

## ESTIMATION OF POSSIBILITIES OF A MILITARY VEHICLE TYPE RECOGNITION ON THE BASIS OF GROUND VIBRATIONS INDEPENDENTLY UPON VEHICLE SPEED

Jerzy Jackowski, Marcin Wieczorek

Military University of Technology  
Faculty of Mechanical Engineering  
Gen. Sylwestra Kaliskego 2, 00-908 Warszawa, Poland  
tel.: +48 22 6839276  
e-mail: jjackowski@wme.wat.edu.pl, mwieczorek@wme.wat.edu.pl

### Abstract

*This work presents the results of the measurement of the seismic vibration generated by differentiated in respect of the vehicle weight and structure. The analysis of registered seismic signals was carried out on the basis of frequency representation. Based on the Student difference test, a series of parameters of determined spectral signal power densities were examined for their usefulness for a differentiating feature vector.*

*A process of qualifying a registered signal of a detected object to a proper class can be realized by various methods. Most often it is carried out on the basis of the object feature vector position against spaces separating it from the vectors of other objects in the multidimensional space of features.*

*Meeting the requirement of maximum classifier structure simplification, searching for the best separating plane was limited to the neuron network method based on the Rosenblatt perception education. Specification of measurement results indicates that there is a high probability of correct recognition of seismic signals generated by the wheeled and tracked vehicles motion. The method of signal classifying of ground vibrations indicated the possibility of the correct recognition of movement of tracklaying and vehicular vehicles with the probability close to 100% and with regard of distribution on "light" and "heavy with the probability close to 90%.*

**Keywords:** recognition of vehicles, seismic signals

## OCENA MOŻLIWOŚCI ROZPOZNAWANIA TYPU POJAZDU WOJSKOWEGO NA PODSTAWIE DRGAŃ PODŁOŻA NIEZALEŻNIE OD PRĘDKOŚCI JAZDY

### Streszczenie

*W pracy przedstawiono proces wskazania cech charakterystycznych sygnałów sejsmicznych, wywołanego przez zróżnicowane pod względem masy i konstrukcji pojazdy. Analizę zarejestrowanych sygnałów drgań podłoża przeprowadzono na podstawie reprezentacji częstotliwościowej. Bazując na teście różnic Studenta wykonano badania szeregu parametrów wyznaczonych widmowych gęstości mocy sygnałów pod kątem ich przydatności dla zbioru cech różnicujących. Proces zakwalifikowania zarejestrowanego sygnału badanego obiektu do odpowiedniej klasy może być realizowany różnymi metodami. Najczęściej przeprowadza się go na podstawie położenia zbioru cech obiektu względem powierzchni oddzielających go od zbiorów innych obiektów w wielowymiarowej przestrzeni cech. Wychodząc naprzeciw wymogowi maksymalnego uproszczenia struktury klasyfikatora, poszukiwanie najlepszej płaszczyzny rozdzielającej ograniczono do wykorzystania metody sieci neuronowej bazującej na uczeniu perceptronowym Rosenblatta. Zestawione wyniki obliczeń wskazują na wysokie prawdopodobieństwo poprawnego rozpoznania sygnałów sejsmicznych wywołanych przejazdem pojazdów kołowych i gąsienicowych. Metoda klasyfikowania sygnałów drgań podłoża wskazała na możliwość poprawnego rozpoznania ruchu pojazdów gąsienicowych i kołowych z prawdopodobieństwem bliskim 100% oraz z uwzględnieniem ich podziału na "lekkie" i "ciężkie" z prawdopodobieństwem bliskim 90%.*

**Słowa kluczowe:** rozpoznawanie pojazdów, sygnały sejsmiczne

## 1. Wstęp

W pracach [1,2], jako zbiór cech charakterystycznych oddziaływań pojazdu na otoczenie, potraktowano reprezentację częstotliwościową drgań wymuszonych przejazdem pojazdu. Zaproponowana tam metoda hierarchiczna oceny przydatności wybranych opisów sygnałów w procesie rozpoznawania pojazdów wskazała na możliwość posługiwania się rozkładami czasowo-częstotliwościowymi. Wykorzystanie rozkładów czasowo-częstotliwościowych, w porównaniu z klasyczną analizą widmową (w postaci dyskretnej transformaty Fouriera i gęstości widmowej mocy), pozwoliło na uzyskanie wysokiej wiarygodności wskazanej miary prawdopodobieństwa rozpoznania oddziaływań poszczególnych pojazdów. Istotnym jednak ograniczeniem wykorzystywania rozkładów czasowo-częstotliwościowych w procesie rozpoznawania pojazdu jest konieczność zastosowania układu, który przed uruchomieniem procesu klasyfikacji najpierw wskaże prędkość poruszającego się obiektu.

Mając na uwadze tę niedogodność, opracowano procedury rozpoznawania oferujące poprawne rozróżnienia niezależnie od prędkości pojazdów. Przy czym, biorąc pod uwagę militarne wykorzystanie informacji dotyczącej rozpoznanego pojazdu istotną staje się przede wszystkim informacja do jakiej grupy pojazdów (gąsienicowy czy kołowy; lekki czy ciężki) zaliczyć wykryty pojazd. Dlatego, przedstawione poniżej metody przetwarzania sygnałów drgań podłoża wywołanych przejazdem wybranych klas pojazdów mechanicznych ukierunkowane zostały na określenie zbioru cech charakterystycznych dla sygnałów odpowiadających rozpatrywanym grupom pojazdów, który w dalszej kolejności umożliwiłby ich efektywne rozpoznanie. Punktem wyjścia do opracowania metod przetwarzania sygnałów stało się więc z jednej strony uwypuklenie różnych typów informacji zawartych w rejestrowanych sygnałach i z drugiej – redukcja wymiaru wynikowego zbioru cech do niezbędnego minimum. Wyodrębnienie cech charakterystycznych stanowi podstawę podjęcia decyzji o przypisaniu sygnału do określonej kategorii, czyli jego klasyfikację i w efekcie rozpoznanie pojazdu. Podstawą do wyszczególnienia kategorii stały się następujące rozróżnienia (tabela 1):

- 1) wśród wszystkich pojazdów: pojazd gąsienicowy - pojazd kołowy (oznaczenie G-K),
- 2) wśród pojazdów gąsienicowych i kołowych: pojazd o małej masie - pojazd o dużej masie (oznaczenia odpowiednio: GMM-GDM, KMM-KDM).

Tab. 1a. Przyjęty podział badanych pojazdów kołowych  
Tab. 1a. Division of tested wheeled vehicles


	Tarpan	Star200	Star266 (bez ładunku)	Star266 (z ładunkiem)	Star 1142	Kraz255	Skot	Jelcz	Tatra
Masa całkowita pojazdu podczas badań; $m_c$ [kg]	2140	3870	7770	10670	10760	12760	16240	25620	23530
Podział ze względu na $m_c$	<b>KMM</b>	<b>KMM</b>	<b>KDM</b>	<b>KDM</b>	<b>KDM</b>	<b>KDM</b>	<b>KDM</b>	<b>KDM</b>	<b>KDM</b>

Tab. 1b. Przyjęty podział badanych pojazdów gąsienicowych  
Tab. 1a. Division of tested tracked vehicles

	BWP	Haubica	T72	PT91
Masa całkowita pojazdu; $m_c$ [kg]	13000	14500	40000	43300
Podział ze względu na $m_c$	<b>GMM</b>	<b>GMM</b>	<b>GDM</b>	<b>GDM</b>

## 2. Metoda badań

Na rysunku 2 pokazano schemat rozmieszczenia czujników pomiarowych drgań podłoża.




Rys. 1. Schemat rozmieszczenia czujników na odcinku pomiarowym  
Fig.1. Sensor location on the measurement section diagram

W celu zachowania pełnej powtarzalności warunków rejestracji wyników pomiarów, w układzie pomiarowym zastosowano barierę świetlną, która uruchamiała pomiar za każdym razem w tym samym miejscu toru ruchu obiektu badań. Każdy pomiar pięciokrotnie powtarzano. Wynikało to z potrzeby zgromadzenia większej bazy danych, albowiem przejazd tego samego pojazdu kołowego i gąsienicowego po tej samej drodze gruntowej, powodując zmiany stanu nawierzchni drogi, może jednocześnie powodować powstanie drgań gruntu o różniących się wartościach. Może to być spowodowane także przez nie dające się uniknąć, różnice w trasie przejazdu oraz sposobie pokonywania nierówności tych samych fragmentów drogi.

Bazę danych tworzył zbiór sygnałów pochodzących od 8 pojazdów kołowych i od 4 pojazdów gąsienicowych (tabela 1) zarejestrowanych poprzez dwa czujniki sejsmiczne przy dwóch prędkościach przejazdu.

Rysunek 2 ilustruje kolejne etapy występujące w przyjętym w badaniach procesie rozpoznawania pojazdów.

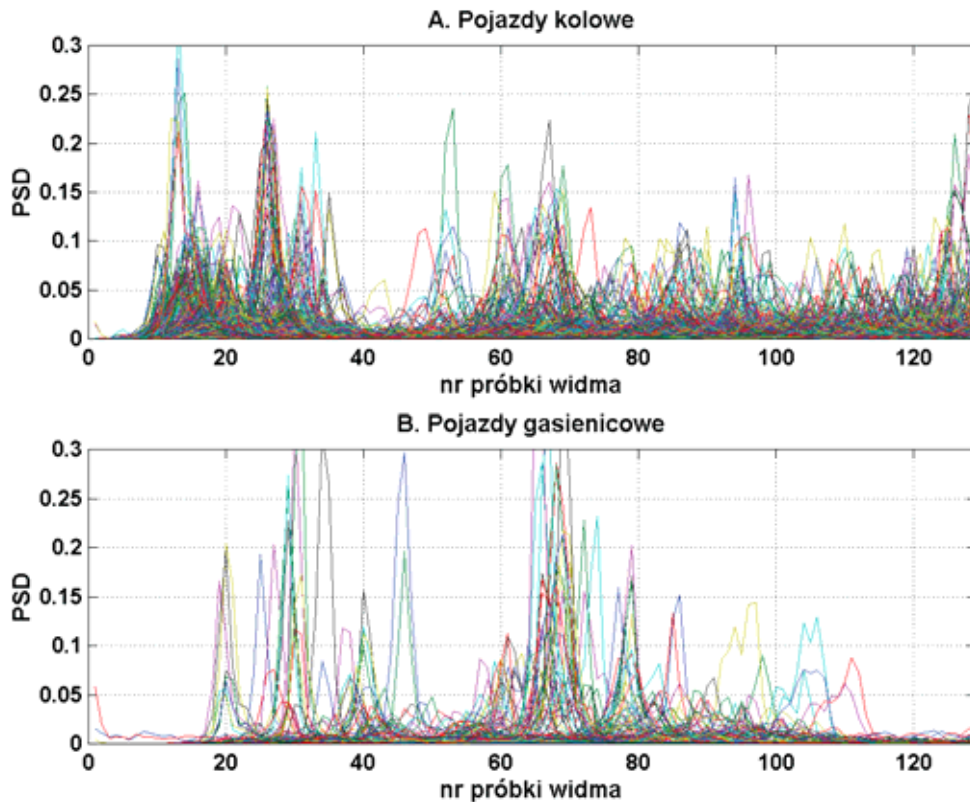


Rys.2. Struktura blokowa procesu rozpoznawania kategorii pojazdów na podstawie drgań podłoża  
Fig. 2. Classification of seismic signals generated by vehicle motion

Sygnaly zarejestrowane w terenie przez stanowisko pomiarowe poddane zostały wybranym algorytmom przetwarzania, generującym określone cechy. W ramach wstępnego przetwarzania

zmierzonych sygnałów w celu wskazania cech charakterystycznych uwagę skupiono na strukturze częstotliwościowej widmowej gęstości mocy PSD (rys.3).

Wymiary zaproponowanych zbiorów cech zostały następnie zredukowane celem uzyskania możliwie dużej zdolności uogólniania. Na podstawie uzyskanych tą drogą zbiorów klasyfikator dokonywał rozpoznania obiektów i przypisania ich do odpowiedniej kategorii.



Rys. 3. Przebiegi widmowych gęstości mocy sygnałów drgań podłoża wywołanych ruchem pojazdów kołowych i gąsienicowych

Fig. 3. Spectral ground vibration signals resulting from a motion of tested wheeled and tracked vehicles

### 3. Selekcja zbioru cech charakterystycznych

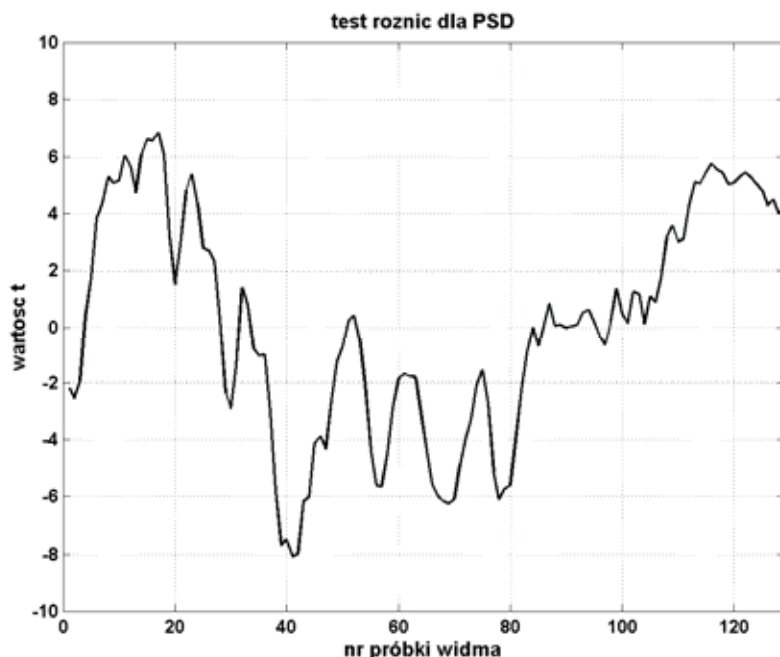
Celem sprawdzenia statystycznej istotności wpływu wyróżnionych klas pojazdów (np. gąsienicowych i kołowych) na wyznaczone cechy sygnałów, wykorzystano test różnic Studenta dla wartości średnich. W teście tym weryfikuje się hipotezę statystyczną o równości wartości średnich dwu normalnych populacji X i Y na podstawie prób o liczebnościach odpowiednio N1 i N2. Przy założeniu prawdziwości hipotezy wyznaczona na podstawie próby statystyka t:

$$t = \frac{\bar{X} - \bar{Y}}{\sqrt{\frac{N_1 s_1 + N_2 s_2}{N_1 + N_2 - 2} \left( \frac{1}{N_1} + \frac{1}{N_2} \right)}}, \quad (1)$$

gdzie: s1, s2 - wariancje z prób, podlega rozkładowi Studenta z liczbą stopni swobody  $v=N_1+N_2-2$ . Weryfikacji hipotezy dokonuje się porównując obliczony z próby moduł t z kwantylem rozkładu Studenta dla poziomu istotności  $\alpha$  oznaczonym  $t_{1-0.5\alpha}$ . Zażycie relacji:

$$|t| \geq t_{1-0.5\alpha} \quad (2)$$

oznacza, że prawdopodobieństwo przyjęcia przez statystykę (1) wartości uzyskanej z próby jest mniejsze lub równe od zakładanego poziomu istotności. Tym samym hipotezę o równości wartości średnich należy odrzucić. W niniejszej pracy wykorzystano omawiany test jako procedurę oceny skuteczności cechy. Odrzucenie hipotezy o równości wartości średnich rozpatrywanej cechy w populacjach wartości związanych z pojazdami kołowymi i gąsienicowymi wiązało się z zakwalifikowaniem jej jako potencjalnego kandydata do zbioru cech charakterystycznych.




Rys. 4. Przebiegi wartości statystyki  $t$  dla częstotliwości widmowej gęstości mocy  
 Fig. 4. Courses of the  $t$  statistics value for the frequency of spectral power density

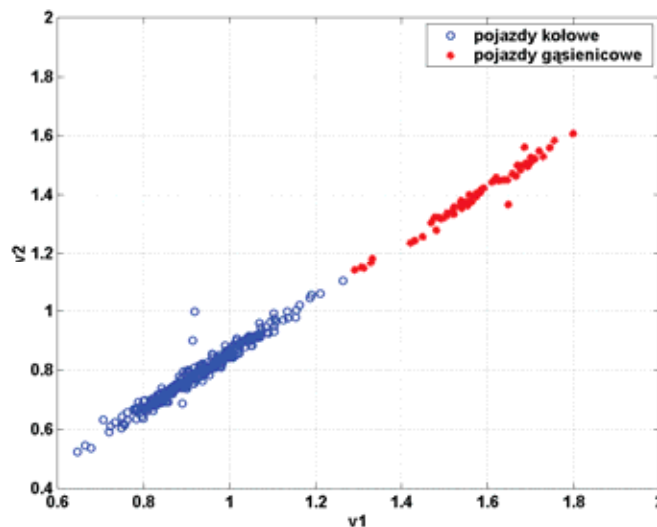
W ramach poszukiwania parametrów istotnych z punktu widzenia różnicowania dla każdej z odciętych na tych wykresach wykonano test różnic Studenta. Rysunek 4 przedstawia przykładowy przebieg statystyki  $t$  dla widmowej gęstości mocy. Wartość krytyczna (2) dla tego przebiegu wyniosła  $t_{1-0.5\alpha} = 1.964$ . Dla kolejnych numerów próbek widma, których statystyka testowa przekroczyła wartość krytyczną zastosowanej procedury selekcji cech utworzono zbiór cech charakterystycznych oddziaływania danego pojazdu.

#### 4. Redukcja wymiaru zbioru cech

Drugim standardowym, obok selekcji cech, zadaniem wyróżnionego na rysunku 2 bloku optymalizacji przestrzeni cech jest redukcja struktury danych wejściowych umożliwiającą uproszczenie algorytmu samego klasyfikatora. Jednymi z najbardziej rozpowszechnionych i jednocześnie skutecznymi metodami redukcji nadmiaru parametrów są metody transformacji pierwotnej przestrzeni w nową przestrzeń o własnościach spełniających wymagania określone zadanym kryterium (np. zachowania maksimum informacji różnicującej). W ramach niniejszej pracy posłużono się jedną z kilku istniejących metod (np. skalowanie wielowymiarowe Samona, grupa metod znanych pod ogólną nazwą Projection Pursuit) zwaną liniową analizą dyskryminacyjną LDA - ang. Linear Discriminant Analysis lub analizą dyskryminacyjną Fishera [4]. Ideę redukcji wymiaru danych pokazano na rysunku 5 a przykładowe rezultaty redukcji wymiaru zbioru cech charakterystycznych przebiegu PSD na rysunku 6.



Rys. 5. Ilustracja metody LDA dla przypadku dwu klas  
 Fig.5. Illustration of LDA method for a two class case



Rys. 6. Wizualizacja skuteczności dyskryminacji zbioru cech charakterystycznych z wykorzystaniem transformacji przestrzeni 129-wymiarowej do przestrzeni 2-wymiarowej za pomocą LDA  
 Fig. 6. Visualization of vector discrimination effectiveness using transformation of 129-dimensional space to 2-dimensional one by means of LDA

## 5. Wyznaczanie hiperpłaszczyzn rozdzielających – rozpoznanie kategorii poruszających się pojazdów

W procedurze wyznaczania położenia hiperpłaszczyzn rozdzielających obszary zbioru cech charakterystycznych dla poszczególnych kategorii pojazdów wykorzystano metodę sieci neuronowych bazującej na uczeniu perceptronowym Rosenblatta [3].

### 5.1. Rozpoznanie kategorii G-K

Baza danych wejściowych do przeprowadzenia badań objęła 360 sygnałów drgań podłoża wywołane ruchem pojazdów gąsienicowych (G) i 80 kołowych (K), przy czym podzielono je na zbiór uczący (80% ogółu danych) i zbiór testujący (20% ogółu danych).

W celu określenia efektywności procesu różnicowania posłużono się liczbą błędów testowania odniesioną do liczności zbioru danych testujących, przy czym w celu poprawnej i uczciwej oceny przypadków uzyskiwania małych błędów testowania przy jednocześnie wysokich błędach uczenia, te elementy zbioru uczącego, których klasyfikator nie był w stanie się „nauczyć” (poprawnie rozpoznać) włączono do zbioru danych testujących. Całkowity błąd różnicowania został więc określony przez:



$$\text{błąd całk.} = \frac{l_{bu} + l_{bt}}{l_{bu} + l_t} \cdot 100\%, \quad (3)$$

gdzie:  $l_{bu}$ ,  $l_{bt}$  – liczba błędów uczenia i testowania,  
 $l_t$  – liczba danych testujących.

Tab. 2. Skuteczność rozróżniania pojazdów gąsienicowych i kołowych (PG-PK)

Tab. 2. Effectiveness of wheeled and tracked vehicles differentiation

Struktura błędów	PG	PK
Liczba błędów uczenia	0	2
Liczba błędów testowania	0	0
<b>błąd całk., %</b>	<b>3</b>	

## 5.2. Rozpoznanie kategorii MM-DM

Celem tej części pracy stało się uzyskanie możliwości rozpoznania ruchu pojazdów odpowiednio gąsienicowych i kołowych z podziałem na dwie podgrupy różniące się ze względu na masę całkowitą.

Następnie, podobnie jak dla podziału G-K, wskazano wyselekcjonowany i zredukowany zbiór cech różnicujących sygnały drgań podłoża wywołanych przez pojazdy gąsienicowe o dużej i małej masie (GMM i GDM) i przez pojazdy kołowe (KMM i KDM). Zbiory te poddano procesowi uczenia oraz testowania z wykorzystaniem neuronowej metody wyznaczania hiperpłaszczyzn rozdzielających. Wyniki skuteczności rozróżniania pojazdów za pomocą tej metody zestawiono w tabeli 3.

Tab. 3. Skuteczność rozróżniania pojazdów gąsienicowych i kołowych o małej i dużej masie

Tab. 3. Effectiveness of wheeled and tracked vehicles differentiation

Struktura błędów	Pojazdy gąsienicowe		Pojazdy kołowe	
	GMM	GDM	KMM	KDM
Liczba błędów uczenia	0	2	4	2
Liczba błędów testowania	0	0	1	1
<b>błąd całk.</b>	<b>11</b>		<b>11</b>	
<b>%</b>				

## 6. Wnioski

Przeprowadzone badania zmierzały do wypracowania metod przetwarzania oferujących poprawne wyniki rozpoznania niezależnie od prędkości przejazdu obiektu oraz jego odległości od czujnika pomiarowego. Zaproponowana metoda klasyfikowania sygnałów drgań podłoża (na podstawie cech charakterystycznych struktury częstotliwościowej sygnałów drgań podłoża) z wykorzystaniem sieci neuronowej wskazała na możliwość poprawnego rozpoznania ruchu pojazdów gąsienicowych i kołowych z prawdopodobieństwem bliskim 100% oraz z uwzględnieniem ich podziału na „lekkie” i „ciężkie” z prawdopodobieństwem bliskim 90%.

## Literatura

- [1] Jackowski, J., Prochowski, L., Wieczorek, M., *Using several features of ground vibration during vehicle recognition process*, Biuletyn WAT, vol. LII, nr 08-09, pp. 151-160, 2003.

- [2] Jackowski, J., Wieczorek, M., *Classification of acoustic signals generated by military vehicle motion*, Mechanika, tom 23, zeszyt 2, AGH, Kraków, 2004.
- [3] Kwiatkowski, W., *Metody automatycznego rozpoznawania wzorców*, Wyd. Instytut Automatyki i Robotyki Wydziału Cybernetyki Wojskowej Akademii Technicznej, Warszawa, 2001.
- [4] Dobosz, M., *Wspomagana komputerowo statystyczna analiza wyników badań*, Akademicka Oficyna Wydawnicza EXIT, Warszawa 2001.

*Praca naukowa finansowana ze środków na naukę w latach 2005-2008 jako projekt badawczy.*