

*selekcja cech, procedura diagnozowania,  
przekładnie zębate wielostopniowe*

Walter BARTELMUS\*, Radosław ZIMROZ\*

## **IDENTYFIKACJA OPTYMALNYCH CECH DIAGNOSTYCZNYCH WIELOSTOPNIOWYCH PRZEKŁADNI ZĘBATYCH**

Równoczesne występowanie wielu uszkodzeń przekładni i możliwości ich identyfikacji na podstawie symptomów drganiowych nie są przedmiotem opracowań literaturowych. Autorzy w większości prac skupiają się na identyfikacji pojedynczych uszkodzeń na podstawie jednego symptomu. Referat przedstawia badania nad doбором optymalnych cech diagnostycznych w warunkach wzrastającej degradacji przekładni i związanej z tym wzrastającej liczbie uszkodzeń. Przedstawia również problem doboru punktu odbioru sygnału. W wyniku odbioru sygnału z wielu punktów otrzymuje się wielowymiarową macierz, z której należy wybrać punkt, dla którego uzyskuje się najlepszą rozdzielczość symptomów przypisanych określonym uszkodzeniom. Zagadnienia te sprowadzają się do odpowiedzi na następujące pytania: jakie symptomy dają lepsze wyniki klasyfikacji różnych uszkodzeń, w jakim punkcie odbioru sygnału separacja klas stanu technicznego dobry/zły jest największa oraz czy możliwa jest redukcja macierzy symptomów?

### 1. WPROWADZENIE

Diagnozowania złożonych obiektów, jakim są wielostopniowe przekładnie zębate jest procesem skomplikowanym. Możliwość występowania zmiany stanu technicznego związana jest z konkretnymi elementami (uszkodzenie/zużycie łożysk czy zazębień, zukosowanie wałów itp.), często występującymi równolegle (Bartelmus, 1991, 1992, 1998, 2000, 2001a-b, 2002a-b, 2003, 2004; Zimroz, 2002) co powoduje konieczność analizowania wielu danych będących wynikiem kilku analiz sygnałów.

W takim przypadku mówimy o wielowymiarowej przestrzeni cech stanu. Przetwarzanie danych wielowymiarowych jest ze względu na brak możliwości wizualizacji zagadnieniem trudnym często również złożonym obliczeniowo. Ogólną tendencją jest możliwie największa redukcja wymiaru danych. Odpowiednie przygotowanie danych jest zadaniem kluczowym (Han, 2000; Pyle, 1999; Ciupke, 2001; Kurzyński, 1997; Bartkowiak, 2003; Korbicz, 2002; Gibiec, 2004).

---

\* Instytut Górnictwa Politechniki Wrocławskiej, pl. Teatralny 2, 50-051 Wrocław,  
e-mail: walter.bartelmus@pwr.wroc.pl


Powstają zatem pytania:

- ile i jakie parametry należy uwzględnić (testowanie redundancji),
- które z parametrów lepiej separują klasy – te należałoby wybrać,
- które z punktów pomiarowych są bardziej informacyjne,
- jaki jest związek pomiędzy cechami i różnymi typami uszkodzeń oraz różnymi ich lokalizacjami (stopnie, wały, łożyska...),
- jak porównywać różne zestawy danych w celu oceny ich przydatności w diagnostyce.

W referacie przeanalizowano cechy wyznaczone z sygnałów drganiowych zarejestrowanych w czasie normalnej eksploatacji przekładni zębatach pracujących w systemach transportu przenośnikowego w kopalni węgla brunatnego.

## 2. REJESTRACJA SYGNAŁÓW DRGANIOWYCH

Sygnały zarejestrowano dla wskazanych przez personel techniczny przekładni w różnym stanie technicznym pracujących w systemach transportu przenośnikowego w czasie ich normalnej eksploatacji. Do rejestracji sygnałów wykorzystano sprzęt pomiarowy firmy Bruel Kjaer. Sygnały zarejestrowano w 5 punktach pomiarowych – rys. 1. Więcej informacji o sposobie realizacji pomiarów można znaleźć w pracach (Bartelmus 1992).



Rys. 1. Analizowana przekładnia – widok ogólny i schemat rozmieszczenia punktów pomiarowych  
Fig. 1. Analysed gearbox – view and scheme of data acquisition points

## 3. EKSTRAKCJA CECH

Problem wyboru cech jest w literaturze szeroko opisywany np. w pracach (Adamczyk, 1999; Zimroz, 2002; Bartelmus, 2003; Bartkowiak, 2004). Zwykle jednak prace dotyczą poszukiwania optymalnych rozwiązań w celu wykrywania konkretnej formy uszkodzenia lub zużycia.

Mamy tu do czynienia z parametrami w dziedzinie czasu i częstotliwości. Powszechnie znane metody to estymatory punktowe, metody widmowe, cepstrum, statystyki wyższych rzędów (polyspectra) i analizy czasowo-częstotliwościowe. Niestety w większości przypadków metody te są dedykowane konkretnym uszkodzeniom tzn. są wrażliwe na pojawienie się konkretnego typu zmiany stanu – wykrycie innych jest niemożliwe. Próby diagnozowania przekładni jako systemu podejmowane były wcześniej przez (Bartelmus, 1992).

W pracach (Bartelmus i Zimroz, 2002-2003) wykazano, że możliwe jest określenie kompleksowe stanu technicznego przekładni dwustopniowej z wykorzystaniem trzech metod przetwarzania sygnału - widma, cepstrum i mapy czasowo-częstotliwościowej.

### 3.1. PARAMETRY W DZIEDZINIE CZASU

Dla analizowanych danych przeprowadzono badania według procedury podanej przez (Liao, 2004). Podobny eksperyment - dla skrzyń biegów w samochodach marki Skoda - ale dla mniejszej liczby parametrów opisano w pracy (Vecer, 2003). Interesujące rezultaty tych prac skłoniły autorów do ponownego sprawdzenia takich cech dla analizowanych przekładni.


Na podstawie doświadczeń w diagnozowaniu przekładni i analizy literaturowej wydaje się bowiem, że proponowane parametry w dziedzinie czasu nie są odpowiednie. W celu sprawdzenia faktycznego wymiaru danych wykorzystano metodę PCA (ang. *Principal Component Analysis*), podczas której okazało się że ponad 90% informacji zawarte jest w dwóch współrzędnych w nowym układzie współrzędnych. Oznacza to wysoka redundancje.

W praktyce w szczególnych przypadkach możliwe jest rozróżnienie stanu technicznego dla wybranych uszkodzeń w zaawansowanych stadiach. Mało prawdopodobne jest zastosowanie ww. parametrów do wykrywania wczesnych stadiów uszkodzeń czy rozróżniania form niesprawności.


Na rysunkach 2 a-d pokazano przebiegi czasowe i histogramy dla przekładni 1 (zły/nieodpowiedni stan techniczny) i przekładni 4 (dobry stan techniczny). Pomiaru dokonano w punkcie pomiarowym nr1. Przykład dobrano tak, aby maksymalizować różnice pomiędzy stanami. Ocena na podstawie pewnych statystyk takich procesów jest możliwa.

Na rysunku 3 przedstawiono przebiegi czasowe i histogramy dla przekładni 1 (zły stan techniczny – zużycie ząbienia stopnia) i przekładni 5 (zły stan techniczny – uszkodzenie lokalne ząbienia stopnia 2). Pomiarów dokonano dla punktu 2.

Rozkłady amplitud są zbliżone, zatem diagnozowanie na podstawie statystyk takich procesów może być bardzo trudne.



Rys. 2. Przebiegi czasowe i histogramy dla przekładni 1 i 4  
Fig. 2. Time series and histograms for gearbox 1 and 4




Rys. 3. Przebiegi czasowe i histogramy dla przekładni 1 i 5  
Fig. 3. Time series and histograms for gearbox 1 and 5

### 3. 2. PARAMETRY W DZIEDZINIE CZĘSTOTLIWOŚCI

Wykorzystywanie cech diagnostycznych pozyskanych w dziedzinie częstotliwości jest ze względu na łatwość ich pozyskiwania i interpretacje fizyczną powszechnie stosowane w praktyce (rys. 4.). W pracy (Bartelmus, 2003) jako zestaw cech wykorzystano:

- sumę amplitud pięciu prążków o częstotliwości zazębienia stopnia 1 „A1”,
- sumę amplitud pięciu prążków o częstotliwości zazębienia stopnia drugiego „A2”,
- sumę amplitud 3 prążków o częstotliwości odpowiadającej obrotom wału 1 „S1”,
- sumę amplitud 3 prążków o częstotliwości odpowiadającej obrotom wału 2 „S1”,
- sumę amplitud 3 prążków w cepstrum odpowiadającym obrotom wału 1 „C1”,
- sumę amplitud 3 prążków w cepstrum odpowiadającym obrotom wału 2 „C2”,
- zmienną logiczną  $\{1,0\}$  będącą wynikiem procedury analizującej mapę czasowo-częstotliwościową w celu detekcji okresowych szerokopasmowych zaburzeń „TF1” „TF2”.



Rys. 4. Widma i cepstra sygnałów dla przekładni w nieprawidłowym i dobrym stanie technicznym  
Fig. 4. Spectra and cepstra for vibration signals from gear in bad and good condition

Tak przygotowany zestaw danych (rys. 5.) wykorzystano do trenowania sieci neuronowej i uzyskano zadowalające rezultaty - 100% skuteczności rozpoznawania.

	A1	A2	C1	C2	S1	S2	TF1	TF2	Targ
case 1									
case 2									
.									
case N									

Rys. 5. Macierz cech diagnostycznych  
Fig. 5. Matrix of diagnostic data

W niniejszej pracy jako wektor danych wykorzystano amplitudy prążków o częstotliwościach zazębienia i wałów a także amplitudy prążków z cepstrum. Rozpatrzono dwa warianty:

wariant 1:

- amplitudy pięciu prążków o częstotliwości zazębienia stopnia pierwszego „A1”,
- amplitudy pięciu prążków o częstotliwości zazębienia stopnia drugiego „A2”,
- sumę amplitud trzech prążków o częstotliwości odpowiadającej obrotom wału wejściowego „S1”,
- amplitudy 3 prążków o częstotliwości odpowiadającej obrotom wału drugiego „S1”,
- amplitudy trzech prążków w cepstrum odpowiadającym obrotom wału wejściowego „C1”,
- amplitudy 3 prążków w cepstrum odpowiadającym obrotom wału drugiego „C2”;

wariant 2:

- sumy odpowiednich prążków jak w pracy (Bartelmus, 2003).


W ramach niniejszego eksperymentu zrezygnowano z analizy czasowo-częstotliwościowej ze względu na skomplikowany charakter obliczeń i procedury wyznaczania cech. Autorzy zdają sobie sprawę z zalet analizy czasowo-częstotliwościowej. Prace nad usprawnieniem pozyskiwania cech z mapy czas-częstotliwość będą kontynuowane.

#### 4. SELEKCJA CECH

Rozważono trzy przypadki: wariant 1 i 2 –cechy wyznaczone w dziedzinie częstotliwości – odpowiednio- amplitudy wybranych prążków i sumy amplitud (cechy skumulowane) oraz wariant 3 - cechy wyznaczone w dziedzinie czasu.

Dla wariantu 1 uzyskano macierz symptomów o wymiarze Nx22. Wykorzystując analizę PCA zidentyfikowano dużą redundancję w tak przygotowanym zestawie danych. Uzasadnienie takiego stanu rzeczy nie jest trudne – wydaje się oczywiste, że np.: cechy 1:5, czyli amplitudy składowych o częstotliwościach zazębienia dla stopnia 1 są skorelowane – wzrost zużycia powoduje wzrost tych składowych.

Zdecydowano zredukować wymiar danych przez kumulację informacji poprzez proste sumowanie odpowiednich składowych - wariant 2. Zauważono wyraźny spadek redundancji - porównaj rys. 6a i b.



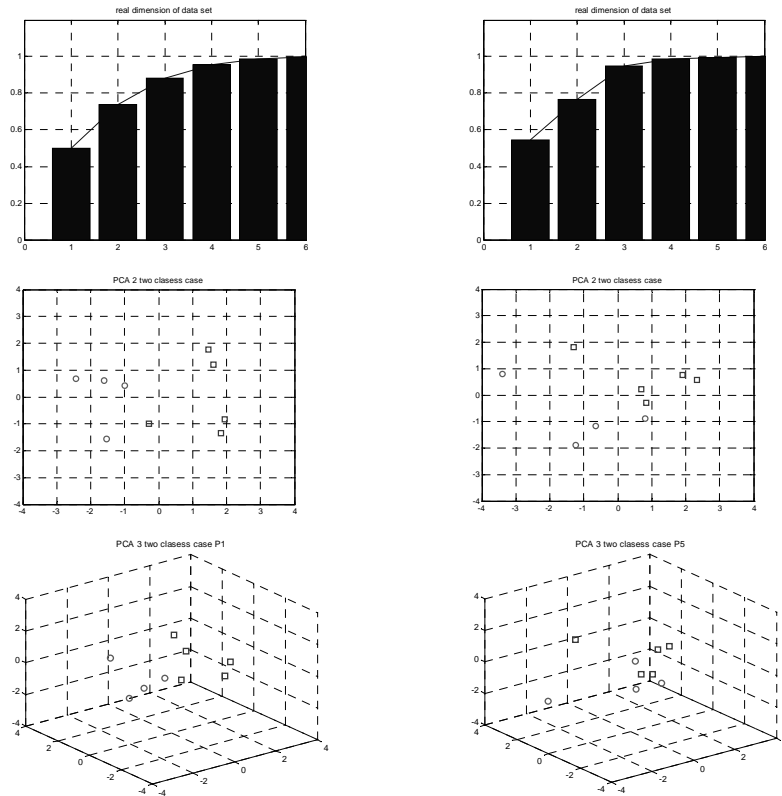
Rys. 6. Wyniki analizy PCA dla danych o wymiarze  $N=22$  i  $N=6$   
Fig.6. Results for PCA for data dimension  $N=22$  and  $N=6$

Przeanalizowano dane dla punktów 1, 2, 4, 5 dla amplitud i sum amplitud (cechy skumulowane).

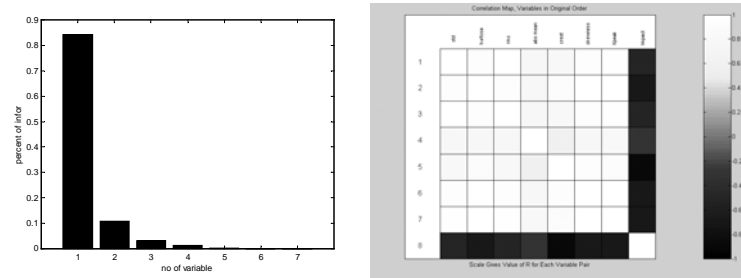
W przypadku, kiedy już dla 3 nowych zmiennych po transformacji PCA udział informacji jest na poziomie 90% uzasadniona jest wizualizacja danych. Dla przykładu przedstawiono wizualizacje dla punktów 1 i 5. Na rysunkach 7b,c i 7e,f pokazano zbiory danych wykreślone dla odpowiednio 2 i 3 najbardziej znaczących współrzędnych po transformacji PCA zawierające odpowiednio 73% oraz 88% dla punktu 1 i 76% i 94% dla punktu 5.

Na podstawie wyników analizy PCA dla amplitud i sum amplitud (cechy skumulowane) stwierdzono większą przydatność cech skumulowanych. W dalszej części pracy rozważano tylko wariant 2 i 3.

Na rys. 8a pokazano rozkład informacji dla danych w dziedzinie czasu po transformacji PCA. Z rysunku wynika, że ponad 80% informacji zawiera się w pierwszej zmiennej a dwie pierwsze zmienne stanowią ponad 95% informacji. Oznacza to wysoką redundancję. Na rysunku 8b pokazano mapę korelacji określającą stopień współzależności danych. Jasny kolor oznacza dużą, pozytywną korelację ciemny korelację ujemną – a pośrednie odcienie – brak korelacji. Z rysunku wynika, że występuje silna korelacja dla wszystkich zmiennych za wyjątkiem ostatniej - cecha „impact”. Potwierdza to wcześniejsze wnioski o nieprzydatności takiego zestawu danych.



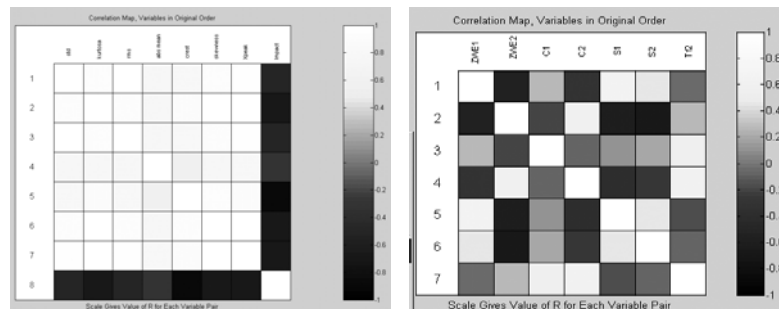
Rys. 7. Wynik PCA oraz wizualizacje (N=2 i N=3) danych dla punktów 1 i 5  
 Fig. 7. Results for PCA and data visualization (N=2 and N=3) for point 1 and 5




Rys.8 Zawartość informacji dla danych w dziedzinie czasu po transformacji PCA.  
 Mapa korelacji dla danych oryginalnych  
 Fig 8 Distribution of information for data in time domain after PCA. Correlation map original data

Na rysunku 9 przedstawiono mapy korelacji dla dwóch różnych zestawów danych: dla parametrów w dziedzinie czasu i parametrów w dziedzinie częstotliwości. Porównanie mapy korelacji daje jednoznaczną odpowiedź na pytanie, który zestaw danych jest lepszy.

Na rysunku 10 pokazano wyniki transformacji PCA dla wyżej wymienionych zestawów danych. Na podstawie rysunku 10b zauważyć można również pewną redundancję dla zestawu danych nr 2 jednak jest to znacznie mniejsza wartość niż w przypadku zestawu danych nr 1.



Rys.9. Mapa korelacji dla danych oryginalnych - dane z dziedziny czasu i częstotliwości  
Fig. 9. Correlation map original data - data from time and frequency domain



Rys.10 Zawartość informacji po transformacji PCA - dane z dziedziny czasu i częstotliwości  
Fig. 10 Distribution of information for data after PCA - data fro time and frequency domain

## 5. OCENA SELEKCJI

Jako kryteria oceny selekcji danych przyjęto parametry zaproponowane w pracy (Malina, 1985), czyli:

- rozproszenie zewnętrzne (międzyklasowe),
  - rozproszenia wewnętrzne dla klasy A i B,
  - kombinacje rozprośnień: zewnętrznego i średniego rozproszenia wewnętrznego.
- Rozważmy  $N$  wymiarową przestrzeń z 2 zbiorami reprezentującymi dwa stany techniczne (dobry/zły).

Średnia odległość między klasami  $K_i$  i  $K_j$  (rozproszenie zewnętrzne) wynosi:



$$D(i, j) = \frac{1}{m_i m_j} \sum_{l=1}^{m_i} \sum_{t=1}^{m_j} \text{Dist}(x_l, x_t)$$

(1)

gdzie:  $m_i, m_j$  oznaczają liczbę elementów zbiorów reprezentujących powyższe klasy, a  $\text{Dist}(x_i, x_j)$  odległość między punktami  $x_i, x_j$ .

W analizie wielowymiarowych danych przydatna jest informacja o rozproszeniu względem kolejnych zmiennych.

Rozproszenie między parą klas wzdłuż  $k$ -tej współrzędnej zdefiniowano następująco:

$$D_k(i, j) = \frac{1}{m_i m_j} \sum_{l=1}^{m_i} \sum_{t=1}^{m_j} \text{Dist}(x_{ki}, x_{kj})$$

(2)

Średnie rozproszenie wewnętrzne klas wynosi:

$$\bar{d} = \frac{1}{L} \sum_{i=1}^L D(i, i)$$

(3)

Do oceny jakości całego zbioru  $N$  cech w pracy (Malina, 1985) zaproponowano zależność:


$$G(N) = \bar{D} - c\bar{d}$$

(4)

gdzie  $c$  współczynnik regulujący proporcje pomiędzy rozproszeniami wewnętrznymi i zewnętrznymi  $c \geq 0$  (tu  $c=0$ ).


Powyższe zależności w postaci procedury zapisano w środowisku Matlab. W celu przetestowania skuteczności w/w miar wygenerowano zestawy syntetycznych danych w przestrzeni  $R^3$ . Jeden ze zbiorów – symulujący dobry stan techniczny – charakteryzuje się małym rozproszeniem wewnętrznym, drugi – symulujący nieprawidłowy stan techniczny – charakteryzuje się dwukrotnie większym rozproszeniem.

Rozważono dwa przypadki polegające na bliskim i dalekim rozmieszczeniu środków klas. Wyniki przedstawiono na rysunku 11.



Rozproszenie zewnętrzne (external):	2.2097	4.6176
Rozproszenie wewnętrzne(internalA):	0.3275	0.3355
Rozproszenie wewnętrzne (internalB):	0.6595	0.6639
Uśrednione rozproszenie wzdłuż k-tej współ. (R_dim):	1.2477	2.2369

Rys. 11. Syntetyczne dane do testowania przydatności parametrów opisujących jakość zbiorów  
 Fig. 11. Synthetic data for testing of parameters used for data sets quality estimation



Rys. 12. Wyniki procedury oceny przydatności zbiorów danych z 4 punktów  
 Fig. 12. Results of estimation of quality of data sets for data from 4 points

Następnie poddano analizie zestawy cech dla czterech punktów pomiarowych. Jest oczywiste, że aby maksymalizować skuteczność diagnozy należy poszukiwać zbiorów cech dla stanu dobry/zły, które są od siebie maksymalnie oddalone. Dodatkowo pożądane jest jak najmniejsze rozproszenie wewnętrzne klas.

Na rysunku 12 przedstawiono wyniki dla 4 zestawów danych. Jak wynika z tego rysunku najbardziej odseparowane klasy występują dla punktów 1 i 4. Rozproszenie wewnętrzne dla klasy „dobry stan techniczny” jest znacznie mniejsze niż dla klasy „nieprawidłowy stan techniczny”. Miarą kompleksowej oceny danych jest parametr oznaczony na wykresie „D-d”. Jak wynika z wykresu zestaw danych dla punktu 1 i 4 wykazuje podobne właściwości.

## 6. WNIOSKI

Dobór cech diagnostycznych w diagnostyce zorientowanej uszkodzeniowo przy założeniu możliwości jednoczesnego występowania wielu uszkodzeń jest zagadnieniem niezwykle ważnym, ale i skomplikowanym. W pracy zaproponowano metodę oceny zestawów cech dla różnych punktów pomiarowych. Wykazano przy użyciu techniki PCA silną redundancję dla zestawu danych opartych na statystykach procesu wyznaczonych w dziedzinie czasu.

Zwiększanie wymiaru danych poprzez uwzględnienie poszczególnych amplitud zamiast ich sum nie przyniosło zadowalających rezultatów.

Autorzy zauważają konieczność prowadzenia dalszych badań ze szczególnym uwzględnieniem zwiększenia liczby analizowanych przypadków (więcej sygnałów diagnostycznych). Celowe wydaje się wykorzystanie dodatkowych cech wyznaczonych na podstawie analiz czasowo-częstotliwościowych czy statystyk wyższych rzędów.

## LITERATURA

- ADAMCZYK J., CIOCH W., KRZYWORZEKA P., *Możliwości neuronowej klasyfikacji stanu w zmiennych warunkach pracy obiektu*, Zagadnienia Eksploatacji Maszyn 2 (118), 1999
- BARTELMUS W., *Diagnostyka przekładni zębatych*, Górnictwo Odkrywkowe 1991, nr 2, s 1-44
- BARTELMUS W., *Vibration Condition Monitoring of Gearboxes*, Machine Vibration, Springer –Verlag London Limited, pp 178-189, 1992
- BARTELMUS W., *Diagnostyka Maszyn Górniczych*, Górnictwo Odkrywkowe, Wyd. Śląsk, 1998
- BARTELMUS W., *Mathematical modeling of gearboxes vibration for fault diagnosis*, International Journal of Comadem, 2000, 3(3), pp5-15
- BARTELMUS W., *Mathematical Modelling and Computer Simulations as an Aid to Gearbox Diagnostics*, Mechanical Systems and Signal Processing, 2001a, Vol.15, nr5, s. 855-871
- BARTELMUS W., ZIMROZ R., *Vibration Condition Monitoring of two stage gearboxes*, 4th Intern. Conf. Acoustical and Vibratory Surveillance Methods and Diagnostics Techniques, France 2001b, s.645
- BARTELMUS W., *Computer aided multistage gearbox diagnostic inference by computer simulation*, Scientific papers of the Institute of Mining of the Wrocław University of Technology 2002a
- BARTELMUS W., ZIMROZ R., *Condition Monitoring of Belt Conveyor Transmissions*, Mine Planning And Equipment Selection 2002. Proc. of 12th Internat Symposium. Czech Rep, 2002b, s.393 – 402
- BARTELMUS W., ZIMROZ R., BATRA H., *Gearbox vibration signal pre-processing and input values choice for neural network training* AIMETH, 2003
- BARTELMUS W., ZIMROZ R., *Application of self-organised networks for supporting condition evaluation of gearboxes* AIMETH, 2004
- BARTKOWIAK A., CEBRAT S., MACKIEWICZ P., *Probabilistic PCA and neural networks in search of representative features fr some yeast genome data*, AIMETH, 2004
- CIUPKE K., *Attributes selection in machinery diagnostics*, AI-Meth Methods of Artificial Intelligence in Mechanics and Mechanical Engineering Gliwice 2001, Poland
- GIBIEC M., UHL T., *Zastosowanie technik Datamining w diagnostyce*, Mech i Autom. Górnictwa, 2004, nr 9
- HAN J., KAMBER M., *Data Mining: Concepts and Techniques* Morgan Kaufman Publishers, 2000

- KORBICZ J., KOSCIELNY J., KOWALCZUK Z., CHOLEWA W., *Diagnostyka procesów. Modele Metody sztucznej inteligencji Zastosowania*, WNT, Warszawa 2002
- KURZYŃSKI M., 1997, *Rozpoznawanie obiektów - metody statystyczne*, Oficyna Wydawnicza Pol. Wrocławskiej, Wrocław, 1997
- LIAO S., LIU T., SHI, G ZHANG *Gearbox condition monitoring using self organizing feature maps*. Proc Instit. Mech. Engrs vol 218p 119-128, 2000
- MALINA W., SOBCZAK W., *Metody selekcji i redukcji informacji*, WNT, Warszawa, 1985
- VECER, P., SMÍD R., KREIDL M., *Application of the Self-Organizing Map to Manual Automotive Transmission Diagnostics*. In ISSPIT 2003 [CD-ROM]. Darmstadt: IEEE, 2003
- ZIMROZ R., *Metoda diagnostyki wielostopniowych przekładni zębatych w układach napędowych przenośników taśmowych z zastosowaniem modelowania* Rozprawa Doktorska, Politechnika Wrocławska, 2002

*feature selection, diagnostic procedure, multistage gearboxes.*

## IDENTIFICATION OF OPTIMIZED DIAGNOSTIC FEATURES OF MULTI STAGE GEARBOX

The occurrence of many gearbox faults simultaneously and possibilities of their identification on the basis of vibration symptoms is not a topic of research work in the literature. The authors are concentrated in maximum of their research work on identification of a single type of fault on the basis of a single symptom. This paper presents the research work on selection of diagnostic features during degradation. Simultaneously it presents the problem of choosing the signal receiving points. In the result of collected signal at many points we obtain a multidimensional matrix from which a point is to be selected for which we get the best distribution of symptoms for the particular faults. In these problems we try to the answer on the following questions: which symptoms give the better results for classification of different faults, for which signal receiving point good/bad technical state classes seperability is the highest, and is it possible to reduce symptoms matrix?