

Diagnostyka silnika synchronicznego oparta na analizie spektrum sygnałów akustycznych

Przedstawiono koncepcję badania sygnałów akustycznych stanów przedawaryjnych silnika synchronicznego. Zastosowano algorytmy przetwarzania i analizy sygnałów akustycznych, w tym algorytm FFT i klasyfikator Nearest Mean z metryką kosinusową. Zaimplementowano oprogramowanie do rozpoznawania dźwięków. Przeprowadzono badania dla sygnałów akustycznych stanów przedawaryjnych. Wyniki badań potwierdzają poprawne działanie systemu rozpoznawania dźwięku w silniku synchronicznym.

1. WSTĘP

Diagnostyka maszyn, urządzeń najwcześniej powstała i została zastosowana do środków transportu powietrznego, morskiego oraz w energetyce. Obecnie jesteśmy świadkami adaptacji i opracowywania nowych metod i środków do oceny stanu maszyn w pozostałych gałęziach przemysłu i gospodarki kraju. Tutaj trzeba wymienić trzy czynniki stymulujące rozwój diagnostyki. Pierwszy z nich to złożoność systemów produkcyjnych, gdzie awaria jednej maszyny unieruchamia cały ciąg technologiczny, dając w efekcie niewspółmiernie duże straty ekonomiczne. Drugi czynnik, słuszny zwłaszcza dla maszyn małych i średnich, to duża liczba tych maszyn, będących jednocześnie w ruchu ciągłym i to bez żadnego nadzoru. Przykładowo: przeciętnie rafineria lub fabryka chemiczna, eksploatuje jednocześnie kilka tysięcy małych i średnich silników. Konserwacja i remont tak liczego zespołu maszyn powoduje wiele kłopotów, jeśli nie potrafimy właściwie przewidzieć terminu remontu. Trzeci czynnik to wysoki poziom niezawodności wymagany dla pewnych urządzeń jednorazowego lub sezonowego użytkowania. Niezawodności takiej wymagamy od specjalnych pojazdów, np. samolotów, gdzie maszyna oczekuje cały rok na kilkutygodniowy okres pracy.

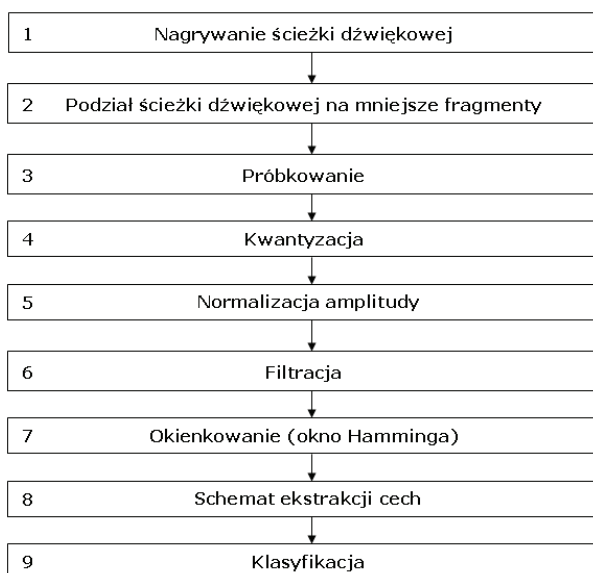
Do rozpoznawania uszkodzeń maszyn stosuje się metody dedykowane dla faz konstruowania, wy-

tworzania 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 [1-6]. Uzyskane dotychczas wstępne wyniki badań potwierdzają słuszność zastosowania tych metod do rozpoznawania stanów przedawaryjnych maszyn elektrycznych [7,8]. 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.

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, pneumatycznych. Pomiarzy zostały wykonane dyktafonem OLYMPUS WS-200S. Jako schemat ekstrakcji cech stosowano algorytm FFT. Jako klasyfikator zastosowano klasyfikator Nearest Mean z metryką kosinusową.

2. PLAN BADANIA SYGNAŁÓW AKUSTYCZNYCH SILNIKA SYNCHRONICZNEGO

Przyjęto następujący plan badań sygnałów akustycznych maszyny elektrycznej: nagrywanie ścieżki dźwiękowej, podział ścieżki dźwiękowej na mniejsze fragmenty, próbkowanie, kwantyzacja, normalizacja, filtracja, okienkowanie (okno Hamminga), schemat ekstrakcji cech (FFT), klasyfikacja oparta na klasyfikatorze Nearest Mean z metryką kosinusową. Przedstawiony plan badań sygnału akustycznego został sporządzony przez podobieństwo do sposobu rozpoznawania tożsamości mówców, zwierząt, instrumentów muzycznych i urządzeń [1-16]. Z uwagi na to, że sygnały maszyn elektrycznych są słyszalne uchem człowieka można częściowo zastosować algorytmy sprawdzone w tych problematykach (rys. 1).



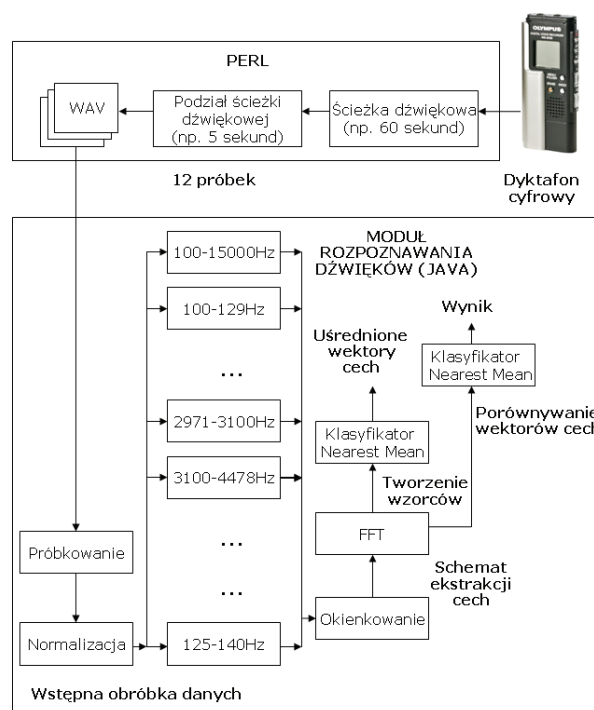
Rys.1. Przegląd stosowanych algorytmów obejmuje trzy etapy: wstępne przetwarzanie danych, schemat ekstrakcji cech i klasyfikację

3. PRZEPIŃY DANYCH W PROCESIE ROZPOZNAWANIA SYGNAŁU AKUSTYCZNEGO SILNIKA SYNCHRONICZNEGO

Proces rozpoznawania dźwięku silnika synchronicznego składa się z procesu tworzenia wzorców do rozpoznawania i procesu identyfikacji. Na początku procesu tworzenia wzorców do rozpoznawania wykonywane jest próbkowanie, normalizacja amplitudy i filtracja. Następnie stosowane jest okienkowanie z zastosowaniem okna Hamminga – okno o rozmiarze 32768. Okno 32768 odpowiada w przybliżeniu

0.743 sekundy przy częstotliwości próbkowania 44100 Hz. W kolejnym kroku dane są zamieniane przez algorytm FFT. Następnie z tak otrzymanych harmonicznycy częstotliwości tworzony jest uśredniony wektor cech (1-16384 cech). Uśredniony wektor cech powstaje przez uśrednienie widm z pewnej grupy próbek wzorcowych określonego dźwięku.

W procesie identyfikacji etapy przetwarzania sygnału akustycznego są takie same jak dla procesu tworzenia wzorców do rozpoznawania. Istotna zmiana następuje w etapie klasyfikacji (rys. 2). W tym etapie porównywane są ze sobą wektory cech (uśredniony wektor cech z nowym nieznanym wektorem cech).




Rys.2. Proces tworzenia wzorców do rozpoznawania i proces identyfikacji z zastosowaniem klasyfikatora Nearest Mean z metryką kosinusową

4. SZYBKA TRANSFORMACJA FOURIERA

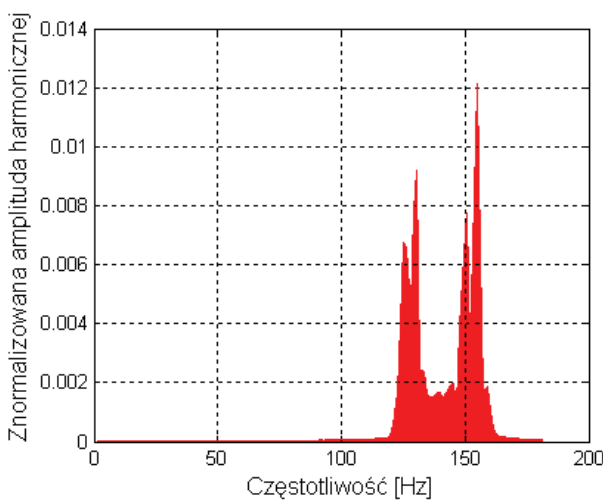
Szybka transformacja Fouriera ma za zadanie przekształcić wartości z dziedziny czasu na wartości w dziedzinie częstotliwości. Otrzymane wartości w dziedzinie częstotliwości można użyć w dalszych obliczeniach. Szybka transformacja Fouriera jest bardzo efektywną operacją, jednak wektor próbek wejściowych musi mieć długość $N = 2^k$, gdzie k to pewna liczba naturalna. Przyjmuje się, że wektor próbek wejściowych N jest równy rozmiarowi stosowanego okna. W omawianym przypadku wynosi on

32768, czyli $k=15$. Algorytm szybkiej transformacji Fouriera może zostać zastosowany jako schemat ekstrakcji cech sygnału akustycznego. W tym przypadku cechami będą odpowiednie harmoniczne częstotliwości.

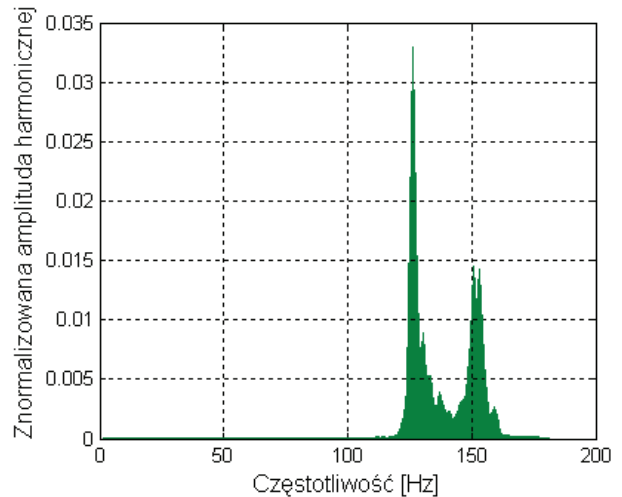
Rysunki 3, 4, 5, 6 pokazują zarejestrowane sygnały akustyczne silnika synchronicznego dla 4 różnych stanów pracy przy zastosowaniu normalizacji amplitudy, filtru przepuszczającego częstotliwości od 120 Hz do 156 Hz, algorytmu FFT z oknem o rozmiarze 32768.



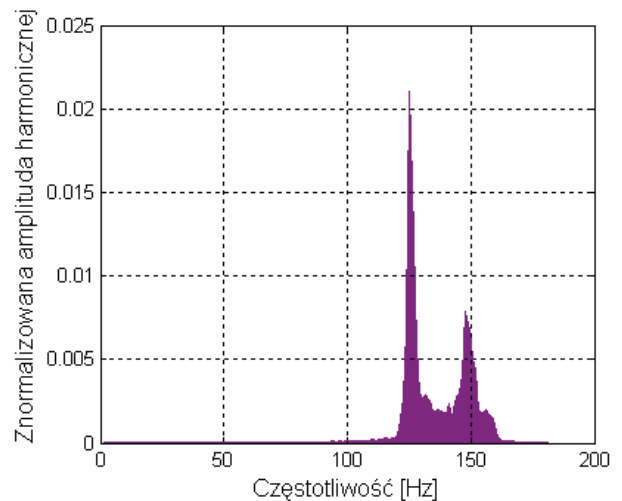
Rys.3. Widmo częstotliwości próbki dźwięku o długości pięć sekund przy zastosowaniu normalizacji amplitudy, filtru przepuszczającego częstotliwości od 120 Hz do 156 Hz i FFT dla silnika synchronicznego bez uszkodzeń



Rys.4. Widmo częstotliwości próbki dźwięku o długości pięć sekund przy zastosowaniu normalizacji amplitudy, filtru przepuszczającego częstotliwości od 120 Hz do 156 Hz i FFT dla silnika synchronicznego ze zwartymi zezwojami stojana



Rys.5. Widmo częstotliwości próbki dźwięku o długości pięć sekund przy zastosowaniu normalizacji amplitudy, filtru przepuszczającego częstotliwości od 120 Hz do 156 Hz i FFT dla silnika synchronicznego z jedną przerwą w uzwojeniu jednej fazy stojana



Rys.6. Widmo częstotliwości próbki dźwięku o długości pięć sekund przy zastosowaniu normalizacji amplitudy, filtru przepuszczającego częstotliwości od 120 Hz do 156 Hz i FFT dla silnika synchronicznego z trzema przerwami w uzwojeniach trzech faz stojana

5. KLASYFIKATOR NEAREST MEAN Z METRYKĄ KOSINUSOWĄ

W algorytmie "najbliższa średnia" (NM - ang. *Nearest Mean*) wzorcem klasy rozpoznawanych wektorów jest wartość średnia. Podobnie też jak w algorytmie NN obliczane są odległości wektora rozpoznawanego od wszystkich wektorów wzorcowych (średnich), a następnie wybierana jest najmniejsza z nich.

Wektory cech są wyliczane odpowiednio z widma częstotliwości silnika synchronicznego. Po wyliczeniu wektorów wzorcowych i wektorów cech następuje obliczenie odległości pomiędzy nimi. Odległość kosinusowa, to miara odległości między dwoma wektorami. Dla pary wektorów $x=[x_1, x_2, \dots, x_n]$, $y=[y_1, y_2, \dots, y_n]$, wyraża się następującym wzorem:

$$d_{\cos}(x, y) = 1 - \frac{\sum_{i=1}^n x_i y_i}{\sqrt{\sum_{i=1}^n x_i^2} \sqrt{\sum_{i=1}^n y_i^2}} \quad (1)$$

gdzie x i y są wektorami cech o tych samych długościach


6. WYNIKI ROZPOZNAWANIA DŹWIĘKÓW

Maszyna synchroniczna pracowała jako silnik synchroniczny. Zwarcie i przerwy wykonano w obwodzie stojana (rys. 7,8). 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-

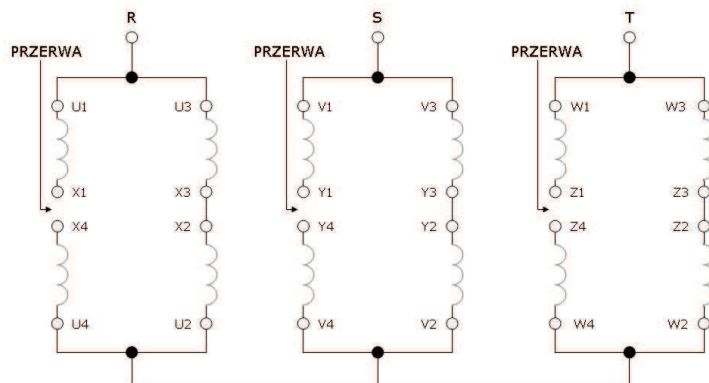
X4, Y1-Y4, Z1-Z4). Różnice między dźwiękami zależą od różnic w uporządkowanej sekwencji. Maszyna pracowała w stanie niewzbudzonym. Określono wartości napięcia międzyprzewodowego stojana, prądu stojana, prędkości silnika i prądu wzbudzenia w czasie rejestracji dźwięków:

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

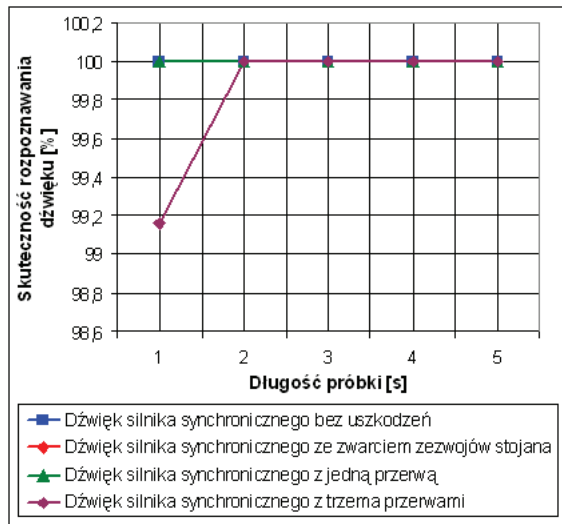
Do procesu tworzenia wzorców do rozpoznawania zastosowano 24 próbki pięciosekundowe dla każdej z czterech kategorii dźwięku. Do identyfikacji stos-



Rys. 7. Schemat uzwojeń stojana dla silnika synchronicznego z jedną przerwą w uzwojeniu jednej fazy stojana (X1-X4)



Rys. 8. Schemat uzwojeń stojana dla silnika synchronicznego z trzema przerwami w uzwojeniach trzech faz stojana (X1-X4, Y1-Y4, Z1-Z4)



Rys. 9. Skuteczność rozpoznawania dźwięku silnika synchronicznego w zależności od rodzaju sygnału akustycznego i długości próbki. Zastosowane algorytmy to normalizacja amplitudy, okienkowanie, filtracja od 120 Hz do 156 Hz, FFT i klasyfikator Nearest Mean z metryką kosinusową

wano nowe próbki o długościach 1-5 sekund dla każdej z kategorii. Skuteczność rozpoznawania dźwięku była określona następująco:

$$E = \frac{N_1}{N} \quad (2)$$

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

Skuteczność rozpoznawania dźwięku w zależności od rodzaju sygnału akustycznego i długości próbki została przedstawiona na rysunku 9.

6. PODSUMOWANIE

System rozpoznawania dźwięku został zbudowany dla silnika synchronicznego. Najlepsze wyniki dla algorytmu FFT i klasyfikatora Nearest Mean zostały otrzymane przy przepuszczaniu częstotliwości od 120 Hz do 156 Hz. Skuteczność rozpoznawania dźwięku wynosiła od 99,16% do 100% dla próbek o długości od 1 do 5 sekund. Na procesorze Pentium M 730 czas identyfikacji jednej pięciosekundowej próbki z zastosowaniem normalizacji, okienkowania, filtracji od 120 Hz do 156 Hz, FFT i klasyfikatora Nearest Mean wynosił 0,89 sekundy. Dla próbki jednosekundowej czas ten wynosił 0,437 sekundy. Zakłada się stoso-

wanie dwóch etapów – etap tworzenia wzorców, etap identyfikacji. Stanowisko rozpoznaje kategorię dźwięku na podstawie uprzednio zarejestrowanych wzorców. Należy przy tym zwrócić uwagę, aby wzorce i nowe dźwięki były rejestrowane tym samym urządzeniem przy: odpowiedniej wilgotności powietrza, temperaturze, odpowiednim ciśnieniu, poziomie napięcia w sieci elektrycznej, przy którym pracuje maszyna elektryczna. System rejestruje jeden sygnał pochodzący od określonej maszyny, przy czym należy zminimalizować wpływ szumów. Inżynierowie mogą stosować stanowisko do wykrywania uszkodzeń i zabezpieczania silników.

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. Kinnunen T., Karpov E., Fränti P.: Real-Time Speaker Identification and Verification, IEEE Transactions on Audio, Speech, and Language Processing, Vol. 14, No. 1, Jan 2006, 277- 288.
7. Glowacz A., Glowacz 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.
8. Glowacz A., Glowacz 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.
9. Glowacz Z., Zdrojewski A.: Analiza spektralna sygnałów silnika komutowanego prądu stałego zasilanego ze źródła napięcia stałego, Przegląd Elektrotechniczny; 82 (2006) nr 11, 76-79.
10. Sutowski P.: Wykorzystanie wartości skutecznej sygnału emisji akustycznej oraz metod sztucznej inteligencji do oceny zużycia ściernicy, Pomiary Automatyka Kontrola, vol. 55, 4/2009, 255-258.
11. Antal M., Antal L., Zawilak J.: Badania eksperymentalne silnika indukcyjnego z uszkodzoną klatką wirnika, Prace Naukowe Instytutu Maszyn, Napędów i Pomiarów Elektrycznych Politechniki Wrocławskiej; nr 59, Studia i Materiały, Oficyna Wydaw. PWroc., 2006, s. 69-77.
12. Kowalski C. T.: Monitorowanie i diagnostyka uszkodzeń silników indukcyjnych z wykorzystaniem sieci neuronowych, Wyd. Pol. Wrocławskiej, Monografie, t.57, nr 18, Wrocław, 2005.
13. Salat R., Osowski S., Siwek K.: Principal Component Analysis for feature selection at the diagnosis of electrical circuits, Przegląd Elektrotechniczny, 2003, No 10, pp. 667-670.
14. Pasko M., Walczak J.: Teoria Sygnałów, Wydawnictwo Politechniki Śląskiej, 2007.
15. Kowal M., Korbicz J.: Robust fault detection using neuro-fuzzy models, Przegląd Elektrotechniczny, 2006, No 1, pp. 32-36.
16. 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.