact detection using a machine learning approach and experimental road roughness classification. *Mechanical Systems and Signal Processing* 2019; 117: 738–756.
- 16 Jia F, Lei Y, Lu N, Xing S. Deep normalized convolutional neural network for imbalanced fault classification of machinery and its understanding via visualization. *Mechanical Systems and Signal Processing* 2018; 110: 349–367.

- 17 Korbicz J, Kościelny J M, Kowalczyk Z, Cholewa W (Eds.). *Models, Artificial Intelligence, Applications*. Springer-Verlag Berlin Heidelberg, 2004.
- 18 Lahrache A, Cocconcelli M, Rubini R. Anomaly detection in a cutting tool by k-means clustering and support vector machines. *Diagnostyka* 2017; 18(3): 21–29.
- 19 Leemans V, Magein H, Destain M F. Defect segmentation on ‘Jonagold’ apples using colour vision and a Bayesian classification method. *Computers and Electronics in Agriculture* 1999; 23: 43–53.
- 20 Lei Y, He Z, Zi Y. Application of an intelligent classification method to mechanical fault diagnosis. *Expert Systems with Applications* 2009; 36(6): 9941–9948.
- 21 Madej H, Czech P. Discrete wavelet transform and probabilistic neural network in IC engine fault diagnosis. *Eksplotacja i Niezawodność - Maintenance and reliability* 2010; 4(48): 47–54.
- 22 Matzke W. *Four-stroke engine timing*, Warszawa: WKiŁ, 1967.
- 23 Mechefske C K, Mathew J. Fault detection and diagnosis in low speed rolling element bearings Part II: The use of nearest neighbour classification. *Mechanical Systems and Signal Processing* 1992; 6(4): 309–316.
- 24 Nguyen T T, Armitage G. A survey of techniques for internet traffic classification using machine learning. *IEEE Communications Surveys Tutorials* 2008, 10(4): 56–76.
- 25 Niziński S, Michalski R. *Diagnostics of technical objects*. Radom: Department of Vehicle and Machine Operation, Faculty of Technical Sciences, University of Warmia and Mazury in Olsztyn, Institute for Sustainable Technologies in Radom, 2002.
- 26 Osiecki J, Ziemba S. *Basics of mechanical vibration measurements*, Warszawa: PWN, 1968.
- 27 Potočník P, Govekar E. Semi-supervised vibration-based classification and condition monitoring of compressors. *Mechanical Systems and Signal Processing* 2017; 93: 51–65.
- 28 Qinghua W, Youyun Z, Lei C, Yongsheng Z. Fault diagnosis for diesel valve trains based on non-negative matrix factorization and neural network ensemble. *Mechanical Systems and Signal Processing* 2009; 23(5): 1683–1695.
- 29 Ruiz M, Mujica L E, Alférez S, Acho L, et al. Wind turbine fault detection and classification by means of image texture analysis. *Mechanical Systems and Signal Processing* 2018; 107: 149–167.
- 30 Serridge M, Licht T R. *Piezoelectric accelerometers and vibration preamplifiers*, Nearum: Brüel & Kjær, 1987.
- 31 Szymański G.M., Tomaszewski F., *Diagnostics of automatic compensators of valve clearance in combustion engine with the use of vibration signal*. *Mechanical Systems and Signal Processing* 2016; 68–69: 479–490.
- 32 Wang C, Zhang Y, Zhong Z. Fault diagnosis for diesel valve trains based on time-frequency images. *Mechanical Systems and Signal Processing* 2008; 22(8), 1981–1993.
- 33 Wong P K, Zhong J, Yang Z, Vong C M. Sparse Bayesian extreme learning committee machine for engine simultaneous fault diagnosis. *Neurocomputing* 2016; 174: 331–343.
- 34 Wu J, Liu C. An expert system for fault diagnosis in internal combustion engines using wavelet packet transform and neural network. *Expert Systems with Applications* 2009, 36: 4278–4286.
- 35 Zhang H, Li J, Huang Y, Zhang L. A Nonlocal Weighted Joint Sparse Representation Classification Method for Hyperspectral Imagery. *IEEE Journal of Selected Topics in Applied Earth Observations and Remote Sensing* 2014; 7(6): 2056–2065