

Piotr BOGUŚ*
Jerzy MERKISZ

Wykrywanie zjawiska wypadania zapłonu w silniku o zapłonie samoczynnym w oparciu o grupowanie danych w krótkoczasowej analizie sygnałów wibroakustycznych

W pracy zaprezentowano rezultaty badań nad nowymi metodami diagnostycznymi silników spalinowych. W pracy opisano zastosowanie krótkoczasowej analizy sygnałów oraz wybranych technik rozpoznawania obrazów do diagnostyki wypadania zapłonu w silniku z ZS z wykorzystaniem sygnałów wibroakustycznych. Badania dotyczyły, przede wszystkim, silnika lokomotywy spalinowej. W zakresie niedrogowych źródeł zanieczyszczeń powietrza lokomotywy spalinowe stanowią znaczący czynnik. W zakresie tym pojawiły się wprawdzie przepisy prawne ograniczające zanieczyszczenia (np. Karta UIC 623 1-2-3 w Europie), ale ciągle brak jest jednolitych obligatoryjnych standardów monitorowania emisyjnie krytycznych uszkodzeń. Tego typu obligatoryjne systemy diagnostyki pokładowej (ang. OBD – on-board diagnostic systems) zostały już wprowadzone dla samochodów osobowych (OBD II, EOBD). System OBD dokonuje ciągłego monitorowania podstawowych parametrów systemu i jednym z jego głównych zadań jest wykrywanie wypadania zapłonu. Powyższe spostrzeżenia stały się impulsem do szukania nowych metod w zakresie diagnostyki silników spalinowych. Głównym celem badań było rozróżnienie pomiędzy stanem normalnej prawidłowej pracy silnika i stanem wypadania zapłonu. Zaproponowana metoda została zainspirowana metodami krótkoczasowej analizy Fouriera. W podejściu tym oblicza się wartości wybranych parametrów w oknie czasowym przesuwanym się wzdłuż sygnału. Dla każdej pozycji okna otrzymuje się zbiór wartości parametrów, który reprezentuje punkt w odpowiedniej wielowymiarowej przestrzeni parametrów. Wówczas ewolucja czasowa sygnału może być obserwowana jako odpowiedni wykres w przestrzeni parametrów. Można oczekiwać, że różne stany systemu (np. wypadanie zapłonu) będzie można rozróżniać jako różne położenia punktów w przestrzeni parametrów. W celu ich wykrywania zaproponowano w pracy grupowanie danych w przestrzeni parametrów. Pierwsze rezultaty pokazują, że jest możliwe rozróżnienie grup w przestrzeni parametrów, które odpowiadają różnym stanom silnika.

Słowa kluczowe: sygnały wibroakustyczne, OBD, analiza krótkoczasowa, grupowanie danych, diagnostyka silnika

Misfire detection in a diesel engine using clustering in a short-time analysis of vibroacoustic signals

The paper presents some results of the research on new diagnostic methods in combustion engines. It describes the application of short-time signal analysis together with pattern recognition techniques in the diagnosis of misfire in Diesel engines through vibroacoustic signals. One considered Diesel locomotive in particular. In the area of the non-road sources of combustion gases the locomotives rate relatively high as air polluters. There are some regulations in the area of locomotives (e.g. Cart UIC 623 1-2-3 in Europe) but we still observe a lack of obligatory requirements for systems monitoring emission critical damage. Such obligatory on-board diagnostic systems were introduced for passenger cars (OBD II, EOBD). The OBD system performs a continuous monitoring of basic system parameters and one of its most important tasks is misfire detection. All these facts inclined the author to research the new relevant detection methods. The main aim of the research is to distinguish between two states: normal engine operation and the state of misfire. The general idea of the method was taken from the short-time Fourier analysis. The method is based on calculation of the values of some selected parameters in the time window sliding along the signal. For each window position one has a set of parameter values which gives the point in a corresponding multidimensional parameter space. Hence, the time evolution of the signal can be observed as the evolution plot in the parameter space. We suspect that the different system states (misfire) can be distinguished by the different position of points in the parameter space. In order to detect them, the clustering in the parameter space was performed. The first results show the possibility of distinguishing some different clusters within the parameter space which may correspond to different engine states.

Key words: vibroacoustic signals, OBD, short-time analysis, clustering, engine diagnosis

1. Wstęp

W zakresie diagnostyki silników spalinowych (szczególnie silników o zapłonie samoczynnym (ZS)) można znaleźć wiele rozwiązań i podejść, wiele z nich jest używanych obecnie w zastosowaniach komercyjnych. Praca opisuje zastosowanie analizy krótkoczasowej do diagnostyki wypadania

1. Introduction

In the area of combustion engines diagnostic (particularly Diesel engines) one can find many methods and approaches, some of them have been used in commercial systems. The paper presents the approach bases on a short-time analysis of vibroacoustic signals taken from an engine. The pa-

zapłonu przy użyciu sygnału wibroakustycznego pozyskanego z silnika. Głównym celem badań było rozróżnienie pomiędzy normalnym stanem działania silnika oraz przypadkiem występowania wypadania zapłonu. Zasadnicza idea zaproponowanej w pracy metody została zaczerpnięta z krótkoczasowej transformaty Fouriera.

Podejście opisane w pracy polega na obliczaniu wartości wybranych parametrów w oknie czasowym przesuwającym się wzdłuż sygnału. Dla każdej chwili czasu otrzymujemy zbiór parametrów, który odpowiada punktowi w wielowymiarowej przestrzeni parametrów. Wówczas ewolucja czasowa sygnału może być obserwowana jako zbiór punktów w przestrzeni parametrów. Można oczekiwać, że różne stany systemu będziemy odróżniać po innym położeniu w przestrzeni parametrów obiektów geometrycznych reprezentujących ewolucję czasową tego sygnału. Dla ich wykrycia przeprowadzone zostanie grupowanie danych w przestrzeni parametrów.

Badania, których wyniki przedstawiono w tej pracy, koncentrują się na silnikach ZS, w tym również na silnikach lokomotyw spalinowych. Należy pamiętać, że w zakresie niedrogowych źródeł zanieczyszczeń powietrza lokomotywy spalinowe stanowią bardzo znaczący składnik. Dla lokomotyw spalinowych istnieją pewne przepisy ograniczające ilość spalin (np. UIC 623 1-2-3 w Europie), ale zasadniczo jest brak obowiązkowych wymagań jeśli chodzi o systemy monitorujące emisyjnie krytyczne uszkodzenia. Tego typu obowiązkowe systemy diagnostyki pokładowej już od paru dobrych lat są stosowane w samochodach osobowych (OBD II w USA oraz EOBD w Europie). Typowy system OBD dokonuje ciągłego monitorowania podstawowych parametrów pojazdu i jednym z jego podstawowych zadań jest wykrywanie wypadania zapłonu. Całość powyższych spostrzeżeń stała się podstawą do podjęcia badań w zakresie nowych metod wykrywania wypadania zapłonu, szczególnie tych, które można zastosować do ciężkich silników ZS lokomotyw spalinowych.

Silnik spalinowy może być źródłem wielu typów sygnałów, które nadają się do analizy – można wymienić sygnały wibroakustyczne pochodzące od czujników przyspieszenia, całość sygnałów akustycznych pozyskiwanych mikrofonami, sygnały elektryczne pochodzące od detektorów prądów jonowych w komorze spalania, sygnały reprezentujące prędkość kątową wału korbowego, sygnały ciśnieniowe itp. [15,16]. W pracy zaprezentowano badania i wyniki dla detekcji wypadania zapłonu bazujące na sygnałach wibroakustycznych.

2. Metody analizy krótkoczasowej

Idea analizy krótkoczasowej zaproponowana w pracy została zaczerpnięta z koncepcji krótkoczasowego widma Fouriera. Typowe widmo Fouriera reprezentuje globalną charakterystykę sygnału, ale nie zapewnia żadnej informacji na temat lokalnych i chwilowych zmian w sygnale. Dla znalezienia lokalnych właściwości sygnału używa się zazwyczaj krótkoczasowe widmo Fouriera [2, 3, 12, 16] lub analizę falkową [9].

Krótkoczasowe widmo Fouriera polega na obliczaniu chwilowego widma w przesuwającym się oknie. Dla każdej

per describes the application of short-time signal analysis in the diagnosis of misfire in Diesel engines through vibroacoustic signal. The main aim of the research is to distinguish between normal engine operation and that of misfire. The general idea of the method was taken from the short-time Fourier analysis where short-time spectrum of the signal takes place. In our approach we calculate the values of some selected parameters in the time window sliding along the signal.

For each time we have a set of parameter values and it creates the point in a corresponding multidimensional parameter space. Thus, the time evolution of the signal can be observed as the point evolution in the parameter space. Then, we suspect that the different system states can be distinguished by the different position of points in the parameter space. In order to detect that, the clustering in the parameter space should be performed.

The research focused on signals obtained from the Diesel engines and first of all locomotive diesels. In the area of the non-road sources of combustion gases the locomotives rate relatively high as air pollutants. There are some regulations in this area (e.g. UIC 623 1-2-3 in Europe) but we still observe a lack of obligatory requirements for systems monitoring emission critical damage. Such obligatory on-board diagnostic systems were introduced for passenger cars (OBD II in the U.S. and EOBD in Europe). The OBD system performs a continuous monitoring of basic power transmission system parameters and one of its most important tasks is misfire detection. All these facts inclined the authors to research the new relevant detection methods, particular those applicable in Diesel engines.

The combustion engine is a source of many signals which can be analyzed – e.g. vibration signals from the sensors mounted in the engine, all acoustic signals, signals from the ionic current detectors, signals indicating crankshaft angle velocity, pressure signals etc. [15,16]. The paper shows some results of the research on misfire detection methods which utilize short-time analysis of vibroacoustic signals obtained from Diesel engines.

2. Short-time analysis methods

The idea of short-time analysis presented in the paper was taken from the concept of short-time Fourier spectrum. Fourier spectrum represents a global signal characteristic, but it does not provide any information about local and instantaneous signal alterations and appears insufficient in describing any local properties and signal alterations. For local and instantaneous signal properties one can use a short-time Fourier spectrum [2, 3, 12, 16] or wavelets analysis [9].

Short-time Fourier spectrum consists in calculating the instantaneous spectrum in a sliding window. Hence, for each moment we obtain the corresponding spectrum that can alter in time. The instantaneous continuous spectrum can be defined in many ways. We present here a spectrum defined as the short-time Fourier transformation [2, 3, 12, 15, 16]. It takes the following definition (1), where $u(i)$ is a discrete time function and $h(n)$ is a time function called a window

chwili otrzymujemy widmo, które może się zmieniać w czasie. Ciągłe chwilowe widmo można zdefiniować na wiele sposobów. Widmo zdefiniowane jako krótkoczasowa transformata Fouriera [2, 3, 12, 15, 16] definiuje wzór:

$$U(f, n) = \sum_{i=-\infty}^{+\infty} u(i) h(n-i) e^{-j2\pi f T i}, \quad (1)$$

gdzie $u(i)$ jest dyskretną funkcją czasu, a $h(n)$ jest funkcja czasu zwaną funkcją okna. Powyższe widmo jest widmem ciągłym, które jest okresowe w dziedzinie częstotliwości f i zależy od funkcji okna oraz chwili n . Zwykle zakłada się, że dla każdego okna $h(n)$ istnieje jego transformata

$$H(f) = \sum_{n=-\infty}^{+\infty} h(n) e^{-j2\pi f n T}. \quad (2)$$

Funkcja okna powinna mieć kształt okna zarówno po stronie czasu, jak i częstotliwości. Najlepiej jeśli obydwie wielkości byłyby kształtu prostokątnego. Niestety jest to nie możliwe i w praktyce obok okien prostokątnych używa się innych, takich jak np. okno Bartleya, Hanninga, Hamminga i podobne [2, 3, 12, 16].

Również widmo falkowe daje wprost lokalne zmiany w sygnale. W wyniku jego zastosowania otrzymujemy widmo falkowe dla całego sygnału, tak, że każdy składnik ma amplitudę i określoną pozycję w czasie. Widmo falkowe bierze jednak pod uwagę cały sygnał na raz, co czyni je trudną do zastosowania w analizie typu *on-line* [9].

3. Techniki rozpoznawania obrazów w analizie krótkoczasowej

Podejście zaproponowane w pracy rozważa wybrane parametry w oknie czasowym przesuwającym się wzdłuż sygnału. Ogólny schemat algorytmu jest następujący [7, 8, 10]:

1. Dokonuje się wyboru szerokości okna czasowego.
2. Dokonuje się wyboru zbioru parametrów, które będą obliczane w oknie czasowym.
3. W przesuwającym się w czasie oknie, dla danej jego pozycji oblicza się wartości wybranych parametrów (patrz rys. 1).
4. Zbiór wartości parametrów dla danej pozycji okna reprezentuje punkt w wielowymiarowej przestrzeni parametrów.
5. Przesuwające się w czasie okno wyznacza zbiór punktów w przestrzeni parametrów, które odpowiadają kolejnym położeniom okna. Obiekt utworzony przez ten zbiór punktów reprezentuje ewolucję czasową w przestrzeni parametrów.
6. Porównanie różnych sygnałów bazuje na grupowaniu danych w przestrzeni parametrów i porównywaniu środków grup.

Można wziąć pod uwagę bardzo wiele parametrów obliczanych w oknie czasowym. Na przykład prążki klasycznej transformaty Fouriera (FFT), parametry statystyczne jak średnia, mediana, kolejne momenty itp. Zastosowanie parametrów nieliniowych jak np. wykładniki Lapunowa lub wymiary korelacyjne również okazuje się interesujące [1, 6, 9].

The above spectrum is a continuous spectrum which is periodical in a frequency f and depends on the window function and the moment n . We usually assume that for each window function $h(n)$ a Fourier transformation exists and is as follows (2).


Usually a window function should have a window shape, both in the time and frequency domains. The best is when both functions are rectangular. Unfortunately this is not possible and beside the rectangular windows we use other windows such as Bartley window, Hanning window, Hamming window and the like [2, 3, 12, 16].

In turn, the wavelet spectrum gives us the local signal alteration but it takes into account the signal as a whole. For all the signals we can find the wavelet spectrum, where each component has an amplitude and a position in time. The wavelet spectrum takes into account the whole signal in time what makes difficult to apply it in *on-line* analysis [9].

3. Pattern recognition techniques in short-time signal analysis

The approach proposed in the paper consists in a consideration of particular parameters in the time window sliding along the signal. The general schema of the algorithm is as follows [7, 8, 10]:

1. Choose the width of a given time window.
2. Choose the set of parameters which will be calculated in the window.
3. In a sliding window for a given window position calculate some signal parameters (see Fig. 1).
4. The set of parameter values for a given window position represents a point in a multidimensional parameter space.



Rys. 1. Okno czasowe (szerokości 200 próbek), przesuwające się wzdłuż sygnału przyspieszenia

Fig. 1. The time window (width 200 samples) which slides along the given acceleration signal

Grupowanie danych jest jedną z ważniejszych technik i metod stosowanych w rozpoznawaniu obrazów. Jeśli założymy, że mamy zbiór X o n elementach, to grupowanie danych oznacza podział zbioru X na c podzbiorów, których elementy są do siebie maksymalnie podobne. Wybór liczby c (mniejszej od liczby elementów n) jest zazwyczaj arbitralny, często wynika z wiedzy *a priori* na temat danego problemu [4, 5, 12].

Najprostszym algorytmem grupowania danych jest algorytm grupowania po c średnich. Algorytm ten można używać znajdując ekstremum funkcji celu w postaci [4, 5, 12]:

$$J = \sum_{i=1}^n \sum_{j=1}^c p_{ij} E_{ij}, \quad (3)$$

gdzie energia E_{ij} jest zdefiniowana jako odległość Euklidesowa $E_{ij} = d_{ij} = |x_i - y_j|^2$ pomiędzy punktem danych x_i i środkiem grupy y_j . Zakłada się ponadto, że prawdopodobieństwa p_{ij} (które można również interpretować jako wartości przynależności) wiążące punkt x_i do grupy j są opisane:

$$\forall_{ij} \quad p_{ij} = \begin{cases} 1 & \text{gdy } x_i \in j \\ 0 & \text{gdy } x_i \notin j \end{cases} \quad (4)$$

Wektor x_i jest elementem grupy j gdy odległość do środka tej grupy jest minimalna.

Algorytm grupowania po c średnich jest obciążony problemem minimów lokalnych i często trudno przy jego pomocy osiągnąć właściwe rezultaty. Jest to przyczyną dla której ciągle rozwija się i proponuje w tym zakresie nowe i lepsze algorytmy [4, 5, 14, 19].

4. Pomiary

Badania zostały przeprowadzone na jednocyndrowym 4-suwowym badawczym silniku ZS typu SB 3.1 oraz lokomotywie 401Da – 427 wyposażonej w silnik 16H12A Henschel – 12V.

Dla jednocyndrowego silnika testowego pomiary były przeprowadzone z użyciem rejestratora cyfrowego TEAC RD-135T. Sygnał wibroakustyczny był mierzony w trzech prostopadłych kierunkach przestrzennych. Częstotliwość próbkowania wynosiła 12 kHz. Dokonano pomiarów przyspieszenia, prędkości drgań oraz ciśnienie w cylindrze. Prędkość obrotowa i moment obrotowy były zmieniane w zakresie: $n = 700 \div 1700$ obr/min, $M_o = 0 \div 90$ N·m. Pomiarów dokonano dla 21 punktów pracy dla różnych prędkości obrotowej i momentu obrotowego. Na rysunku 2 pokazano przykładowy pozyskany sygnał przyspieszania.

Dla jednocyndrowego silnika badawczego równocześnie z pomiarem wibroakustycznego sygnału przyspieszenia pozyskiwano odpowiadający mu sygnał ciśnienia w cylindrze. To dawało informacje na temat, który sygnał przyspieszenia reprezentował stan z pojawiającym się wypadaniem zapłonu. Biorąc pod uwagę wykres ciśnienia, przypadki wypadania zapłonu były identyfikowane jako znaczące obniżenie się szczytowych wartości ciśnień.

Dla silnika lokomotywy spalinowej porównywano dwa podstawowe rodzaje sygnałów: sygnał nieprawidłowy (wy-

5. Sliding the window in time along the whole signal gives the set of points in the multidimensional parameter space.
6. The comparison of different signals is based on the clustering in the parameter space and comparison of the cluster centers.

Many kinds of parameters calculated in a time window can be taken into consideration. For example lines of classical Fourier transformation (FFT), statistical parameters like median higher order moments etc. The application of non-linear parameters like Lyapunov exponents, correlation dimensions etc. also appears interesting [1, 6, 9].

The clustering is one of the most important techniques of pattern recognition. If we assume we have n element data set X , the clustering means that we want to find the number c (lower than the number of elements n) and divide data set X for c subsets, where elements are most similar to each other [4, 5, 12].

The most popular clustering algorithm is a classical hard c -means algorithm of clustering. The c -means clustering algorithm can be obtained by optimization of the objective function in a form [4, 5, 12] (3), where energy E_{ij} is defined as an Euclidean distance $E_{ij} = d_{ij} = |x_i - y_j|^2$ between data point x_i and center of cluster y_j . It is assumed that probabilities (membership values) p_{ij} that associate data point x_i to cluster j are (4).

Vector x_i is considered as an element of group j when the distance to the cluster center is minimal.

Classical hard c -means algorithm of clustering poses a problem of local minima that makes a solution difficult to find. For this reason all the time the new and better clustering algorithms are developed [4, 5, 14, 19].


4. Measurements

The tests were performed on one-cylinder 4-stroke Diesel test engine SB 3.1, 401Da – 427 locomotive with a 16H12A Henschel – 12V engine.

For the one-cylinder test engine the measurements of the pressure and vibrations were performed through signal recorder TEAC RD-135T. The vibroacoustic signal was measured in three space directions with the use of a piezoelectric sensors Brüel & Kjaer 4391. The sample frequency was 12 kHz. The following quantities were measured: acceleration, vibration velocity and cylinder pressure. In the tests revolutions and torque were changed in the range: $n = 700 \div 1700$ rev/min, $M_o = 0 \div 90$ N·m. The measurements were performed for 21 working points with different torque and revolutions. Fig. 2 presents an example of the acceleration signal which was examined.

For the one-cylinder test engine measurements together with the vibroacoustic signal the corresponding pressure signal was acquired. This gave us the knowledge of which acceleration signal represents the state of misfire. Taking into account the plots of the cylinder pressure the misfires were identified as significant decreases of the pressure plot peaks.

For the locomotive engine two kinds of signals were compared: an improper signal (misfire simulated by disconnection of one cylinder) with a proper signal (all cylinders operative).



Rys. 2. Przykładowy wykres sygnału przyspieszenia (oś Z, $M_o = 0 \text{ N}\cdot\text{m}$, $n = 1700 \text{ obr/min}$; A – pełny wykres, B – fragment)

Fig. 2. Acceleration plot for the working engine corresponds to the pressure signal from fig. 6 (axis Z, $M_o = 0 \text{ N}\cdot\text{m}$, $n = 1700 \text{ rev/min}$; A – full plot, B – part of the plot)

padanie zapłonu symulowane poprzez odłączenie jednego cylindra) oraz prawidłowy (wszystkie cylindry pracują).

Dla silnika lokomotywy spalinowej czujnik został przy-mocowany na korpusie silnika na cylindrze 1. Pomiarów dokonano z użyciem 16-kanalowego cyfrowego rejestratora TA11 GOLD, który wykorzystuje piezoelektryczny czujnik 4395 produkowany przez Brüel & Kjaer oraz programy pozyskiwania i analizy danych. Pomiarów dokonywano dla trzech wartości prędkości obrotowych wału korbowego: 650-680 obr/min (bieg jałowy), 1100 obr/min i 1500 obr/min, w trzech fazach: wszystkie cylindry pracują, odłączono cylinder 1, odłączono cylinder 4. Sygnał był rejestrowany w trzech kanałach, każdy reprezentujący składową w jednym kierunku przestrzennym: równoległym do osi głównej lokomotywy, horyzontalnym-prostopadłym i pionowym-prostopadłym do osi głównej lokomotywy. Częstotliwość próbkowania wynosiła 20 kHz.

Wszystkie otrzymane sygnały były następnie analizowane przy użyciu oprogramowania MATLAB. Do grupowania danych zastosowano klasyczny algorytm grupowania po c średnich.

5. Wyniki

W analizie krótkoczasowej sygnałów pozyskanych z jednocyndrowego silnika badawczego rozważano 11 parametrów: prążki FFT od 1 do 5; średnią, momenty od 2 do 5 oraz medianę. Szerokość okna, w większości przypadków, była wybrana jako okres (lub pół okresu) trwania cyklu pracy silnika (4-suwowego).

Rys. 3 pokazuje przykład podprzestrzeni parametrów otrzymanej dla sygnału w przypadku wypadania zapłonu (wykrytymi poprzez porównanie z odpowiednim wykresem

For the locomotive engine an acceleration sensor was mounted into the engine body on cylinder 1. The measurements were performed through a TA11 16-channel digital recorder produced by GOLD which incorporates a 4395 piezoelectric sensor manufactured by Brüel & Kjaer, the acquisition program and analysis software. The measurements of the locomotive engine were taken in three engine speed values: 650-680 rev/min (idle run), 1100 rev/min and 1500 rev/min, in three measurement phases: all cylinders operative, cylinder 1 disconnected and cylinder 4 disconnected. The signal was registered in three channels, each channel representing a component in one of three directions: parallel to the main longitudinal locomotive axis, horizontal-transverse and vertical-transverse to the main longitudinal locomotive axis. The sampled frequency was 20 kHz.

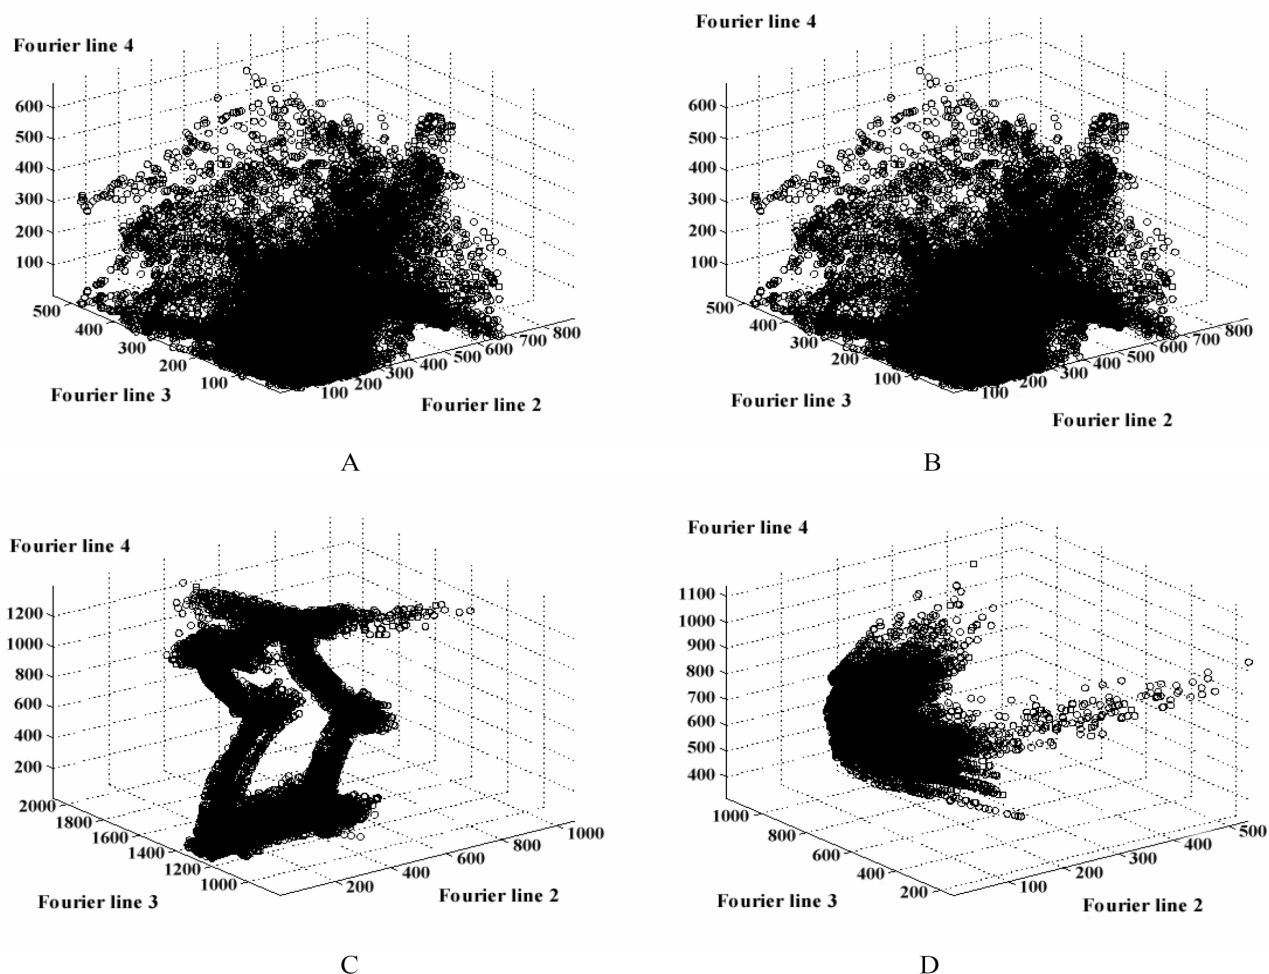
The obtained engine signals were processed through the MATLAB software. In clustering a classical c-means algorithm of clustering was used.

5. Results

In short-time analysis for signals taken from one-cylinder test engine eleven parameters were considered: FFT lines from 1 to 5; mean; moments from 2 to 5 and the median. The window width was chosen as time (or half time) of the engine cycle of work (four strokes).

Fig. 3 presents an example of a parameter subspaces obtained for signal with some misfire events (detected by comparison with pressure plots) for different window width. The choice of window width influences the object shape in the parameter space.

In turn, Fig. 4 presents the effect of clustering in the parameter space from the Fig. 3.



Rys. 3. Wynik rzutowania 11-wymiarowej przestrzeni parametrów na trójwymiarową podprzestrzeń (prążki Fouriera 1,2,3; sygnał przyspieszenia; oś Z; $M_0 = 0 \text{ N}\cdot\text{m}$, $n = 1700 \text{ obr/min}$; okres obrotu 420 próbek) dla okien o szerokości: A – 100 próbek; B – 210 próbek; C – 420 próbek; D – 840 próbek

Fig. 3. The projections of 11-dimensional parameter space into three dimensional subspace (Fourier lines 1,2,3; acceleration signal; axis Z; $M_0 = 0 \text{ N}\cdot\text{m}$, $n = 1700 \text{ rev/min}$; rotation period 420 samples) for the window width: A – 100 samples; B – 210 samples; C – 420 samples; D – 840 samples

ciśnienia) dla różnych szerokości okna. Okazuje się, że wybór szerokości okna znacząco wpływa na kształt uzyskanych obiektów w przestrzeni parametrów.

Rys. 4 pokazuje dalej efekt grupowania danych w przestrzeni parametrów dla przypadku z rys. 3.


Podczas analizy wzrokowej zobaczyć możemy jedynie rzutowanie 11 wymiarowej przestrzeni parametrów do najwyżej trójwymiarowej podprzestrzeni. To powoduje, że po przeprowadzeniu grupowania danych, grupy, które w jednej trójwymiarowej podprzestrzeni są dobrze rozróżnialne, mogą się okazać nie rozróżnialne w innej podprzestrzeni (patrz rys. 5).

It must be noted that we can observe only the projection of a full 11-dimension parameter space into the three dimensional subspaces.

This gives us a possibility that the clusters which are well distinguished in one subspace are quite undistinguishable in the other (see Fig. 5).

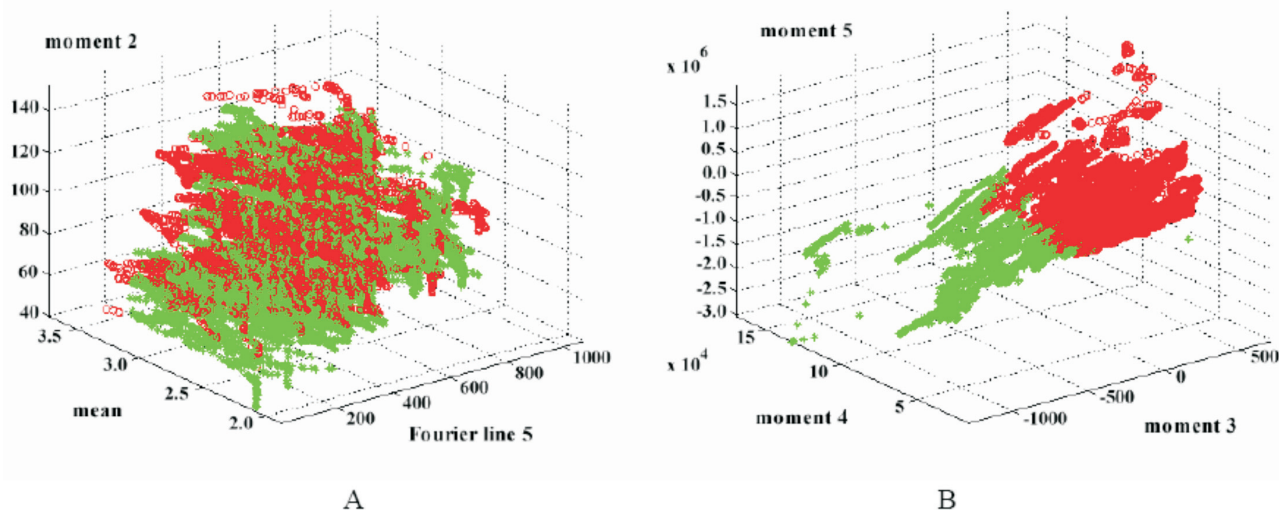
The analysis of locomotive signals was performed in two cases: for signals without preprocessing (the signals in the form obtained exclusively from a recording device) and for signals with preprocessing (by using FIR filter).

For signals taken from the locomotive en-



Rys. 4. Pogrupowana przestrzeń parametrów dla przypadku D z rys. 3

Fig. 4. The result clustering of the parameter space object for the case D of Fig. 3

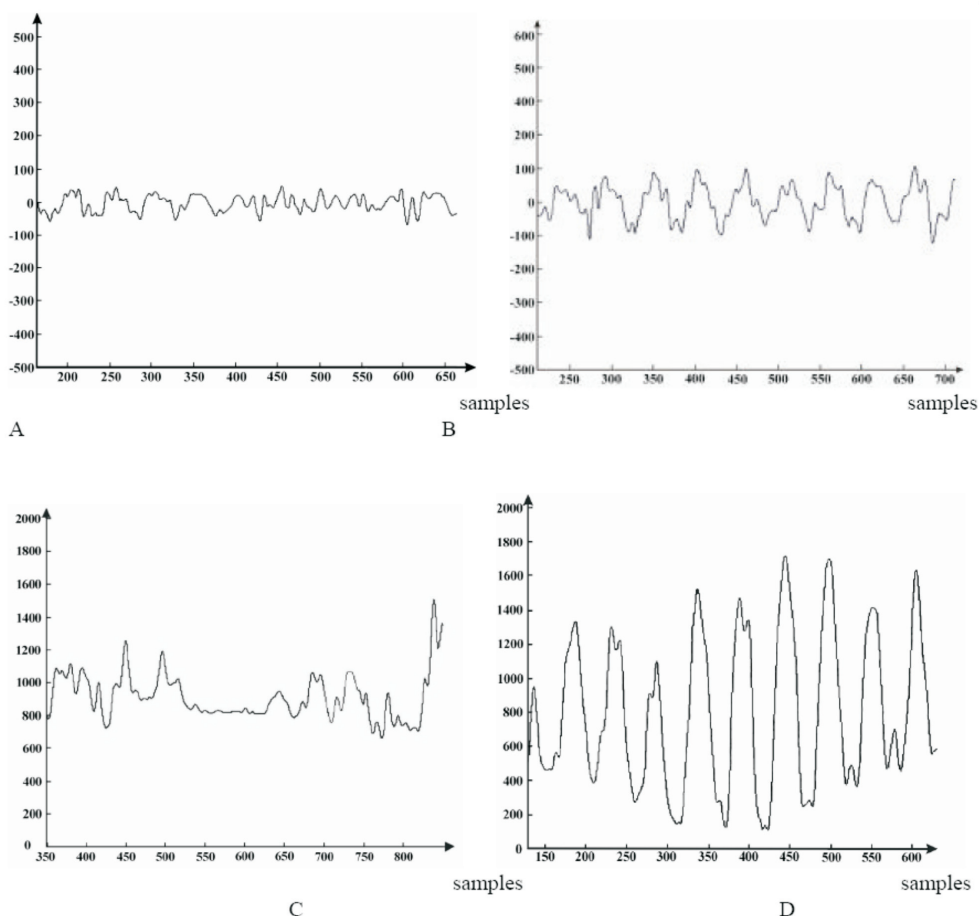


Rys. 5. Wynik grupowania danych 11-wymiarowej przestrzeni parametrów rzutowanej na trójwymiarową podprzestrzeń (oś Y; $M_0 = 0 \text{ N}\cdot\text{m}$, $n = 1700 \text{ obr/min}$; szerokość okna 420 próbek) dla współrzędnych: A – prążek Fouriera 5, średnia, moment 2; B – momenty 3, 4, 5

Fig. 5. The result of clustering of the 11-dimensionsl parameter space in projections into 3-dimensional spaces (axis Y; $M_0 = 0 \text{ N}\cdot\text{m}$, $n = 1700 \text{ rev/min}$; window width 420 samples) for coordinates: A – Fourier line 5, mean, moment 2; B – moments 3, 4, 5


Analiza sygnałów dla silnika lokomotywy została przeprowadzona dla dwóch przypadków: bez przetwarzania wstępnego (analizowano sygnały w postaci otrzymanej wprost z urządzenia rejestrującego) i z przetwarzaniem wstępnym (używając filtru FIR).

Dla silnika lokomotywy spalinyowej szerokość okna przyjęto jako 0,1 sekundy (2000 próbek) lub 0,01 sekundy (200 próbek). W każdym oknie obliczano siedem parametrów: prążki FFT od 2 do 6; wartość średnią i wariancję. Rys. 6 pokazuje fragmenty przykładowych wykresów oryginalnych sygnałów oraz odpowiadające im wykresy zmienności 3 prążka FFT. W odpowiedniej 7 wymiarową przestrzeni parametrów obliczono środki zbiorów punktów dla różnych stanów układu używając do tego celu klasyczny algorytm grupowania po c średnich. Obserwacja wizualna przestrzeni parametrów pozwala rozpoznać, że obiekty utworzone w przestrzeni



Rys. 6. Przykładowe fragmenty wykresów sygnałów 1500 obr/min dla przypadku prawidłowego (wszystkie cylindry pracują) (A) i nieprawidłowego (cylinder 1 odłączony) (B) oraz fragmenty wykresów drugiego prążka Fouriera uzyskanego w analizie krótkoczasowej – odpowiednio (C) i (D) (w oknie o szerokości 2000 próbek)

Fig. 6. Example fragments of plots of signals of 1500 rev/min for all cylinders operative (A), for cylinder 1 disconnected (B) and fragments of plots of their short-time Fourier spectrum (the second Fourier line) – (C) and (D) correspondingly (in the 2000 samples window)



Rys. 7. Ewolucja w 7-wymiarowej przestrzeni parametrów rzutowana na trójwymiarową (prążki Fouriera 2,3, 4) podprzestrzeń dla sygnału 1500 obr/min dla przypadku prawidłowego (wszystkie cylindry pracują) (A) oraz nieprawidłowego (cylinder 1 odłączony) (B) (w oknie o szerokości 200 próbek)

Fig. 7. Evolution in 7-dimensional parameter space in projection into three (Fourier line 2,3 and 4) dimensional subspaces for signals 1500 rev/min for all cylinders operative (A) and for cylinder 1 disconnected (B) (in the 200 samples window)

parametrów dla stanów prawidłowych i nieprawidłowych wykazują pewne zróżnicowanie (patrz rys. 7). Równocześnie obliczone wartości współrzędnych środków grup pokazują zdecydowane różnice pomiędzy stanami prawidłowymi i nieprawidłowymi.

Przeprowadzono również badania wstępne dla parametrów nieliniowych. Rys. 8 pokazuje przykładowe wykresy maksymalnych wykładników Lapunowa dla prawidłowych i nieprawidłowych sygnałów. Wykładniki Lapunowa pokazują interesujące zachowanie, ale z powodu dużej złożoności obliczeniowej nie zostały one użyte jako parametry rozważanej wielowymiarowej przestrzeni parametrów.

6. Wnioski

W pracy zastosowano analizę krótkoczasową dla diagnostyki wypadania zapłonu w silniku z zapłonem samoczynnym. Wybrane parametry obliczane były w oknie czasowym przesuwającym się wzdłuż sygnału, co dawało możliwość zaobserwowania ewolucji czasowej w wielowymiarowej przestrzeni parametrów. Następnie w przestrzeni parametrów stosowano techniki grupowania danych dla rozróżnienia różnych stanów silnika. Podstawowe wyniki oraz obserwacja wielowymiarowej przestrzeni parametrów okazały się obiecujące i interesujące. Ogólny widok przestrzeni parametrów pozwolił na rozróżnienie ścieżek ewolucji oknowej oraz przeprowadzenie grupowania danych.

Wypadanie zapłonu było symulowane poprzez stałe odłączenie zasilania jednego cylindra (silnik lokomotywy spalinowej) albo też występowało naturalnie w postaci pojedynczych przypadków (jednocyldrowy silnik badawczy). Dla stałego odłączenia zasilania (silnik lokomotywy spalinowej) analiza przestrzeni parametrów wskazuje na różne położenie grup odpowiadających stanowi prawidłowemu oraz z wypadaniem zapłonu. Dla naturalnego wypadania zapłonu (jednocyldrowy silnik badawczy) można zauważyć zazwyczaj masywne centrum oraz dodatkowe zewnętrzne fragmenty,

gdzie szerokość okna były brane jako 0.1 sekunda (2000 próbek) i 0.01 sekundy (200 próbek). W każdym oknie obliczono siedem parametrów: FFT linie od 2 do 6; średnią i wariancję. Fig. 6 przedstawia części niektórych przykładowych wykresów sygnałów i odpowiadających im wykresów drugiej linii FFT. W końcu, mając 7-wymiarową przestrzeń parametrów, obliczono współrzędne środków grup dla różnych stanów. W pierwszym podejściu klasyczny algorytm c-means clustering został użyty do znalezienia środków dla danych sygnałów.


Obiekty stworzone w przestrzeni parametrów dla prawidłowych i nieprawidłowych sygnałów wykazują pewne różnice (patrz rys. 7). Podobnie, obliczone wartości współrzędnych środków grup wykazują istotne różnice dla prawidłowych i nieprawidłowych sygnałów.

Some introductory tests were also performed with the use of nonlinear parameters. Fig. 8 presents some exemplary plots of dominant Lyapunov exponents for proper and improper signals. The nonlinear parameters like Lyapunov exponents show some interesting behavior but because of the high computational complexity of their calculations they were not used as the parameters of the considered parameter space.

6. Conclusions

In the paper the short-time analysis was performed for misfire diagnostic of a Diesel engine. The selected parameters were calculated for the time window sliding along the signal what created the multidimensional parameter space where one could observe the time evolution. Next the clustering techniques were performed to differentiate engine states in a parameter space. The main results and the observation of the multidimensional parameter space seem interesting and promising. The general look of the parameter space allows to distinguish the traces of window evolution.

Misfire was simulated by permanent disconnection of one cylinder (locomotive engine) or appeared naturally as



Rys. 8. Przykładowe fragmenty wykresów wartości maksymalnych wykładników Lapunowa w analizie krótkoczasowej (500 obr/min, okno czasowe 200 próbek, czujnik na cylindrze 1) dla sygnału prawidłowego (wszystkie cylindry pracują) bez filtracji (A) i odfiltrowane (B) oraz dla sygnału nieprawidłowego (cylinder 1 odłączony) bez filtracji (C) i odfiltrowany (D)

Fig. 8. Example fragments of plots of dominant Lyapunov values of exponent in short-time analysis (1500 rev/min, time window width 200 samples, sensor on 1 cylinder) for proper signal (all cylinders operative) without filtration (A) and filtrated (B) and for improper signal (cylinder 1 disconnected) without filtration (C) and filtrated (D)

które powinny odpowiadać nieprawidłowym fragmentom sygnału. Zastosowanie algorytmu grupowania danych pozwoliło na zaznaczanie odpowiednich grup.

Ponadto większość parametrów (w tym parametry nieliniowe) pokazały dużą zmienność wartości w przesuwającym się oknie i zmiany te okazały różne dla stanu normalnej pracy silnika oraz dla wypadania zapłonu.

Uzyskane wyniki i rezultaty udowodniły przydatność metody analizy krótkoczasowej z zastosowaniem grupowania danych w przestrzeni parametrów do diagnostyki wypadania zapłonów. Obecny etap badań stanowi pierwszy krok w budowie systemu diagnostyki chwilowej on-line silnika o zapłonie samoczynnym. Wobec perspektywy przeniesienia obligatoryjnych systemów diagnostyki pokładowej typu OBD na ciężkie silniki o zapłonie samoczynnym zaproponowana metoda diagnostyczna stanowi nową propozycję w tym zakresie.

Pełne opracowanie metody wymaga jednak szeregu dodatkowych badań. Zadanie badawcze okazało się bowiem bardzo złożone ze względu na wielką różnorodność możliwych schematów pomiarowych. Pod uwagę wzięto jedynie ograniczoną liczbę sygnałów oraz zastosowano ograniczoną liczbę parametrów obliczanych w oknie czasowym. Użycie większej liczby parametrów, a przede wszystkim, róż-

single cases (one-cylinder test engine). For permanent cylinder disconnection (locomotive engine) the analysis of parameter space shows the different position of clusters represent a proper state and a state of misfire. For natural misfire (one-cylinder test engine) one can find the massive center and some outside traces that should correspond to the improper behavior of signal fragments. The application of clustering algorithms allowed to label the given cluster.

Additionally the most of parameters (nonlinear parameters also) are showing the big values variance in sliding window and this changes are quite different for the state of engine normal work and for the misfire.

The obtained results showed the usefulness of short-time analysis with using clustering techniques in misfire diagnostic. The current research stage is a first step in building short-time on-line diagnostic system of a Diesel engine. Taking into account the perspective of carrying of obligatory on-board diagnostic systems OBD on heavy Diesel engines the proposed method create the new approach in this area.

The full study of the presented method needs some more researches. The measurement task showed us the great complexity and variety of possible measurement schemes. Only a limited number of signal examples have been utilized. Also, a limited number of window parameters have been used.

nych ich typów powinno zapewnić lepsze odróżnienie odrębnych stanów silnika w przestrzeni parametrów. W przyszłych eksperymentach trzeba więc użyć nowych rodzajów parametrów (przede wszystkim dołożyć parametry nieliniowe) i przestrzeni parametrów o wyższym wymiarze. Należy również oczekiwać, że zastosowanie innych algorytmów grupowania danych (algorytmy rozmyte oraz bazujące na metodach fizyki statystycznej) w znaczącym stopniu polepszy wyniki grupowania w przestrzeni parametrów.

Podziękowanie

Publikacja została wykonana w ramach pracy badawczej Nr 5 T12D 011 25 finansowanej przez Komitet Badań Naukowych w Polsce.

Artykuł recenzowany

The usage of larger number of parameters and different types of parameters will give us a better differentiation of clusters representing the different engine states. Hence, in the future experiments we should consider using new parameters (non-linear for example), and higher dimensional parameter spaces. We also expect the improvement of our results while applying some better clustering algorithms (fuzzy clustering algorithms and clustering algorithms based on the methods of statistical physics).

Acknowledgments

The paper was supported by the grant No 5 T12D 011 25 of KBN (state Committee for Scientific Research) in Poland.

Literatura/Bibliography

- [1] Abarbanel H. D. I.: Analysis of Observed Chaotic Data Springer, 1996.
- [2] Allen J. B., Rabiner L. R.: A Unified Approach to Short-Time Fourier Analysis and Synthesis, Proceedings of the IEEE 65, 1558-1564, 1977.
- [3] Allen J. B.: Short Term Spectral Analysis, Synthesis, and Modification by Discrete Fourier Transform, 1977 IEEE Transactions on Acoustic, Speech, and Signal Processing ASSP-25, 235-238, 1977.
- [4] Bezdek J. C.: Pattern Recognition with Fuzzy Objective Function Algorithms, Plenum Press (Second edition), 1987.
- [5] Boguś P., Massone A. M., Masulli F., Schenone A.: Interactive graphical system for segmentation of multimodal medical volumes using fuzzy clustering, Machine GRAPHICS & VISION 7, 1998, 781-791, 1998.
- [6] Boguś P., Merksiz J., Grzeszczyk R., Mazurek S.: Nonlinear Analysis of Combustion Engine Vibroacoustic Signals for Misfire Detection, SAE Technical Paper Series, 2003-01-0354.
- [7] Boguś P., Merksiz J., Waligórski M.: Short-time methods of signal processing in combustion engine diagnostic – OBDII/EOBD perspectives, Proceedings of 29th International Scientific Conference on Combustion Engines KONES 2003, September 14-17, Wisła, Poland, 31-37, 2003.
- [8] Boguś P., Lewandowska K.: Short-Time Signal Analysis Using Pattern Recognition Methods. Lecture Notes in Computer Science. Artificial Intelligence and Soft Computing – ICAISC 2004, Springer-Verlag, 550-555, 2004.
- [9] Boguś P., Merksiz J.: Misfire Detection of Locomotive Diesel Engine by Nonlinear Analysis, Mechanical Systems and Signal Processing, Vol. 19, Issue 4, pp. 881-899, 2005.
- [10] Boguś P., Merksiz J.: Short Time Analysis of Combustion Engine Vibroacoustic Signals with Using Pattern Recognition Techniques, SAE Technical Paper Series 2005-01-2529.
- [11] Chui C. K., Wavelets: A Mathematical Tool for Signal Processing, SIAM Society for Industrial and Applied Mathematics, 1997.
- [12] Duda R., Hart P.: Pattern Classification and Scene Analysis, Wiley Interscience, 1973.
- [13] Harris F. J.: On the Use of Windows for Harmonic Analysis with the Discrete Fourier Transform, Proceedings of the IEEE 66, 51-83, 1978.
- [14] Krishnapuram R., Keller J. M.: A Possibilistic Approach to Clustering, IEEE Transactions on Fuzzy Systems 1, 98-110, 1993.
- [15] Merksiz J., Boguś P., Grzeszczyk R.: Overview of engine misfire detection methods used in on-board diagnostics. Journal of KONES – Internal Combustion Engines 8, 326-341, 2001.
- [16] Merksiz J., Waligórski M., Boguś P., Grzeszczyk R.: Some Insights into Diesel Locomotives Misfires for the Application of an OBD System, Journal of KONES Internal Combustion Engines 9, 188-203, 2002.
- [17] Mitra S. K., Kaiser J.F. (eds.): Handbook for Digital Signal Processing, John Wiley & Sons, 1993.
- [18] Portnoff M. R.: Time-Frequency Representation of Digital Signals and Systems Based on Short-Time Fourier Analysis, IEEE Transactions on Acoustic, Speech, and Signal Processing ASSP-28, 55-69, 1980.
- [19] Rose K., Gurewitz E., Fox G. C.: A deterministic annealing approach to clustering. Pattern Recognition Letters 11, 589-594, 1990.

* Dr inż. Piotr Boguś – Adiunkt w Instytucie Pojazdów Szynowych w Poznaniu oraz w Katedrze Fizyki i Biofizyki Akademii Medycznej w Gdańsku.

Mr Piotr Boguś, PhD, MEng – Doctor in the Rail Vehicles Institute „TABOR” in Poznan and Department of Physics and Biophysics at Medical University of Gdansk.



Prof. dr hab. inż. Jerzy Merksiz – Profesor na Wydziale Maszyn Roboczych i Transportu Politechniki Poznańskiej.

Prof. Jerzy Merksiz DSc, MEng – Professor in the Faculty of Working Machines and Transportation at Poznan University of Technology.

