

Adam Głowacz, Witold Głowacz, Zygfryd Głowacz
Akademia Górniczo-Hutnicza w Krakowie

DIAGNOSTYKA SILNIKA SYNCHRONICZNEGO OPARTA NA ANALIZIE SYGNAŁÓW AKUSTYCZNYCH Z ZASTOSOWANIEM MFCC I GSDM

DIAGNOSTICS OF SYNCHRONOUS MOTOR BASED ON ANALYSIS OF ACOUSTIC SIGNALS WITH APPLICATION OF MFCC AND GSDM

Abstract: The paper presents method of diagnostics of imminent failure conditions of synchronous motor. This method is based on a study of acoustic signals generated by synchronous motor. Sound recognition system is based on data processing algorithms, such as MFCC and GSDM. Software to recognize the sounds of synchronous motor was implemented. The studies were carried out for four imminent failure conditions of synchronous motor. The results confirm that the system can be useful for detecting damage and protect the motors.

1. Wstęp

Zdolność wydobywcza kopalń w dużym stopniu uzależniona jest od możliwości przewozu urobku z pól wydobywczych do szybów. Rozwój lokomotyw i maszyn elektrycznych pozwolił na wzrost wydobywania w kopalniach oraz prowadzenie eksploatacji pokładów węgla znacznie oddalonych od szybów wydobywczych [1]. Przykładowo przeciętna kopalnia, eksploatuje jednocześnie wiele maszyn elektrycznych. Konserwacja i remont tak licznego zespołu maszyn powoduje wiele kłopotów, jeśli nie potrafimy właściwie przewidzieć terminu remontu. Do tego celu przydatna jest diagnostyka. Stanem awaryjnym układu nazywamy niezamierzony stan pracy, który wywołuje niepożądane skutki z punktu widzenia prawidłowości jego funkcjonowania.

Stanem przedawaryjnym nazywamy stan pracy, w którym pojawiają się symptomy zjawisk charakterystycznych dla stanu awaryjnego (zagięcia, zarysowania, zwarcia obwodów elektrycznych, przerwy w obwodach elektrycznych). W literaturze metody badania stanów przedawaryjnych maszyn elektrycznych 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 literaturze popularne są metody oparte na badaniu sygnałów elektrycznych [1÷4]. W ostatnich latach powstały również metody

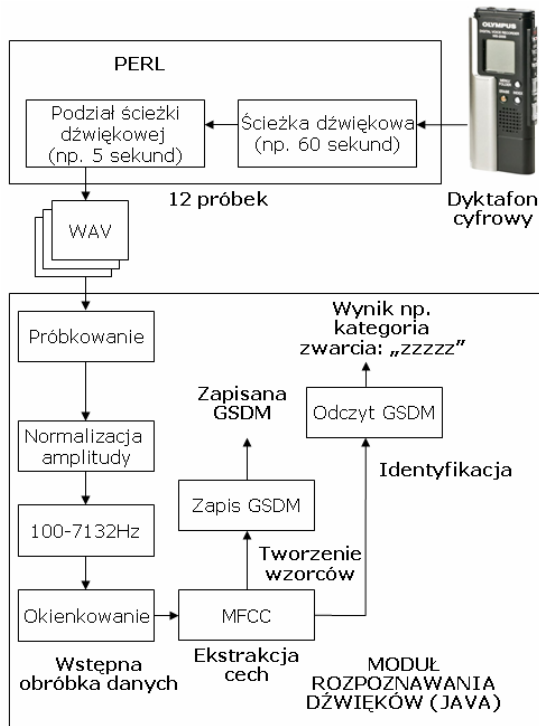
badania sygnałów akustycznych [5÷10]. Stąd pomysł aby zastosować te metody do maszyn elektrycznych [11÷13]. Rozważania prowadzone w artykule dotyczą silnika synchronicznego generującego sygnały akustyczne. Wykonane badania mogą posłużyć do dalszego stosowania diagnostyki opartej na emisji akustycznej w maszynach elektrycznych, mechanicznych i hydraulicznych. Pomiary zostały wykonane dyktafonem OLYMPUS WS-200S.

2. Przepływ danych w procesie rozpoznawania dźwięku silnika synchronicznego

Proces rozpoznawania dźwięku składa się z procesu tworzenia wzorców do rozpoznawania (zapis GSDM) i procesu identyfikacji (odczytu GSDM). Na początku procesu tworzenia wzorców do rozpoznawania wykonywane jest próbkowanie, normalizacja amplitudy i filtracja [14]. Następnie stosowane jest okienkowanie z zastosowaniem okna Hamminga (okno o rozmiarze 256). W kolejnym kroku dane są zamieniane przez algorytm MFCC. Następnie z otrzymanych współczynników filtra liniowej predykcji tworzony jest wektor cech (4 cechy). Wektory cech są używane do zapisu pamięci GSDM.

W procesie identyfikacji etapy przetwarzania sygnału akustycznego są takie same jak dla procesu tworzenia wzorców do rozpoznawania. Istotna zmiana następuje w etapie klasyfikacji, gdzie zamiast zapisu pamięci GSDM następuje jej odczyt, który prowadzi do określenia kategorii dźwięku. Przepływ danych w systemie do badania sygnałów akustycznych silnika został

przedstawiony na schemacie blokowym (rys. 1).

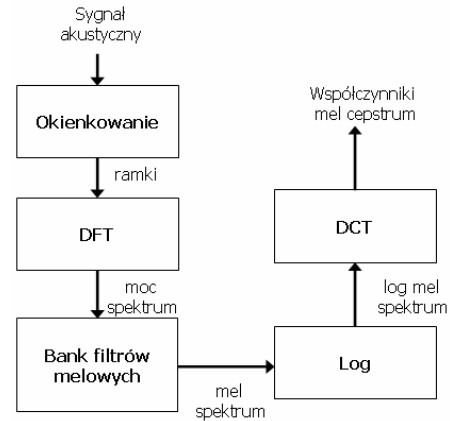


Rys. 1. Proces tworzenia wzorców do rozpoznawania i procesu identyfikacji z zastosowaniem MFCC i GSDM


2.1. Parametryzacja MFCC

Metoda MFCC (ang. Mel-frequency cepstral coefficients) odznacza się wysoką skutecznością w rozpoznawaniu mowy człowieka. Ponadto w literaturze wielu autorów stosowało metodę MFCC do rozpoznawania tożsamości mówcy. W systemie rozpoznawania dźwięku silnika synchronicznego zaimplementowano metodę MFCC. Metoda MFCC charakteryzuje się zadowalającą skutecznością przy umiarkowanej złożoności obliczeniowej. Na rysunku 2 przedstawiono schemat parametryzacji MFCC.

Parametryzacja MFCC zawiera elementy modelowania własności percepcyjnych słuchu ludzkiego takie, jak zaniedbanie informacji o widmie fazowym, nieliniowa skala częstotliwości, uśrednianie mocy sygnału w pasmach oraz nieliniowa reakcja na poziom mocy sygnału. Obliczenie mocy FFT następuje w określonych pasmach częstotliwościowych. Częstotliwości środkowe w tych pasmach są równomiernie rozmieszczone względem melowej skali częstotliwościowej.




Rys. 2. Schemat parametryzacji MFCC



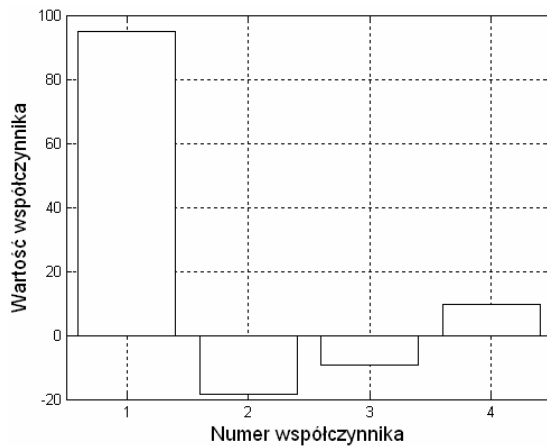
Rys. 3. Bank filtrów melowych MFCC-FB40

Szerokość pasma jest powiązana z rozmieszczeniem częstotliwości środkowych. Pasma częstotliwości filtrów zachodzą na siebie na połowie swej długości. Obecnie istnieją różne metody MFCC, np. MFCC FB-20, MFCC FB-40, MFCC FB-24 HTK. W systemie rozpoznawania dźwięków silnika zastosowano metodę MFCC FB-40. Dla metody MFCC FB-40 liczba filtrów melowych wynosi 40. Filtry te pokrywają pasmo częstotliwości od 133 Hz do 6854 Hz (rys. 3). Pierwsze 13 filtrów leży w przedziale częstotliwości od 200 Hz do 1000 Hz co 66,67 Hz. Kolejne 27 filtrów są rozmieszczone logarytmicznie w zakresie od 1071 Hz do 6400 Hz [15÷18].


W systemie rozpoznawania dźwięku silnika przyjęto, że liczba współczynników MFCC wynosi $M = 4$. Podczas stosowania metody MFCC otrzymywane były melowe współczynniki cepstralne. Kolejne wartości melowych współczynników cepstralnych dla czterech różnych dźwięków silnika synchronicznego zostały pokazane na rysunkach 4,5,6,7.




Rys.4. Cztery kolejne wartości melowych współczynników cepstralnych przy zastosowaniu filtracji 100-7132 Hz dla silnika synchronicznego bez uszkodzeń



Rys.5. Cztery kolejne wartości melowych współczynników cepstralnych przy zastosowaniu filtracji 100-7132 Hz dla silnika synchronicznego ze zwartymi zezwojami stojana



Rys.6. Cztery kolejne wartości melowych współczynników cepstralnych przy zastosowaniu filtracji 100-7132 Hz dla silnika synchronicznego z jedną przerwą w uzwojeniu jednej fazy stojana



Rys.7. Cztery kolejne wartości melowych współczynników cepstralnych przy zastosowaniu filtracji 100-7132 Hz dla silnika synchronicznego z trzema przerwami w uzwojeniach trzech faz stojana

Współczynniki te kolejno tworzyły wektor cech odpowiedni dla danej kategorii dźwięku. Następnie wektor cech przetwarzany jest przez algorytm GSDM.

2.2. Klasyfikator GSDM

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.

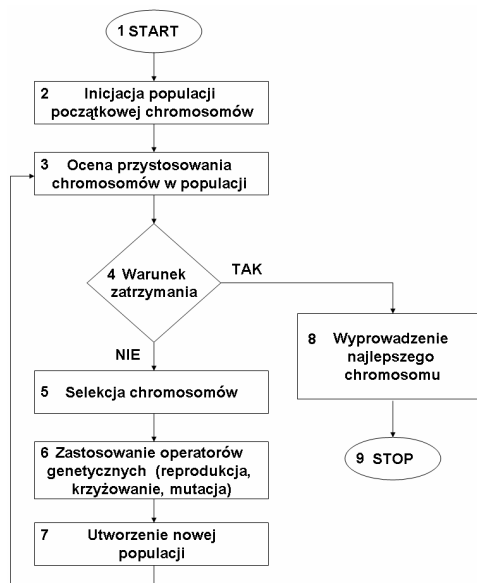
W przypadku błędnego odtworzenia system może dawać na wyjściu wzorec inny niż y^p .

W pamięci GSDM czytanie danych przebiega tak samo jak w SDM. Inaczej pamięci działają podczas zapisu. Pamięć GSDM stosuje algorytm genetyczny (rys. 8). Algorytm ten różni się od klasycznego algorytmu genetycznego. Różnica polega na stosowaniu operatora genetycznego do różnych przypadków.

Pamięć GSDM ma określoną liczbę komórek pamięci z N pustymi adresami i ich zawartościami. Adres p^k pary treningowej (p^k, d^k) jest wysyłany do odpowiednich komórek pamięci skalkulowanych przez odległość Hamminga. Po wyznaczeniu wartości elementów wektora selekcji s mogą zajść trzy przypadki:

- 1) Liczba zaznaczonych komórek pamięci w s jest równa 0 (wszystkie elementy wektora selekcji mają wartość równą 0): wzorzec p jest reprodukowany jako adres kandydata. Potem mała liczba losowych bitów adresu kandydata jest wybierana i zmieniana przez operację mutacji. Tak wygenerowany adres jest dodawany do tablicy adresów A , jeżeli istnieje w niej pusty adres, w przeciwnym razie jest odrzucany.
- 2) Liczba zaznaczonych komórek pamięci w s jest większa od progu (pewna liczba elementów wektora selekcji ma wartość równą 1), zasada zapisu jest dokładnie taka sama jak w SDM.
- 3) Liczba zaznaczonych komórek pamięci w s jest większa od zera, a mniejsza od progu: oznacza to, że wybrane adresy są zbyt małe do opisu oryginalnych danych. Nowy adres powinien zostać dodany do pamięci. Dodanie nowego adresu do pamięci w tym przypadku staje się możliwe przez operator krzyżowania. Pierwsze dwa adresy, które mają najmniejszą odległość z p^k , są kojarzone przez operator krzyżowania. Następnie generowana jest przypadkowa liczba całkowita będąca punktem krzyżowania. Prefiks jednego adresu jest dołączony z przyrostkiem drugiego adresu w miejscu punktu krzyżowania. Wygenerowany zmieniony adres będzie dodany do tablicy adresu [19], [20].

Klasyfikator oparty na GSDM wykonywać będzie najpierw operacje zapisu GSDM (proces tworzenia wzorców do rozpoznawania). W procesie tym kolejne wektory cech będą zapisywane do pamięci. Następnie wykonywany będzie odczyt pamięci (proces identyfikacji). Przewiduje się dobierać parametry pamięci GSDM w celu uzyskania jak najlepszych wyników rozpoznawania dźwięku.



Rys.8. Schemat blokowy algorytmu genetycznego użytego w pamięci GSDM

3. Wyniki rozpoznawania dźwięków

Maszyna synchroniczna pracowała jako silnik synchroniczny. Zwarcie i przerwy wykonano w obwodzie stojana (rys. 9). 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). Parametry silnika synchronicznego były następujące:

-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).

Proces tworzenia wzorców do rozpoznawania przeprowadzony został dla dziesięciu próbek pięciosekundowych dla każdej z czterech kategorii dźwięku.



Rys. 9. Schemat uzwojeń stojana dla silnika synchronicznego z jedną przerwą w uzwojeniu jednej fazy stojana (X1-X4)

Do identyfikacji stosowano dziesięć nowych próbek o długości 5 sekund. Skuteczność rozpoznawania dźwięku była określona następująco:

$$E = \frac{N_1}{N} \quad (1)$$

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

Parametry pamięci GSDM wynosiły odpowiednio: dokładność rozpoznanych próbek =0.95, liczba iteracji w algorytmie genetycznym =100, współczynnik mutacji w algorytmie genetycznym =0.01, próg odległości Hamminga =25, liczba znaków kategorii dźwięku =5, rozmiar pamięci GSDM =1000. Wymienione parametry miały duży wpływ na rozpoznawanie dźwięku.

Skuteczność rozpoznawania dźwięku wynosiła 90% dla dźwięku silnika synchronicznego bez uszkodzeń. Skuteczność rozpoznawania dźwięku wynosiła 60% dla dźwięku silnika synchronicznego ze zwartymi zezwojami stojana. Skuteczność rozpoznawania dźwięku wynosiła 50% dla dźwięku silnika synchronicznego z jedną przerwą w uzwojeniu jednej fazy stojana. Skuteczność rozpoznawania dźwięku wynosiła 90% dla dźwięku silnika synchronicznego z trzema przerwami w uzwojeniach trzech faz stojana.

4. Podsumowanie

System rozpoznawania dźwięku został zaprojektowany i zaimplementowany dla silnika synchronicznego. Otrzymano dobre wyniki dla algorytmu MFCC i klasyfikatora GSDM. Zastosowano filtrację w zakresie od 100 Hz do 7134 Hz. Skuteczność rozpoznawania dźwięku wynosiła od 50% do 90% dla próbek o długości 5

sekund. System może być przydatny do wykrywania uszkodzeń i zabezpieczania silników. W przyszłości system rozpoznawania dźwięku silnika synchronicznego można wyposażyć w inne skuteczne algorytmy przetwarzania danych.

Literatura

- [1]. Głowacz Z., Zdrojewski A.: *Analiza spektralna sygnałów silnika komutatorowego prądu stałego zasilanego ze źródła napięcia stałego*, Przegląd Elektrotechniczny; 82 (2006) nr 11, 76–79.
- [2]. 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.
- [3]. Kowalski C. T.: *Monitorowanie i diagnostyka uszkodzeń silników indukcyjnych z wykorzystaniem sieci neuronowych*, Wyd. Pol. Wrocławskiej, Monografie, t. 57, nr 18, Wrocław, 2005.
- [4]. Sałat 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.
- [5]. 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.
- [6]. 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.
- [7]. Lee K.: *Effective Approaches to Extract Features and Classify Echoes in Long Ultrasound Signals from Metal Shafts*, Ph. D. dissertation, Brisbane, Australia, 2006.
- [8]. The MARF Development Group, *Modular Audio Recognition Framework v.0.3.0-devel-20050606 and its Applications*, Application note, Montreal, Quebec, Canada, 2005.
- [9]. 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.
- [10]. 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.
- [11]. 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.
- [12]. Głowacz A., Głowacz W.: *Sound recognition of dc machine with application of FFT and back-*

propagation neural network, Przegląd Elektrotechniczny (Electrical Review), R. 84, NR 9/2008, pp.159-162.

[13]. 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.

[14]. Pasko M., Walczak J.: *Teoria Sygnałów*, Wydawnictwo Politechniki Śląskiej, 2007.

[15]. Mrówka P., *Algorytmy kompensacji warunków transmisyjnych i cech osobniczych mówcy w systemach automatycznego rozpoznawania mowy*. Rozprawa Doktorska, Politechnika Wroclawska, Wrocław 2007.

[16]. Ganchev T., Fakotakis N., Kokkinakis G., *Comparative evaluation of various MFCC implementations on the speaker verification task*. Proceedings of 10th International Conference on Speech and Computer (SPECOM 2005), Vol. 1, pp. 191–194.

[17]. Sigurdsson S., Brandt Petersen K., Lehn-Schiøler T., *Mel Frequency Cepstral Coefficients: An Evaluation of Robustness of MP3 Encoded Music*. Proceedings of ISMIR 2006, 7th International Conference on Music Information Retrieval, Victoria, Canada, 8-12 October 2006.

[18]. Slaney M. *Auditory Toolbox. Version 2*, Technical Report #1998-010, Interval Research Corporation, 1998.

[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.

Autorzy

Mgr inż., Adam Głowacz, doktorant, Akademia Górniczo-Hutnicza, al. Mickiewicza 30, 30-059 Kraków, adglow@agh.edu.pl

Mgr inż., Witold Głowacz, doktorant, Akademia Górniczo-Hutnicza, al. Mickiewicza 30, 30-059 Kraków, wglowacz@agh.edu.pl

Dr hab. inż., Zygfryd Głowacz, profesor nadzwyczajny, Akademia Górniczo-Hutnicza, al. Mickiewicza 30, 30-059 Kraków, glowacz@agh.edu.pl

Recenzent

Prof. dr hab. inż. Jan Zawilak