

Diagnostyka silnika indukcyjnego oparta na analizie sygnałów akustycznych z użyciem dyskretnej transformaty falkowej Haara i klasyfikatora najbliższej średniej z metryką Euklidesa

W artykule zaproponowana została nieinwazyjna metoda diagnostyki stanów przedawaryjnych silnika indukcyjnego. Zastosowana metoda oparta jest na analizie sygnałów akustycznych silnika indukcyjnego. Przedstawiono badania dla trzech stanów silnika indukcyjnego, które zostały przeprowadzone dla algorytmów przetwarzania danych: dyskretnej transformaty falkowej Haara i klasyfikatora najbliższej średniej z metryką Euklidesa. Opisano proces tworzenia wzorców do rozpoznawania, który został przeprowadzony dla 27 próbek dźwięku, oraz proces identyfikacji, przeprowadzony dla 75 próbek dźwięku. Podkreślono, że metoda ta może być zastosowana w różnych gałęziach przemysłu.

1. WPROWADZENIE

Wpływ uszkodzenia prętów klatki wirnika na prace silnika indukcyjnego jest znany i opisywany w literaturze. Warto w tym kontekście zaznaczyć, że silnik indukcyjny z uszkodzonymi prętami klatki wirnika może nadal funkcjonować. Własność ta jest jedną z zalet silników indukcyjnych, która przekłada się na ich szerokie zastosowanie. Do najważniejszych wielkości, na które wpływa uszkodzenie klatki, należą: czas rozruchu, moment, prąd stojana, prąd wirnika oraz naciąg magnetyczny. Badania maszyn indukcyjnych potwierdzają wydłużanie się czasu rozruchu w przypadku silników z uszkodzonymi kłatkami wirnika. Ma to znaczenie w silnikach o większej mocy, których rozruch jest poważnym obciążeniem dla samego wirnika, i właśnie podczas rozruchu najczęściej dochodzi do uszkodzenia tego elementu urządzenia. Uszkodzenie zazwyczaj powoduje zmiany widoczne w widmie częstotliwościowym. Zmienia się również rozkład prądów wirnika. Wyraźnie wrażliwymi są wartości prądów w prętach sąsiadujących z prę-

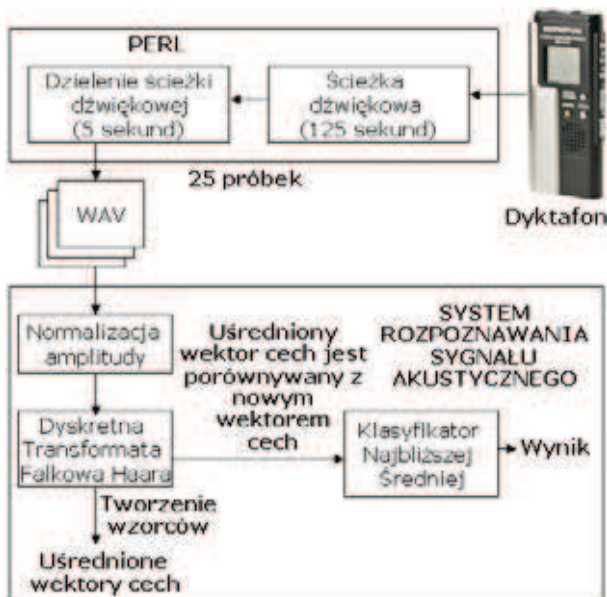
tem uszkodzonym, co powoduje ich większe obciążenie i wzrost temperatury. Uszkodzenie wirnika przyczynia się do zwiększenia temperatury uzwojeń stojana, zwiększenia strat, wzrostu poziomu drgań i hałasu oraz obniżenia współczynnika sprawności. Przy diagnostyce klatki wirnika istotna jest świadomość, że nawet jeden uszkodzony pręt może doprowadzić do uszkodzenia stojana. Innym ważnym aspektem używania nie w pełni działającego silnika jest to, że maszyna ma mniejszą sprawność [8].

W artykule zaprezentowano metodę diagnostyki wybranego silnika indukcyjnego wytwarzającego sygnały akustyczne. Eksperymenty takie mogą być wykorzystane w dalszej diagnostyce opartej na emisji akustycznej w silnikach indukcyjnych i sprzęcie elektrycznym [5, 9].

2. PROCES ROZPOZNAWANIA SYGNAŁU AKUSTYCZNEGO SILNIKA INDUKCYJNEGO

Proces rozpoznawania sygnału akustycznego silnika indukcyjnego składa się z procesu tworzenia

wzorców do rozpoznawania i procesu identyfikacji. Na początku procesu tworzenia wzorców do rozpoznawania wykonywana jest normalizacja amplitudy [12]. W kolejnym kroku dane są zamieniane przez algorytm dyskretnej transformaty falkowej Haara. Następnie z tak otrzymanych cech tworzony jest wektor cech danej kategorii (862 cech). Kolejno wektory danej kategorii są uśredniane, w wyniku czego powstaje uśredniony wektor cech. W procesie identyfikacji etapy przetwarzania sygnału akustycznego są takie same jak dla procesu tworzenia wzorców do rozpoznawania. Istotna zmiana polega na dodaniu etapu klasyfikacji (rys. 1), w którym porównywane są ze sobą wektory cech (wzorcowy uśredniony wektor cech z nieznanym wektorem nowej próbki dźwięku). W tym celu stosowana jest metryka Euklidesa.




Rys. 1. Proces rozpoznawania sygnału akustycznego silnika indukcyjnego z użyciem dyskretnej transformaty falkowej Haara i klasyfikatora najbliższej średniej [8]

3. DYSKRETNA TRANSFORMATA FALKOWA HAARA

Analiza falkowa polega na dekompozycji sygnału przy użyciu falek otrzymanych poprzez przesunięcie i skalowanie falki podstawowej (mother wavelet). Dla $\psi: \mathbb{R} \rightarrow \mathbb{R}$ funkcja falki Haara zdefiniowana jest następująco (rys. 2):

$$\psi(t) = \begin{cases} 1 & \text{dla } t \in [0,0.5) \\ -1 & \text{dla } t \in [0.5,1) \\ 0 & \text{dla } t \notin [0,1) \end{cases} \quad (1)$$



Rys. 2. Falka Haara [8]

Jeżeli weźmie się pod uwagę założenie (1), każda ze zdefiniowanych funkcji Haara może zostać utworzona według następującego wzoru:

$$\psi_i^j(t) = \sqrt{2^j} \psi(2^j t - i) \quad (2)$$

gdzie $i = 0, 1, \dots, 2^j - 1$ oraz $j = 0, 1, \dots, \log_2 N - 1$.


Stała $\sqrt{2^j}$ jest wybierana w taki sposób, aby skalarne produkt $\langle \psi_i^j, \psi_i^j \rangle = 1$, $\psi_i^j \in L^2(\mathbb{R})$ [7].

Dla $\Phi: \mathbb{R} \rightarrow \mathbb{R}$, funkcja skalująca Haara jest zdefiniowana przez wzór:

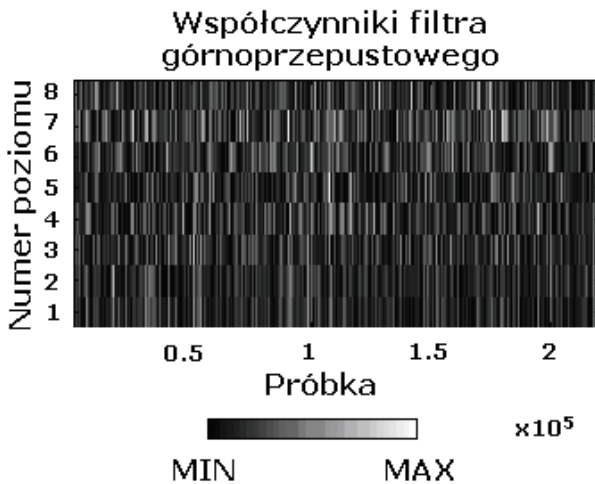
$$\Phi(t) = \begin{cases} 1 & \text{dla } t \in [0,1) \\ 0 & \text{dla } t \notin [0,1) \end{cases} \quad (3)$$

Dyskretna transformata falkowa oryginalnego sygnału jest liczona za pomocą serii dolnoprzepustowych i górnoprzepustowych filtrów.


Kolejno współczynniki ($\mathbf{d}_1, \mathbf{d}_2, \mathbf{d}_3, \dots, \mathbf{d}_n$) otrzymywane są z filtra górnoprzepustowego, a współczynniki ($\mathbf{a}_1, \mathbf{a}_2, \mathbf{a}_3, \dots, \mathbf{a}_n$) – z filtra dolnoprzepustowego, gdzie n oznacza poziom dekompozycji (rys. 3).



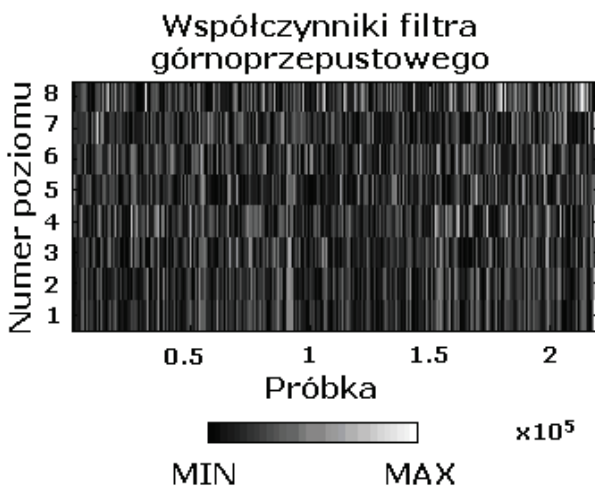
Rys. 3. Współczynniki dla ósmego poziomu dekompozycji [9]



Rys. 4. Współczynniki filtra górnoprzepustowego dla sygnału akustycznego silnika indukcyjnego bez uszkodzeń [9]



Rys. 5. Współczynniki filtra górnoprzepustowego dla sygnału akustycznego silnika indukcyjnego z jednym uszkodzonym prętem klatki wirnika [9]



Rys. 6. Współczynniki filtra górnoprzepustowego dla sygnału akustycznego silnika indukcyjnego z dwoma uszkodzonymi prętami klatki wirnika [9]

Wektory $\mathbf{d}_1, \dots, \mathbf{d}_n$ są ważne w procesie rozpoznawania sygnału akustycznego (rys. 4, 5 i 6). Ich wartości bezwzględne będą używane w dalszych obliczeniach.

4. KLASYFIKATOR NAJBLIŻSZEJ ŚREDNIEJ

W literaturze istnieje wiele metod klasyfikacji [1, 2, 3, 4, 6, 10, 11]. W algorytmie najbliższej średniej wzorcem klasy rozpoznawanych obiektów jest wartość średnia, podobnie jak w algorytmie najbliższego sąsiada obliczane są odległości wektora rozpoznawanego od wszystkich wektorów wzorcowych (wektorów średnich cech), a następnie wybierana jest najmniejsza z nich. Podstawowymi zaletami algorytmu najbliższej średniej w stosunku do algorytmu najbliższego sąsiada są: brak konieczności pamiętania wszystkich próbek ciągu uczącego oraz mniejsza liczba obliczeń.

Wzorcowy wektor cech określony jest następująco: $\mathbf{x} = [x_1, x_2, \dots, x_n]$. Klasy wzorców oznaczone są jako w_1, w_2, \dots, w_M , gdzie M jest numerem indeksu klasy. W procesie tworzenia wzorców otrzymywany jest ciąg uczący. Zawiera on uśrednione wektory cech $\mathbf{m}_1, \mathbf{m}_2, \dots, \mathbf{m}_j$ (4),

$$\mathbf{m}_j = \frac{1}{P_j} \sum_{i=1}^{P_j} \mathbf{x}_i \quad (4)$$

gdzie:

$\mathbf{x}_i \in w_j$, P_j jest liczbą wzorców z klasy w_j .

Zbiór identyfikacji zawiera nowe wektory cech $\mathbf{y}_1, \mathbf{y}_2, \dots, \mathbf{y}_j$. Kolejną najmniejszą odległość jest obliczana pomiędzy wektorami cech (wektor cech nowej próbki i uśredniony wektor cech danej kategorii). W celu obliczenia najmniejszej odległości zastosowana została metryka Euklidesowa. Dla wektorów \mathbf{y} i \mathbf{m} z takimi samymi długościami n zdefiniowana jest jako:

$$d_e(\mathbf{y}, \mathbf{m}) = \sqrt{\sum_{i=1}^n (y_i - m_i)^2} \quad (5)$$

gdzie:

\mathbf{y} i \mathbf{m} są wektorami cech o tych samych długościach, $\mathbf{y} = [y_1, y_2, \dots, y_n]$, $\mathbf{m} = [m_1, m_2, \dots, m_n]$.

5. WYNIKI ROZPOZNAWANIA SYGNAŁU AKUSTYCZNEGO SILNIKA INDUKCYJNEGO

Pomiary ciśnienia akustycznego zostały wykonane dyktafonem OLYMPUS WS-200S. Parametry pliku audio były następujące: częstotliwość próbkowania – 44100 Hz, liczba bitów – 16, liczba kanałów – 1. Analiza sygnałów została wykonana dla trzech identycznych silników indukcyjnych o mocy 500 W, przy czym jeden z nich był sprawny, a pozostałe zostały celowo uszkodzone. Kategorie rozpoznawanego sygnału akustycznego określono następująco:

- sygnał akustyczny silnika indukcyjnego bez uszkodzeń,
- sygnał akustyczny silnika indukcyjnego z jednym uszkodzonym prętem klatki wirnika,
- sygnał akustyczny silnika indukcyjnego z dwoma uszkodzonymi prętami klatki wirnika.

Proces tworzenia wzorców do rozpoznawania został wykonany dla 27 próbek pięciosekundowych dla każdej z trzech kategorii sygnału akustycznego. Do identyfikacji zastosowano nowe próbki o długości pięć sekund dla każdej z kategorii (w procesie identyfikacji zastosowanych zostało 75 próbek). Skuteczność rozpoznawania sygnału akustycznego została zdefiniowana następującym wzorem:

$$E = \frac{N_1}{N} \cdot 100\% \quad (6)$$

gdzie:

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

Najlepsze wyniki rozpoznawania sygnału akustycznego otrzymano dla współczynnika d_8 (862 cechy). Skuteczność rozpoznawania sygnału akustycznego dla silnika indukcyjnego bez uszkodzeń równała się 95%, dla silnika indukcyjnego z jednym uszkodzonym prętem klatki wirnika wynosiła 85%, a dla silnika indukcyjnego z dwoma uszkodzonymi prętami klatki wirnika – 60%.

6. PODSUMOWANIE

Wykonywanie diagnostyki, która zapobiega uszkodzeniom, jest korzystne z kilku powodów: koszty usług diagnostycznych są nieduże w porównaniu z kosztami energii elektrycznej zużywanej przez

silniki indukcyjne, koszty zabiegów diagnostycznych są mniejsze od kosztów remontów maszyn, zabiegi diagnostyczne zwiększają niezawodność działania urządzeń.

System rozpoznawania sygnału akustycznego został zaimplementowany dla silnika indukcyjnego. Wyniki rozpoznawania sygnału akustycznego były dobre w przypadku użycia dyskretnej transformaty falkowej Haara i klasyfikatora najbliższej średniej z metryką Euklidesa. Skuteczność rozpoznawania sygnału akustycznego wahała się od 60-95%.

Przeprowadzone badania potwierdzają skuteczność proponowanej metody diagnostyki, opartej na sygnałach akustycznych. Metoda ta może być zastosowana w różnych gałęziach przemysłu.

Praca została sfinansowana ze środków AGH – umowa AGH nr 11.11.120.612 (Adam Głowacz).

Literatura

1. Glavas Z., Unikic F., Lisjak D.: *The Prediction of the Microstructure Constituents of Spheroidal Graphite Cast Iron by Using Thermal Analysis and Artificial Neural Networks*, „Archives of Metallurgy and Materials”, vol. 55, issue 1/2010, pp. 213-220.
2. Głowacz A.: *Diagnostics of dc machine based on sound recognition with application of FFT and Jacquard distance*, „Przegląd Elektrotechniczny”, cz. 86, nr 4, 2010, s. 292-295.
3. Głowacz Z., Kozik J.: *Selekcja symptomów zwarć uzwojeń twornika silnika synchronicznego z wykorzystaniem algorytmu genetycznego i odległości Mahalanobisa*, „Przegląd Elektrotechniczny”, cz. 88, nr 2, 2012, s. 204-207.
4. Gomółka Z., Kwiatkowski B., Pękala R.: *Bezinwazyjna diagnostyka uzwojeń magnesujących przy użyciu sztucznych sieci neuronowych*, „Przegląd Elektrotechniczny”, cz. 87, nr 8, 2011, s. 66-69.
5. Gutten M., Jurcik J., Brandt, Polansky R.: *Mechanical effects of short-circuit currents analysis on autotransformer windings*, „Przegląd Elektrotechniczny”, cz. 87, nr 7, 2011, s. 272-275.
6. Pietrowski W.: *Application of Radial Basis Neural Network to diagnostics of induction motor stator faults using axial flux*, „Przegląd Elektrotechniczny”, cz. 87, nr 6, 2011, s. 190-192.
7. Porwik P., Lisowska A.: *The Haar-Wavelet Transform in digital image processing: its status and achievements*, „Machine Graphics and Vision”, vol. 13, issue 1/2004, pp. 79-98.
8. Rad M.: *Diagnostyka wirnika maszyn indukcyjnych z wykorzystaniem analizy falkowej i układów uczących się*, Rozprawa doktorska, Akademia Górniczo-Hutnicza, Kraków 2009.
9. Rusek J.: *Harmonics and inter-harmonics of voltage converter supplied induction machine stator currents*, ICREPQ07, International Conference on “Renewable Energy and Power Quality”: Sevilla, 28-30 of March, 2007, pp. 1-4.
10. Szczebiot R., Cieślak S.: *Application of genetic algorithm for optimal placement of wind generators in the MV power grid*, „Przegląd Elektrotechniczny”, cz. 87, nr 3, 2011, s. 198-200.
11. Tarasiuk J., Wierzbowski K., Lodini A.: *Use of Genetic Algorithms for Optimisation of Materials Properties*, „Archives of Metallurgy and Materials”, vol. 54, issue 1/2009, pp. 35-39.
12. The MARF Development Group: *Modular Audio Recognition Framework v.0.3.0-devel-20050606 and its Applications*, Application note, Montreal, Quebec, Canada, 2005.

Artykuł został zrecenzowany przez dwóch niezależnych recenzentów.