

Adam GŁOWACZ*, Witold GŁOWACZ*AKADEMIA GÓRNICZO-HUTNICZA, WYDZIAŁ ELEKTROTECHNIKI, AUTOMATYKI, INFORMATYKI I ELEKTRONIKI
ul. Nawojki 6/79, 30-072 Kraków**Diagnostyka silnika synchronicznego oparta na rozpoznawaniu dźwięku z zastosowaniem LPCC i GSDM**

Mgr inż. Adam GŁOWACZ

Mgr inż. Adam Głowacz w latach: 2002 – 2007 był studentem na kierunku elektronika i telekomunikacja na Wydziale Elektrotechniki, Automatyki, Informatyki i Elektroniki AGH w Krakowie. W dniu 20 lipca 2007 r. otrzymał tytuł magistra inżyniera. Jest autorem trzydziestu publikacji w czasopiśmie i materiałach konferencyjnych.



e-mail: adglow@agh.edu.pl

Mgr inż. Witold GŁOWACZ

Mgr inż. Witold Głowacz był studentem na kierunku automatyka i robotyka na Wydziale Elektrotechniki, Automatyki, Informatyki i Elektroniki AGH w Krakowie. W dniu 28 września 2007 r. otrzymał tytuł magistra inżyniera. Jest autorem trzydziestu publikacji w czasopiśmie i materiałach konferencyjnych.



e-mail: wglowacz@agh.edu.pl

Streszczenie

Zaprezentowano koncepcję badania sygnałów akustycznych stanów przedawaryjnych silnika synchronicznego. Oprogramowanie do rozpoznawania dźwięku zostało zaimplementowane. Algorytmy przetwarzania i analizy sygnałów akustycznych zostały zastosowane. System jest oparty na algorytmie LPCC (Współczynniki cepstralne liniowego kodowania) i GSDM (*Genetyczna rozrzedzona pamięć rozproszona*). Badania zostały przeprowadzone dla sygnałów akustycznych stanów przedawaryjnych.. Zmiany w sygnale akustycznym spowodowane były przez zwarcia i przerwy w obwodzie stojana. Analiza wyników pokazuje wrażliwość metody opartej na LPCC i GSDM w zależności od danych wejściowych. Wyniki badań potwierdzają poprawne działanie systemu rozpoznawania dźwięku silnika synchronicznego.

Słowa kluczowe: silnik synchroniczny, rozpoznawanie dźwięku, LPCC, GSDM, diagnostyka.

Diagnostics of a synchronous motor based on sound recognition with application of LPCC and GSDM**Abstract**

In recent years the methods of sound recognition have been developed. Hence, there is an idea to use them in case of machines. The paper describes the concept of investigations of acoustic signals of synchronous motor imminent failure conditions. Measurements were taken with a recorder OLYMPUS WS-200S. Sound recognition software was implemented. Algorithms of signal processing and analysis were used. The system is based on the LPCC (*Linear Predictive Cepstrum Coefficients*) algorithm and GSDM (*Genetic Sparse Distributed Memory*). Investigations were carried out for acoustic signals of imminent failure conditions. The following plan of investigations of a synchronous motor acoustic signal was proposed: recording of audio track, sound track division, sampling, quantization, normalization, filtration, windowing, feature extraction, classification (Fig. 2). Figs. 3, 4, 5 and 6 show changes of the LPCC values for four types of the categories recognized. Changes in the acoustic signal were caused by short circuit and broken coils in the stator circuit. The sound recognition efficiency depending on the acoustic signal and the sample length is presented in Fig. 8. The sound recognition system was built for a synchronous motor. There were used 39 band-pass filters in investigations. Analysis of the results shows the sensitivity of the method based on LPCC and GSDM, depending on the input data. The results confirm correct operation of the synchronous motor sound recognition system. These studies can be used for diagnostics based on acoustic emission in electrical, mechanical, hydraulic and pneumatic machines.

Keywords: synchronous motor, sound recognition, LPCC (Linear Predictive Cepstrum Coefficients), GSDM (Genetic Sparse Distributed Memory), diagnostics.

1. Wstęp

Do rozpoznawania uszkodzeń maszyn stosuje się metody dedykowane dla faz konstruowania, wytwarzania i eksploatacji maszyn.

Najważniejsze metody oparte są na badaniu: pola magnetycznego maszyny, ultradźwięków generowanych przez maszynę, radiograficznym, emisji akustycznej maszyny, wizualnym wybranych części maszyny, produktów zużycia zawartych w olejach smarnych lub hydraulicznych maszyn, emisji termicznej maszyny, emisji wibroakustycznej maszyny, sygnałów elektrycznych maszyny. W ostatnich latach powstało wiele metod do badania sygnału akustycznego [1-9]. Uzyskane dotychczas wstępne wyniki badań potwierdzają słusność zastosowania tych metod do rozpoznawania stanów przedawaryjnych maszyn elektrycznych. W przyjętym rozumowaniu powstanie stanu przedawaryjnego interpretowane jest jako zagrożenie zepsucia się maszyny. Naprawa maszyny kosztuje mniej, gdy awaria zostanie wykryta wcześniej, dlatego tak ważne jest badanie stanów przedawaryjnych.

Zakłada się, że sygnał akustyczny zawiera informację o stanie maszyny elektrycznej. Generuje to ciąg badań sygnału akustycznego, które należy przeprowadzić aby wydobyc informację użyteczną z punktu widzenia diagnostyki. Podstawową rzeczą jest zaprojektowanie i budowa środowiska w którym badany sygnał akustyczny będzie przetwarzany i analizowany. Proponowane podejście umożliwi sprecyzowanie zadań systemu, a następnie budowę takiego stanowiska. Środowisko to będzie łączyć sprzęt i oprogramowanie potrzebne do właściwego przetwarzania, analizy sygnału akustycznego. Kolejno należy przeprowadzić badania sygnałów akustycznych silnika synchronicznego. Dobierając odpowiednio metody przetwarzania, analizy i klasyfikacji można wykazać, że zastosowanie algorytmów rozpoznawania umożliwia efektywną diagnostykę stanów przedawaryjnych silnika synchronicznego. Pomiarzy zostały wykonane dyktafonem OLYMPUS WS-200S. Jako metodę ekstrakcji cech stosowano algorytm LPCC. Jako klasyfikator zastosowano algorytm GSDM.

Rozważania prowadzone w artykule dotyczyć będą wybranego silnika synchronicznego generującego sygnały akustyczne. Badania te mogą posłużyć do dalszego stosowania diagnostyki opartej na emisji akustycznej w maszynach i urządzeniach elektrycznych, mechanicznych, hydraulicznych i pneumatycznych.

2. Maszyna synchroniczna


Maszyna synchroniczna pracowała jako silnik synchroniczny. Zwarcie i przerwy wykonano w obwodzie stojana (rys. 1). Zwarcie cewki zrealizowano w fazie R (U3-X3), jedną przerwę w fazie R (X1-X4), natomiast trzy przerwy w fazach R, S i T (X1-X4, Y1-Y4, Z1-Z4). Maszyna pracowała w stanie niewzbudzonem.

Określono wartości napięcia międzyprzewodowego stojana, prądu stojana, prędkości silnika i prądu wzbudzenia w czasie rejestracji dźwięków:

- dźwięk silnika synchronicznego bez uszkodzeń, $U_{RS}=100$ V, $I_R=30.9$ A, $n_N=1500$ obr/min, $I_w \approx 0$ A,

- dźwięk silnika synchronicznego ze zwartymi zewojami stojana, $U_{RS}=100\text{ V}$, $I_R=31.2\text{ A}$, $n_N=1500\text{ obr/min}$, $I_w \approx 0\text{ A}$, $R_z=2.5\ \Omega$,
- dźwięk silnika synchronicznego z jedną przerwą w uzwojeniu jednej fazy stojana, $U_{RS}=100\text{ V}$, $I_R=24\text{ A}$, $n_N=1500\text{ obr/min}$, $I_w \approx 0.3\text{ A}$,
- dźwięk silnika synchronicznego z trzema przerwami w uzwojeniach trzech faz stojana, $U_{RS}=100\text{ V}$, $I_R=36\text{ A}$, $n_N=1500\text{ obr/min}$, $I_w \approx 0.245\text{ A}$,

gdzie: U_{RS} – napięcie międzyprzewodowe stojana pomiędzy fazami R i S, I_R – prąd fazy R, I_w – prąd wzbudzenia, n_N – znamionowa prędkość wirnika, R_z – rezystancja zwierająca (U3-X3).



Rys. 1. Schemat uzwojeń stojana dla silnika synchronicznego z jedną przerwą w uzwojeniu jednej fazy stojana (X1-X4)

Fig. 1. Stator windings for a synchronous motor with one broken coil in stator circuit (X1-X4)

3. Wybór algorytmów przetwarzania i analizy sygnałów akustycznych

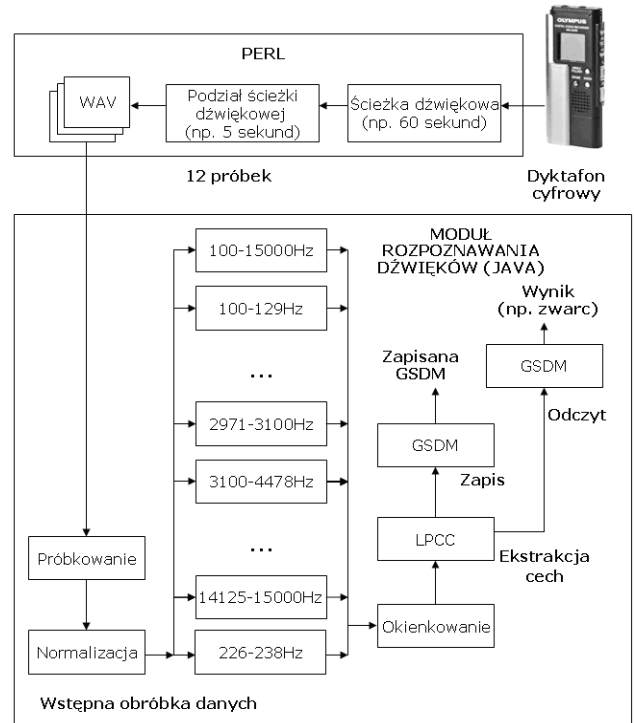
Największe trudności pojawiają się podczas doboru metod przetwarzania i analizy sygnału akustycznego. Trzeba zadać sobie pytanie jakich różnic w sygnale należy szukać. W literaturze przetwarzania, analizy i rozpoznawania sygnałów akustycznych, problem ten jest szeroko omówiony przez wielu autorów. Z uwagi jednak na odmienną naturę sygnałów akustycznych w każdym problemie stosowane metody nie zawsze są skuteczne. Przyjęto następujący plan badań sygnałów akustycznych maszyny elektrycznej: nagrywanie ścieżki dźwiękowej, podział ścieżki dźwiękowej na mniejsze fragmenty, próbkowanie, kwantyzacja, normalizacja, filtracja cyfrowa, okienkowanie (okno Hamminga), ekstrakcja cech (LPCC), klasyfikacja (GSDM). Przedstawiony plan badań sygnału akustycznego został sporządzony przez podobieństwo do sposobu rozpoznawania mowy, tożsamości mówców, zwierząt, instrumentów muzycznych i urządzeń [4-16]. Z uwagi na to, że sygnały maszyn elektrycznych są słyszalne uchem człowieka można częściowo zastosować algorytmy sprawdzone w tych problematykach.

4. Przepływ danych w procesie rozpoznawania dźwięku silnika synchronicznego

Proces rozpoznawania dźwięku silnika synchronicznego składa się z procesu tworzenia wzorców do rozpoznawania (zapis GSDM) i procesu identyfikacji (odczyt GSDM). Na początku procesu tworzenia wzorców do rozpoznawania wykonywane jest próbkowanie, normalizacja amplitudy i filtracja cyfrowa. Następnie stosowane jest okienkowanie (okno o rozmiarze 256).

Okno czasowe powinno być na tyle krótkie, by można było założyć, iż sygnał w obrębie okna jest lokalnie stacjonarny. W kolejnym kroku dane są zamieniane przez algorytm LPCC. Następnie z tak otrzymanych współczynników cepstralnych liniowego kodowania tworzony jest wektor cech (75 cech). Wektory cech są używane do zapisu pamięci GSDM. Różnice między dźwiękami zależą od różnic w uporządkowanej sekwencji. W procesie iden-

tyfikacji etapy przetwarzania sygnału akustycznego są takie same jak dla procesu tworzenia wzorców do rozpoznawania. Istotną zmianą następuje w etapie klasyfikacji, gdzie zamiast zapisu pamięci GSDM następuje jej odczyt, który prowadzi do określenia kategorii dźwięku (rys. 2).




Rys. 2. Proces tworzenia wzorców do rozpoznawania i proces identyfikacji

Fig. 2. Creating patterns for recognition and the identification process

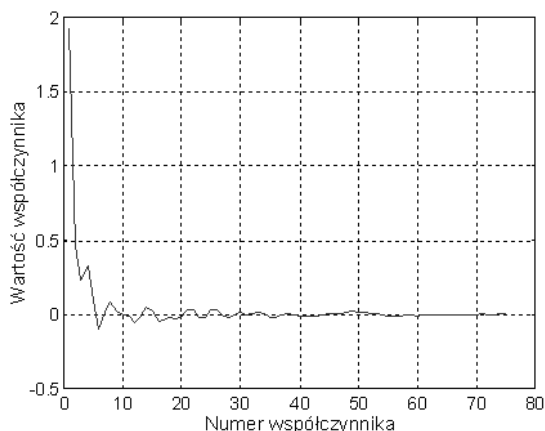
5. Współczynniki cepstrum liniowego kodowania

W celu zmniejszenia liczby cech sygnału stosuje się ekstrakcję cech. Jedną z metod ekstrakcji cech jest liniowe kodowanie predykcyjne (LPC). Jest to algorytm, który posiada stosunkowo szybki sposób wyznaczania swoich współczynników.




Rys. 3. Kolejne wartości współczynników liniowego kodowania predykcyjnego cepstrum dla próbek dźwięku o długości pięć sekund przy zastosowaniu normalizacji amplitudy (100-15000 Hz) dla silnika synchronicznego bez uszkodzeń

Fig. 3. LPCC values for sound samples of five seconds duration when normalising the amplitude (analysed frequencies 100-15000 Hz) for a faultless synchronous motor




Rys. 4. Kolejne wartości współczynników liniowego kodowania predykcyjnego cepstrum dla próbek dźwięku o długości pięć sekund przy zastosowaniu normalizacji amplitudy (100-15000 Hz) dla silnika synchronicznego ze zwartymi zezwojami stojana

Fig. 4. LPCC values for sound samples of five seconds duration when normalising the amplitude (analysed frequencies 100-15000 Hz) for a synchronous motor with shorted stator coils



Rys. 5. Kolejne wartości współczynników liniowego kodowania predykcyjnego cepstrum dla próbek dźwięku o długości pięć sekund przy zastosowaniu normalizacji amplitudy (100-15000 Hz) dla silnika synchronicznego z jedną przerwą w uzwojeniu jednej fazy stojana

Fig. 5. LPCC values for sound samples of five seconds duration when normalising the amplitude (analysed frequencies 100-15000 Hz) for a synchronous motor with one broken coil in the stator circuit



Rys. 6. Kolejne wartości współczynników liniowego kodowania predykcyjnego cepstrum dla próbek dźwięku o długości pięć sekund przy zastosowaniu normalizacji amplitudy (100-15000 Hz) dla silnika synchronicznego z trzema przerwami w obwodzie stojana

Fig. 6. LPCC values for sound samples of five seconds duration when normalising the amplitude (analysed frequencies 100-15000 Hz) for a synchronous motor with three broken coils in the stator circuit

Transmitancja jest wyrażona następującym wzorem:

$$H(z) = \frac{1}{1 - \sum_{k=1}^p a_k z^{-k}} \quad (1)$$

gdzie p jest liczbą współczynników, a_k jest współczynnikiem.

Metoda LPCC (ang. Linear Predictive Cepstrum Coefficients) jest oparta na algorytmie LPC. Po zastosowaniu metody LPC zostają otrzymane współczynniki filtra predykcji liniowej a_k [17, 18]. Kolejno stosuje się wzór (2), który przekształca je w wartości współczynników cepstralnej liniowej predykcji. Postać taka może zostać zastosowana do efektywnego porównywania sygnałów:

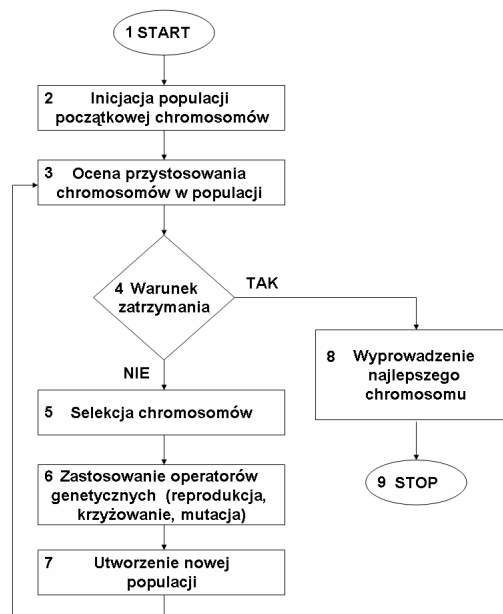
$$c(n) = \begin{cases} a_n + \sum_{k=1}^{n-1} \frac{k}{n} c(k) a_{n-k} & 1 \leq n \leq p \\ \sum_{k=n-p}^{n-1} \frac{k}{n} c(k) a_{n-k} & n > p \end{cases} \quad (2)$$

gdzie $c_0=r(0)$, p – rząd predykcji, n – liczba współczynników cepstralnych.

Ekstrakcja cech została zastosowana dla dźwięków silnika synchronicznego (rys. 3, 4, 5, 6).

6. Klasyfikacja

Genetyczna rozrzedzona pamięć rozproszona (ang. *Genetic Sparse Distributed Memory*) powstała przez połączenie pamięci SDM (ang. *Sparse Distributed Memory*) i algorytmu genetycznego [19, 20]. SDM przechowuje wzorce w celu ich późniejszego odtworzenia. Na wejście pamięci podczas operacji czytania podawany jest „klucz”, który jest jednym z wzorców zapisanych w pamięci. Wynikiem tego typu operacji jest wygenerowanie na wyjściu wzorca skojarzonego z „kluczem”. Kluczami są wektory wejściowe x^p , które są skojarzone z wektorami wyjściowymi y^p . Zadaniem pamięci jest zapamiętanie skojarzonych ze sobą zbiorów: $\{(x^1, y^1), (x^2, y^2), (x^3, y^3), \dots\}$ i każdorazowe odtworzenie na wyjściu wzorca y^p , jeżeli na wejście podany zostanie wektor wejściowy x , najbardziej przypominający wektor x^p spośród wszystkich zapamiętanych wektorów wejściowych. W przypadku błędnego odtworzenia system może dawać na wyjściu wzorec inny niż y^p .



Rys. 7. Schemat blokowy algorytmu genetycznego użytego w algorytmie GSDM
Fig. 7. Flowchart of the genetic algorithm used in the GSDM algorithm

W pamięci GSDM czytanie danych przebiega tak samo jak w SDM. Inaczej pamięci działają podczas zapisu. Pamięć GSDM stosuje algorytm genetyczny (rys. 7).

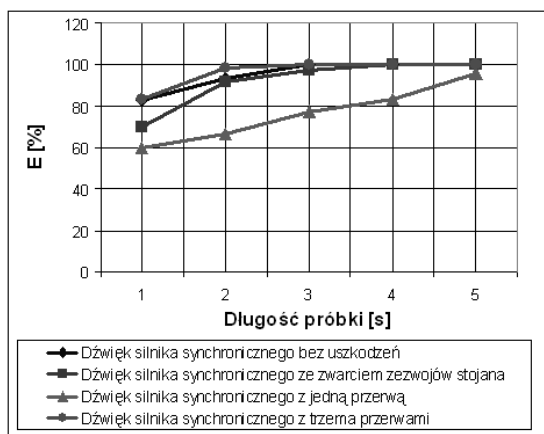
Klasyfikator oparty na GSDM wykonywać będzie najpierw operacje zapisu GSDM (proces tworzenia wzorców do rozpoznawania). Następnie wykonywany będzie odczyt pamięci (proces identyfikacji). Przewiduje się dobierać parametry pamięci GSDM w celu uzyskania jak najlepszych wyników rozpoznawania dźwięków. Ważniejsze parametry pamięci GSDM na które należy zwrócić uwagę to: dokładność rozpoznanych próbek, liczba iteracji w algorytmie genetycznym, współczynnik mutacji w algorytmie genetycznym, próg odległości Hamminga, liczba znaków kategorii dźwięku, rozmiar pamięci GSDM [19, 20].

7. Wyniki rozpoznawania dźwięków

Do zapisu pamięci GSDM zastosowano 24 próbki pięciosekundowe dla każdej z czterech kategorii dźwięku. Do identyfikacji stosowano nowe próbki o długościach 1-5 sekund dla każdej z kategorii. Skuteczność rozpoznawania dźwięku była określona następująco:

$$E = \frac{N_1}{N} \quad (3)$$

gdzie: E – skuteczność rozpoznawania dźwięku, N_1 – liczba poprawnie rozpoznanych próbek, N – liczba wszystkich próbek w procesie identyfikacji.



Rys. 8. Skuteczność rozpoznawania dźwięku silnika synchronicznego w zależności od rodzaju sygnału akustycznego i długości próbki (100-15000 Hz). Badane próbki zostały znormalizowane

Fig. 8. Sound recognition efficiency for a synchronous motor vs. the sample length (100-15000 Hz). The investigated samples were normalised

Skuteczność rozpoznawania dźwięku w zależności od rodzaju sygnału akustycznego i długości próbki została przedstawiona na rysunku 8.

8. Wnioski

System rozpoznawania dźwięku został zbudowany dla silnika synchronicznego. W badaniach zastosowano 39 filtrów pasmowo-przepustowych. Najlepsze wyniki dla algorytmu GSDM zostały otrzymane gdy stosowano normalizację bez filtracji cyfrowej. Odległość Hamminga wynosiła wówczas 620. Pozostałe parametry zostały dobrane w następujący sposób: dokładność rozpoznanych próbek = 0.90, liczba iteracji w algorytmie genetycznym = 100, współczynnik mutacji w algorytmie genetycznym = 0.01, liczba znaków kategorii dźwięku = 5, rozmiar pamięci GSDM = 500.

Wyniki otrzymane przy zastosowaniu algorytmu LPCC, GSDM i normalizacji dają skuteczność rozpoznawania dźwięku na poziomie od 60% do 100% dla próbek o długości 1-5 sekund. Skuteczność rozpoznawania dźwięku dla próbek pięciosekundowych

była najlepsza. Na procesorze Pentium M 730 czas wykonywania procesu identyfikacji jednej pięciosekundowej próbki z zastosowaniem normalizacji, LPCC i GSDM wynosi 0.203 sekundy. Dla próbki jednosekundowej czas ten wynosi 0.188 sekundy.

9. Literatura

- [1] Mitrovic D., Zeppelzauer M., Eidenberger H.: Analysis of the Data Quality of Audio Features of Environmental Sounds, *Journal of Universal Knowledge Management*, vol. 1, no. 1 (2006), 4-17.
- [2] Yoshii K., Goto M. and Okuno H. G.: Drum Sound Recognition for Polyphonic Audio Signals by Adaptation and Matching of Spectrogram Templates With Harmonic Structure Suppression, *IEEE Transactions on Audio, Speech, and Language Processing*, Vol. 15, No. 1, January 2007, 333-345.
- [3] Dubois D., Guastavino C.: Cognitive evaluation of sound quality: Bridging the gap between acoustic measurements and meanings. *Proceedings of 19th International Congress on Acoustics - ICA07*, September 2-8 2007, Madrid, Spain.
- [4] Lee K.: Effective Approaches to Extract Features and Classify Echoes in Long Ultrasound Signals from Metal Shafts, Ph. D. dissertation, Brisbane, Australia, 2006.
- [5] The MARF Development Group: Modular Audio Recognition Framework v.0.3.0-devel-20050606 and its Applications, Application note, Montreal, Quebec, Canada, 2005.
- [6] Sutowski P.: Wykorzystanie wartości skutecznej sygnału emisji akustycznej oraz metod sztucznej inteligencji do oceny zużycia ściemnicy, *Pomiary Automatyka Kontrola*, vol. 55, 4/2009, 255-258.
- [7] Tadeusiewicz R.: Speech recognition versus understanding of the nature of speech deformation in pathological speech analysis (Abstract), *Archives of Acoustics*, vol. 28, No. 3, 2003, pp. 260.
- [8] Głowacz A., Głowacz W.: Dc machine diagnostics based on sound recognition with application of FFT and fuzzy logic, *Przegląd Elektrotechniczny (Electrical Review)*, R. 84, NR 12/2008, pp.43-46.
- [9] Głowacz A., Głowacz W.: Sound recognition of dc machine with application of FFT and backpropagation neural network, *Przegląd Elektrotechniczny (Electrical Review)*, R. 84, NR 9/2008, pp.159-162.
- [10] Kościelny J. M.: Diagnostyka zautomatyzowanych procesów przemysłowych, *Akademicka Oficyna Wydawnicza EXIT*, Warszawa 2001.
- [11] Uhl T., Barszcz T.: Informatyczne aspekty projektowania systemów monitorowania stanu maszyn – sprzęt i oprogramowanie, *Diagnostyka*, 2001 vol. 24 s. 13–22.
- [12] Strzyżakowski Z., Szulc W.: Komputerowe sterowanie i nadzór w zintegrowanych systemach bezpieczeństwa, *Prace Naukowe Politechniki Radomskiej, Transport 1(17)*, Radom 2003.
- [13] Kaczorek T.: Wektory i macierze w automatyce i elektrotechnice, *WNT Warszawa*, 1998.
- [14] Klamka J., Ogonowski Z., Jamicki M., Stasik M.: *Metody numeryczne*, Wydawnictwo Politechniki Śląskiej, 2004.
- [15] Kowal M., Korbić J.: Robust fault detection using neuro-fuzzy models, *Przegląd Elektrotechniczny*, 2006, No 1, pp. 32-36.
- [16] Zielonko R., Kowalewski M.: Nowa, metrologicznie zorientowana sieć neuronowa i metoda diagnostyki obiektów technicznych, *Pomiary Automatyka Kontrola*, vol. 54, 3/2008, 174-177.
- [17] Corneliu M., Costinescu B.: Implementing the Levinson-Durbin Algorithm on the StarCore™ SC140/SC1400 Cores, *Application Note Freescale Semiconductor AN2197*, 1/2005.
- [18] Antoniol G., Rollo F., Venturi G.: Linear Predictive Coding and Cepstrum Coefficients for Mining Time Variant Information from Software Repositories, *Second International Workshop on Mining Software Repositories*, St. Louis, USA, May, 17, 2005, pp.74-78.
- [19] Fan K.-C., Wang Y.-K.: A Genetic Sparse Distributed Memory Approach To The Application Of Handwritten Character Recognition. *Pattern Recognition*, Volume 30, Number 12, December 1997, pp. 2015-2022(8).
- [20] Mizera P.: Rozpoznawanie mówcy z wykorzystaniem GSDM, *Praca dyplomowa, Politechnika Krakowska, Kraków 2006*.