

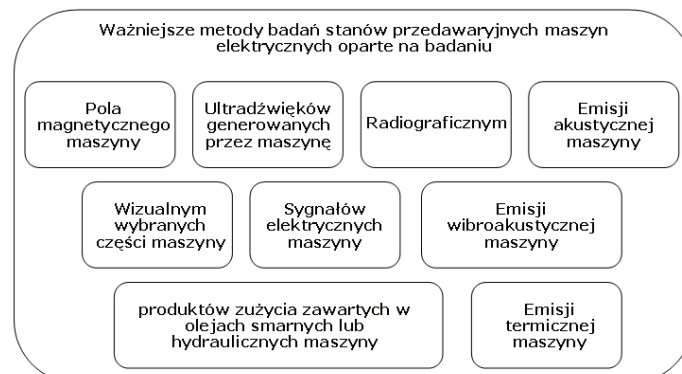
Diagnostyka silnika synchronicznego oparta na analizie sygnałów akustycznych z zastosowaniem MFCC i klasyfikatora rozmytego

Zaprezentowano metodę diagnozowania stanów przedawaryjnych silnika synchronicznego. Metoda ta oparta jest na badaniu sygnałów akustycznych generowanych przez silnik synchroniczny. System rozpoznawania dźwięku oparty jest na algorytmach przetwarzania danych, takich jak algorytm MFCC i klasyfikator rozmyty z trójkątną funkcją przynależności. Zaimplementowano oprogramowanie do rozpoznawania dźwięków silnika synchronicznego. Przeprowadzono badania dla czterech stanów przedawaryjnych silnika synchronicznego. Wyniki badań potwierdzają, że system może być przydatny do wykrywania uszkodzeń i zabezpieczania silników.

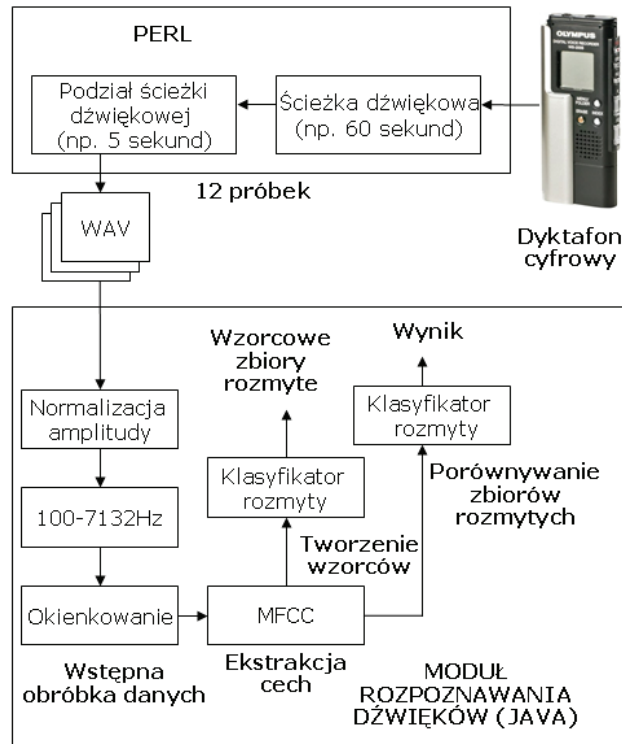
1. WSTĘP

Diagnostyka techniczna zajmuje się oceną stanu technicznego maszyny poprzez badanie własności procesów roboczych i towarzyszących pracy maszyny, a także poprzez badanie własności wytworów maszyny. Diagnostyka jest szczególnie ważna dla przemysłu wydobywczego i przetwórczego. 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 to duża liczba 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 licznego 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. Metody badania stanów przedawaryjnych maszyn elektrycznych zostały pokazane na rysunku 1.



Rys. 1. Ważniejsze metody badań stanów przedawaryjnych maszyn elektrycznych



Rys. 2. Proces tworzenia wzorców do rozpoznawania i proces identyfikacji z zastosowaniem MFCC i klasyfikatora rozmytego z trójkątną funkcją przynależności

W literaturze popularne są metody oparte na badaniu sygnałów elektrycznych [1-4]. W ostatnich latach powstały również metody do badania sygnałów akustycznych [5-6]. Stąd pomysł, aby zastosować je dla maszyn elektrycznych i innych urządzeń [7, 8]. Rozważania prowadzone w artykule dotyczą wybranego silnika synchronicznego generującego sygnały akustyczne. Badania te mogą posłużyć do dalszego stosowania diagnostyki opartej na emisji akustycznej w maszynach elektrycznych, mechanicznych, hydraulicznych, pneumatycznych. Pomiary zostały wykonane dyktafonem OLYMPUS WS-200S.

2. PRZEPIŃY DANYCH W PROCESIE ROZPOZNAWANIA DŹWIĘKU

Proces rozpoznawania dźwięku silnika synchronicznego składa się z procesu tworzenia wzorców do rozpoznawania i procesu identyfikacji. Na początku procesu tworzenia wzorców do rozpoznawania wykonywana jest normalizacja amplitudy i filtracja cyfrowa [9].

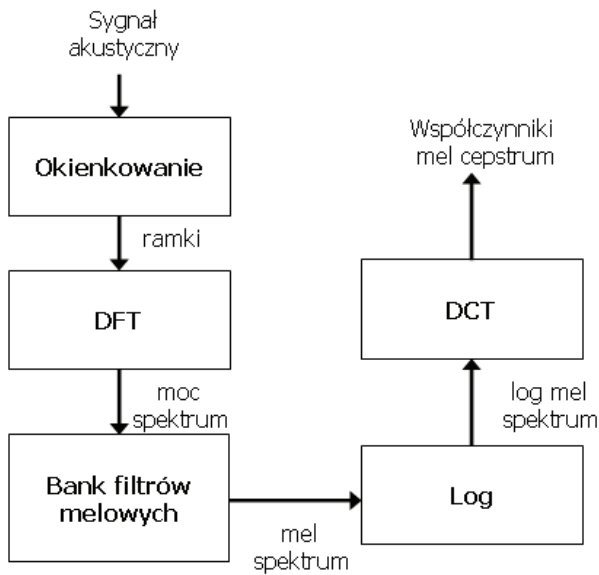
Następnie stosowane jest okienkowanie z zastosowaniem okna Hamminga – okno o rozmiarze 256. W kolejnym kroku dane są zamieniane przez algorytm MFCC. Następnie z tak otrzymanych cech

tworzony jest wzorcowy wektor cech danej kategorii (75 cech). Wzorcowy wektor cech powstaje przez uśrednienie cech określonej grupy próbek dźwięku. Kolejno tworzone są wzorcowe zbiory rozmyte. Zbiory rozmyte są tworzone z zastosowaniem trójkątnej funkcji przynależności.

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 zbiory rozmyte (wzorcowe zbiory rozmyte z nieznanymi zbiorami rozmytymi nowej próbki dźwięku).

3. PARAMETRIZACJA MFCC

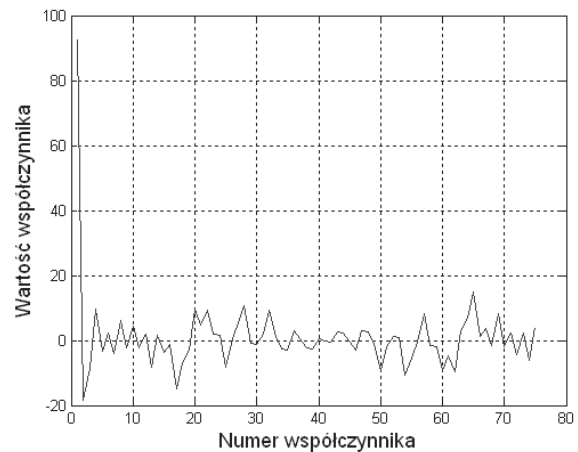
Metoda MFCC (ang. *Mel-frequency cepstral coefficients*) odznacza się wysoką skutecznością w rozpoznawaniu mowy człowieka. Ponadto w literaturze wielu autorów stosowało metodę MFCC do rozpoznawania tożsamości mówcy. W systemie rozpoznawania dźwięku silnika synchronicznego zaimplementowano metodę MFCC. Metoda MFCC charakteryzuje się zadowalającą skutecznością przy umiarkowanej złożoności obliczeniowej. Na rysunku 3 przedstawiono schemat parametryzacji MFCC.



Rys. 3. 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. Szerokość pasma jest powiązana z rozmieszczeniem częstotliwości środkowych. Pasma częstotliwości filtrów zachodzą na siebie na połowie swej długości. Obecnie istnieją różne metody MFCC, takie jak: MFCC FB-20, MFCC FB-40, MFCC FB-24 HTK. W systemie rozpoznawania dźwięków silnika synchronicznego 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. 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 1071 Hz do 6400 Hz [10-13]. W systemie rozpoznawania dźwięku silnika synchronicznego przyjęto, że liczba współczynników MFCC wynosi $M = 75$.


Z zastosowaniem metody MFCC zostały wyznaczone melowe współczynniki cepstralne dla każdej z czterech kategorii. Współczynniki te tworzyły wektory cech. Następnie z wektorów cech tworzone były zbiory rozmyte. Możliwe to było dzięki zastosowaniu trójkątnych funkcji przynależności. Wartości melowych współczynników cepstralnych dla dźwięku silnika synchronicznego bez uszkodzeń zostały pokazane na rysunku 4.



Rys. 4. Kolejne wartości melowych współczynników cepstralnych dla próbek dźwięku o długości pięć sekund dla silnika synchronicznego bez uszkodzeń (zastosowano normalizację amplitudy i filtr cyfrowy przepuszczający częstotliwości od 100 Hz do 7132 Hz)

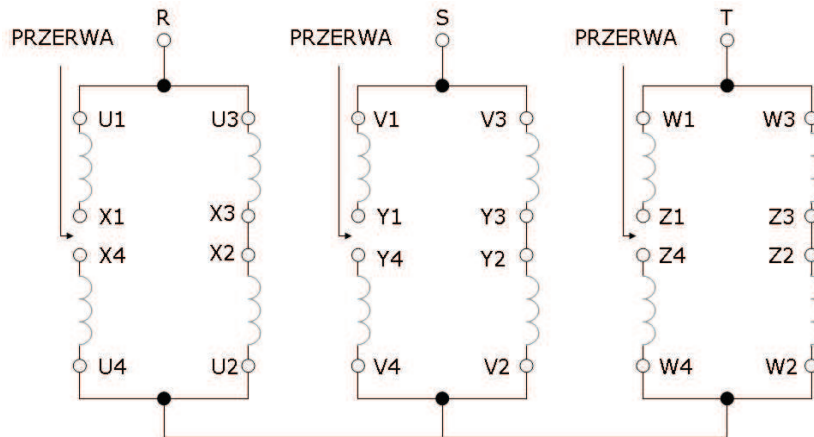
4. KLASYFIKATOR ROZMYTY Z TRÓJKĄTNĄ FUNKCJĄ PRZYNALEŻNOŚCI

Klasyfikator rozmyty jest to klasyfikator używający logiki rozmytej lub zbiorów rozmytych w swoich operacjach. Klasyfikator rozmyty z trójkątną funkcją przynależności podejmuje decyzje dotyczące zakwalifikowania badanego sygnału akustycznego do danej kategorii. Porównywane są różne zbiory rozmyte ze sobą. W aplikacji zostało zastosowanych 260 trójkątnych funkcji przynależności (rys. 5). Zauważyć można, że kształt funkcji przynależności nie będzie miał dużego wpływu na rozpoznawanie dźwięku.



Rys. 5. Trójkątna funkcja przynależności

Podstawa trójkąta tworzącego funkcję przynależności będzie parametrem, który będzie trzeba dobrać w zależności od wektora cech. W procesie identyfikacji porównywane są ze sobą zbiory rozmyte (grupa nowych zbiorów rozmytych z grupą wzorcowych zbiorów).



Rys. 6. Schemat uzwojeń stojana dla silnika synchronicznego z trzema przerwami w uzwojeniach trzech faz stojana (X1-X4, Y1-Y4, Z1-Z4)

rów rozmytych). Większa liczba wspólnych zbiorów rozmytych określać będzie właściwą kategorię [14,15]. Trójkątna funkcja przynależności $p(x)$ jest określona następującym wzorem:

$$p(x) = \begin{cases} 0 & x < a_1 \\ \frac{x - a_1}{a_2 - a_1} & a_1 \leq x < a_2 \\ \frac{a_3 - x}{a_3 - a_2} & a_2 \leq x < a_3 \\ 0 & x \geq a_3 \end{cases} \quad (1)$$

5. WYNIKI ROZPOZNAWANIA DŹWIĘKÓW

Maszyna synchroniczna pracowała jako silnik synchroniczny. Zwarcie i przerwy zlokalizowane zostały w obwodzie stojana (rys. 6). 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). 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 zewzwojami 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 pięciosiekundowych 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:

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

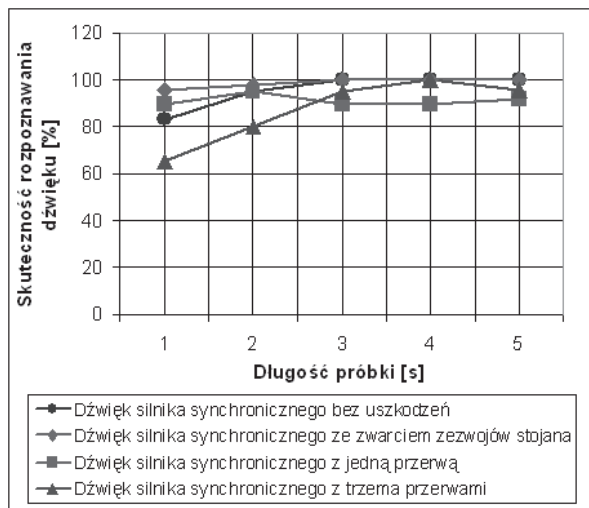
gdzie:

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

Największy wpływ na rozpoznawanie dźwięku klasyfikatorem rozmytym miały dane zawarte w wektorze cech – uśrednione melowe współczynniki cepstralne i parametr trójkątnej funkcji przynależności. Parametr trójkątnej funkcji przynależności wynosił $P=0.5$. Skuteczność rozpoznawania dźwięku w zależności od rodzaju sygnału akustycznego i długości próbki została przedstawiona na rysunku 7.

6. PODSUMOWANIE

System rozpoznawania dźwięku został zaprojektowany i zaimplementowany dla silnika synchronicznego. Otrzymano bardzo dobre wyniki dla algorytmu



Rys. 7. Skuteczność rozpoznawania dźwięku silnika synchronicznego w zależności od rodzaju sygnału akustycznego i długości próbki (zastosowano filtr cyfrowy przepuszczający częstotliwości od 100 Hz do 7132 Hz, MFCC i klasyfikator rozmyty z trójkątną funkcją przynależności)

MFCC i klasyfikatora rozmytego z trójkątną funkcją przynależności. Zastosowano filtr pasmowoprzepustowy w zakresie częstotliwości od 100 Hz do 7134 Hz. Skuteczność rozpoznawania dźwięku wynosiła od 65% do 100% dla próbek o długości 1-5 sekund. Skuteczność rozpoznawania dźwięku dla próbek o długości 4 sekund była najlepsza i wynosiła od 90% do 100%. Na procesorze Pentium M 730 czas identyfikacji jednej pięciosekundowej próbki z zastosowaniem normalizacji, okienkowania, filtracji cyfrowej od 100 Hz do 7132 Hz, MFCC i klasyfikatora rozmytego z trójkątną funkcją przynależności wyniósł 5,891 sekundy. Dla próbki jednosekundowej czas ten wyniósł 2,172 sekundy. 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. 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.

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. 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.
7. 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.
8. Sutowski P.: Wykorzystanie wartości skutecznej sygnału emisji akustycznej oraz metod sztucznej inteligencji do oceny zużycia sciernicy. *Pomiary Automatyka Kontrola*, Vol. 55, 4/2009, 255-258.
9. Pasko M., Walczak J.: *Teoria Sygnałów*. Wydawnictwo Politechniki Śląskiej, 2007.
10. Mrówka P.: Algorytmy kompensacji warunków transmisyjnych i cech osobniczych mówcy w systemach automatycznego rozpoznawania mowy. *Rozprawa Doktorska, Politechnika Wrocławska, Wrocław 2007*.
11. 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.
12. Sigurdsson S., Brandt Petersen K., Lehn-Schioler 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*.
13. Slaney M. "Auditory Toolbox. Version 2", Technical Report #1998-010, Interval Research Corporation, 1998.
14. Szabat K., Orłowska-Kowalska T.: Adjustment of classical and fuzzy logic speed controllers for electrical drives with elastic joint. *Proceedings of XVI International Conference on Electrical Machines (ICEM 2004)*, Cracow, 2004.
15. Kosanovic B. R., Chaparro L. F., Scabassi R. J.: Signal Analysis in Fuzzy Information Space, *Fuzzy Sets and Systems*, Vol. 77, pp. 49-62, 1996.

Recenzent: dr inż. Adam Heyduk