

Adam GLOWACZ

RECOGNITION OF ACOUSTIC SIGNALS OF INDUCTION MOTOR USING FFT, SMOFS-10 AND LSVM

ROZPOZNAWANIE SYGNAŁÓW AKUSTYCZNYCH SILNIKA INDUKCYJNEGO Z ZASTOSOWANIEM FFT, SMOFS-10 I LSVM*

A correct diagnosis of electrical circuits is very essential in industrial plants. An article deals with a recognition method of early fault detection of induction motor. The described approach is based on patterns recognition. Acoustic signals of specific induction motor are analyzed patterns. Acoustic signals include information about motor state. The analysis of the patterns was conducted for three states of induction motor using Fast Fourier Transform (FFT), shortened method of frequencies selection (SMoFS-10) and Linear Support Vector Machine (LSVM). The results of calculations suggest that the method is efficient and can be also used for diagnostic purposes.

Keywords: acoustic signal, induction motor, feature extraction, classification.

Prawidłowa diagnostyka obwodów elektrycznych jest bardzo istotna w zakładach przemysłowych. Artykuł zajmuje się metodą rozpoznawania stanów przedawaryjnych silnika indukcyjnego. Opisane podejście jest oparte na rozpoznawaniu wzorców. Sygnały akustyczne określonego silnika indukcyjnego są badanymi wzorcami. Sygnały akustyczne zawierają informację o stanie silnika. Analiza wzorców została przeprowadzona dla trzech stanów silnika indukcyjnego używając FFT, skróconej metody wyboru częstotliwości (SMoFS-10) i liniowej maszyny wektorów wspierających (LSVM). Wyniki obliczeń sugerują, że metoda jest skuteczna i może być również zastosowana dla celów diagnostycznych.

Słowa kluczowe: sygnał akustyczny, silnik indukcyjny, ekstrakcja cech, klasyfikacja.

1. Introduction

The induction motors are used in various industries such as: mining, fuel, metallurgical. These motors have low maintenance and low price. To reduce maintenance costs scientists analyze mechanical properties of materials [18, 20, 25, 30].

They also develop early fault detection methods [1, 5, 6, 10-15]. Especially non-invasive methods are developed such as: acoustic, vibrations, thermal, magnetic [3, 14, 19, 27, 28, 29, 35, 36, 38]. Non-invasive methods are capable to diagnose early faults without disassembly the induction motor. Many of them used patterns recognition and signal processing to identify type of fault.

Incipient faults of motors may change into damages and may stop the production line. The stopped production line causes losses of resources and production time. It increases the cost of operation and maintenance.

This article deals with a recognition method of early faults of induction motor. Proposed method uses Fast Fourier Transform (FFT), shortened method of radio frequencies selection (SMoFS-10) and Linear Support Vector Machine (LSVM).

2. Proposed approach of recognition of acoustic signal of induction motor

The proposed approach of recognition of acoustic signal of induction motor contained two processes: a pattern creation process and an identification process. These processes were needed for proper recognition of acoustic signal (Fig. 1).

The first of them recorded acoustic signal of motor with the help of a sound card and a microphone [22]. Acoustic signal was converted

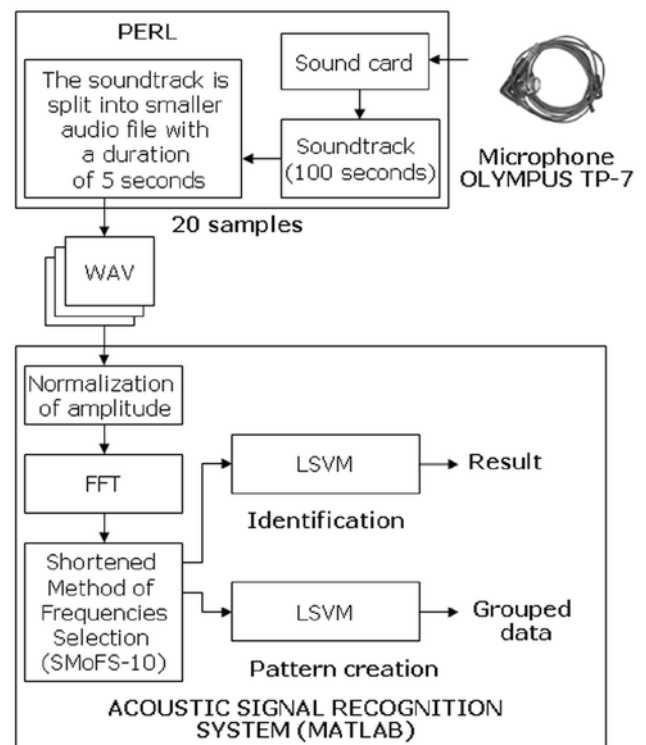


Fig. 1. Process of recognition of acoustic signal of induction motor using FFT, shortened method of frequencies selection (SMoFS-10) and Linear Support Vector Machine

(*) Tekst artykułu w polskiej wersji językowej dostępny w elektronicznym wydaniu kwartalnika na stronie www.ein.org.pl

to soundtrack. Next this signal was converted into smaller audio files with a duration of 5 seconds. After that amplitudes of audio files (recorded acoustic signal) were normalized. Next the radio frequency spectra were calculated by FFT algorithm [8]. These spectra were processed by the shortened method of radio frequencies selection (SMoFS-10). The results of this method were feature vectors containing specific amplitudes of radio frequencies. The shortened method of frequencies selection (SMoFS-10) was discussed in chapter 2.2. Next step was grouping of data. For this purpose, Linear Support Vector Machine (LSVM) algorithm was used. The same methods as above were used in the identification process. Calculated feature vectors were recognized by Linear Support Vector Machine algorithm.

The described approach was based on patterns recognition. Patterns of acoustic signals of specific induction motor were analyzed. For this reason, there were two databases of patterns: training database and test database. The training database of patterns was used in the pattern creation process. All training samples and their classes were known. The test database of patterns was used in the identification process. All test samples were known, but their classes were unknown. Proposed method identified the correct class.

2.1. Measurement and preprocessing of acoustic signals of induction motor

The sound card and the microphone OLYMPUS TP-7 were applied to record acoustic signal of induction motor. Parameters of recorded soundtrack were following: 16-bit depth, number of channels – single channel, sampling rate – 44100 Hz, WAVE PCM audio file. Obtained soundtrack was converted into smaller audio files with a duration of 5 seconds. Afterwards amplitudes of audio files were normalized. Normalization of amplitude divided each point of the signal by maximum value. In that way signals were comparable in the range $\langle -1, 1 \rangle$. Next the radio frequency spectra were calculated by FFT algorithm. Obtained radio frequency spectra were used by shortened method of frequencies selection SMoFS-10.

2.2. Shortened method of frequencies selection (SMoFS-10)

The shortened method of frequencies selection (SMoFS-10) was based on the radio frequency spectrum. The method had following steps:

- 1) Calculate the difference of the radio frequency spectra of two states of motor $\|F_1 - F_2\|$, where $|F_1|$ - is the radio frequency spectrum of acoustic signal of the first state of motor, $|F_2|$ - is the radio frequency spectrum of acoustic signal of the second state of motor.
- 2) Select the radio frequencies, which meets following criterion:

$$\|F_1 - F_2\| > t \quad (1)$$

where t – threshold of selection of amplitudes of radio frequencies (formula 1), $\|F_1 - F_2\|$ – the difference of amplitudes of radio frequencies for two different states of the motor.

Parameter t should be selected properly. This parameter depends on number of analyzed states and number of selected radio frequencies. Too little number of analyzed radio frequencies can cause errors. The differences between the selected radio frequencies can have different values (for example the first difference has maximum amplitude for frequencies 100, 200, 300 Hz; the second difference has maximum amplitude for frequencies 150, 200, 250 Hz; the third difference has maximum amplitude for frequencies 150, 225, 275 Hz in that case states 1 and 3 do not have common radio frequencies). For this reason, the parameter t is selected according to formulas 2 and 3. If the number of radio frequencies (number s) is greater than 10, the method will do loop calculation (formula 3). If the number of radio frequencies is smaller or equal to 10 it finishes its calculations.

$$t = \frac{\sum_{s=1}^s \|F_1 - F_2\|}{s}, \quad (2)$$

$$s \leq 10, \quad (3)$$

where t – threshold of selection of amplitudes of radio frequencies (it depends on s and analyzed acoustic signal), s – natural number, number of radio frequencies (initially $s=16384$, 16384 is the number of all frequencies after usage of FFT algorithm). The amplitudes of selected radio frequencies of acoustic signals of motor are used to create feature vectors. SMoFS-10 method gives feature vector with 1-10 features, where a feature is the amplitude of radio frequency. The feature vector may have 2 features or 8, depending on the analyzed signals and the parameter s (for SMoFS-10 $s = 10$). Optimization of parameters s and t depends on the number of analyzed states, their types, disturbances and the type of machine.

Difference between spectrum of acoustic signal of faultless induction motor and spectrum of acoustic signal of induction motor with faulty rotor bar was showed in figure 2.

Selected radio frequencies for differences between spectra of acoustic signals of induction motor were presented (Fig. 3-5). Two radio frequencies were common for analyzed states of induction mo-

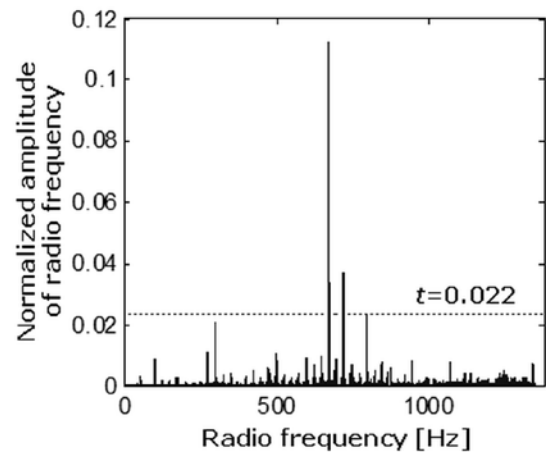


Fig. 2. Difference between spectrum of acoustic signal of faultless induction motor and spectrum of acoustic signal of induction motor with faulty rotor bar




Fig. 3. Selected radio frequencies for difference between spectrum of acoustic signal of faultless induction motor and spectrum of acoustic signal of induction motor with faulty rotor bar with the use of SMoFS-10

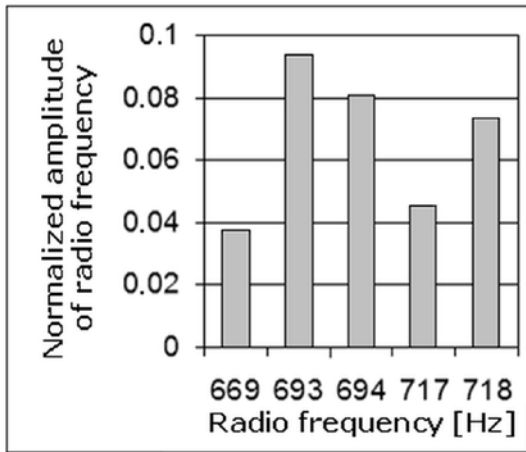


Fig. 4. Selected radio frequencies for difference between spectrum of acoustic signal of faultless induction motor and spectrum of acoustic signal of induction motor with two faulty rotor bars with the use of SMOFS-10




Fig. 5. Selected radio frequencies for difference between spectrum of acoustic signal of induction motor with faulty rotor bar and spectrum of acoustic signal of induction motor with two faulty rotor bars with the use of SMOFS-10

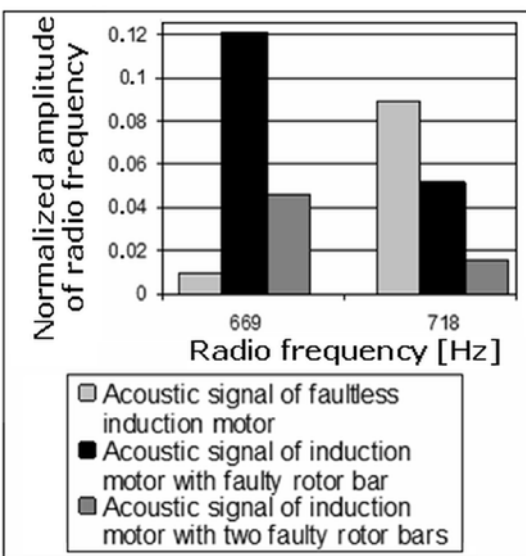


Fig. 6. Selection of common radio frequencies for 3 states of induction motor (669 and 718 Hz) with the use of SMOFS-10

tor: 669 and 718 Hz (Fig. 6). Selected amplitudes of frequencies 669 and 718 Hz were used to form feature vector.

2.3. Linear Support Vector Machine

Last step of signal processing was classification. Scientists proposed many methods of classification in the literature [2, 4, 7, 9, 16, 17, 21, 23, 26, 31-34]. Linear Support Vector Machine (LSVM) classified feature vectors by finding the best hyperplane that separated all vectors of one class from those of the other class. The considered hyperplane had the largest margin between the two classes [24, 37]. There were two more hyperplanes parallel to the separating hyperplane. They cut through the closest training examples (support vectors) on either side. These hyper-planes were called "support hyper-planes". They contained support vectors. A set of vectors x_i with their categories y_i were training examples.

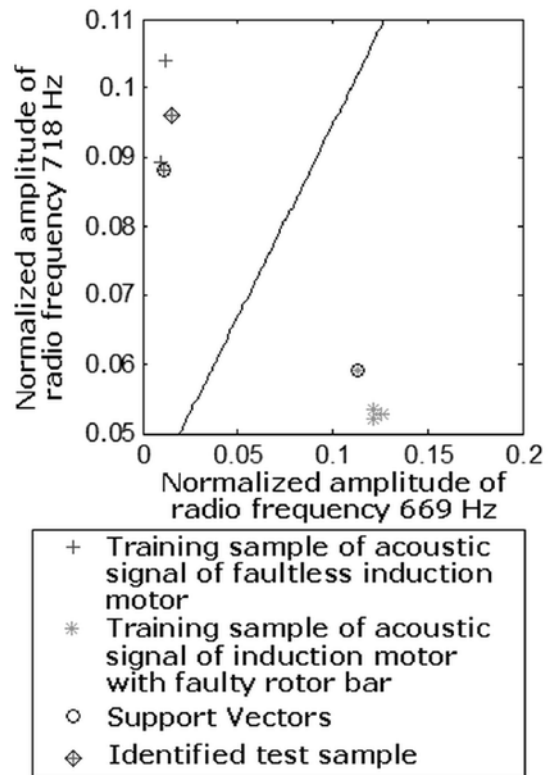


Fig. 7. Identification of test sample (acoustic signal of faultless induction motor) with the use of SMOFS-10, LSVM and training samples of acoustic signal of faultless induction motor and acoustic signal of induction motor with faulty rotor bar

A hyperplane was defined by following formula:

$$\langle w, x \rangle + b = 0, \tag{4}$$

where $w \in R_d$, $x_i \in R_d$, R_d (datapoints), $y_i = \pm 1$, $\langle w, x \rangle$ was the inner product of w and x , b was real.

Solution of this problem was to find w and b that minimize $\|w\|$ for all training examples (x_i, y_i) ,

$$y_i(\langle w, x_i \rangle + b) \geq 1. \tag{5}$$

More about Linear Support Vector Machine could be found in literature [24, 37]. Identification of test sample of acoustic signal of faultless induction motor was showed (Fig. 7, 8).

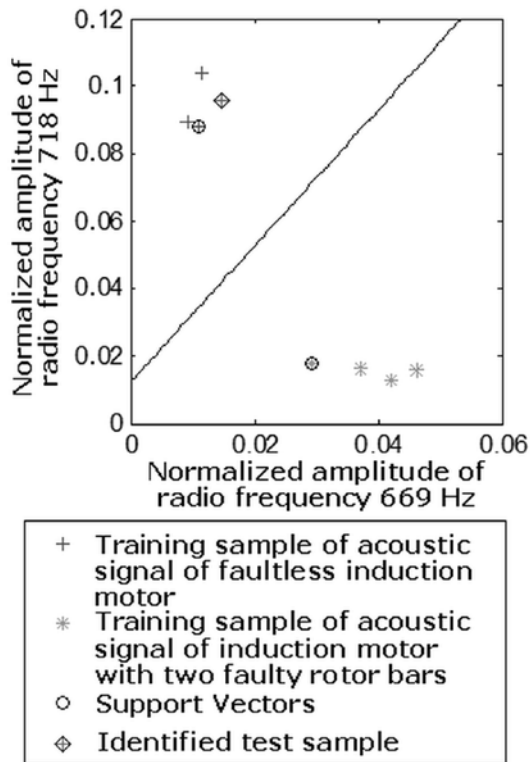


Fig. 8. Identification of test sample (acoustic signal of faultless induction motor) with the use of SMOFS-10, LSVM and training samples of acoustic signal of faultless induction motor and acoustic signal of induction motor with two faulty rotor bars

3. Analysis of acoustic signals of three phases induction motors

Three loaded three phases induction motors were used in analysis. These motors were the same. Open loop control system was used for these motors. Each of them had operational parameters: $U_N=220/380$ V (Δ/Y), $I_N=2.52/1.47$ A (Δ/Y), $P_N=0.55$ kW, $n_N=1400$ rpm, where U_n - nominal stator voltage, I_n - nominal stator current, P_N - motor power, n_N - rotor speed.

The first motor was faultless induction motor. The second motor was induction motor with faulty rotor bar. The third motor was induction motor with two faulty rotor bars (Fig. 9).




Fig. 9. Squirrel-cage rotor of three phases induction motor with two faulty rotor bars

In the pattern creation process 12 five-second training samples were processed by proposed method of acoustic signal recognition. These training samples were used to group data.

References

1. Abramov IV, Nikitin YR, Abramov AI, Sosnovich EV, Bozek P. Control and Diagnostic Model of Brushless Dc Motor. Journal of Electrical Engineering-Elektrotechnicky Casopis 2014; 65 (5): 277-282, <http://dx.doi.org/10.2478/jee-2014-0044>.

The identification process used 60 samples (20 samples for each class). These samples were used to evaluate efficiency of recognition of acoustic signal. This efficiency was defined as:

$$E = \frac{NoPITS}{NoTS} 100\% , \quad (6)$$

where $NoPITS$ – number of properly identified test samples of specific class used in the identification process, $NoTS$ – number of test samples of specific class used in the identification process, E – efficiency of recognition of acoustic signal of specific class.

$$TEoRoAS = \frac{E_1 + E_2 + E_3}{3} , \quad (7)$$

where $TEoRoAS$ - Total efficiency of recognition of acoustic signal, E_1 - efficiency of recognition of acoustic signal of faultless induction motor, E_2 - efficiency of recognition of acoustic signal of induction motor with faulty rotor bar, E_3 - efficiency of recognition of acoustic signal of induction motor with two faulty rotor bars.

Table 1 presented efficiency of recognition of acoustic signal of three phases induction motor depending on state of induction motor. It also presented total efficiency of recognition of acoustic signal of induction motor.

On the basis of table 1 it can be noticed that E was in the range of 90-100 % and $TEoRoAS$ was 96.66 %.

Table 1. Results of recognition of acoustic signal of three phases induction motor with the use of SMOFS-10 and LSVM

| State of induction motor | E [%] |
|----------------------------------|---------------|
| Faultless motor | 100 |
| Motor with faulty rotor bar | 90 |
| Motor with two faulty rotor bars | 100 |
| | $TEoRoAS$ [%] |
| 3 analyzed states of motor | 96.66 |

4. Conclusions

Paper presented method of recognition of acoustic signal of three phases induction motor. This method contained methods of processing such as: FFT, SMOFS-10 and LSVM. SMOFS-10 was also new method of feature extraction. Analysis of acoustic signals showed that proposed solution was good to recognize state of induction motor. Total efficiency of recognition of acoustic signal of induction motor was equal to 96.66 % for 3 analyzed states of motor. Presented method can be used for early diagnostics of specific induction motors (the same size, operational parameters). It can be used for other electric motor when the patterns are properly selected. Moreover method based on acoustic signal can be used together with diagnostics methods based on thermal signals and stator current signals. In this way, it can improve the diagnostics of electrical motors.

Acknowledgments

This work has been financed under AGH researcher grant in 2015 (Adam Glowacz).

2. Alshayeb M, Eisa Y, Ahmed MA. Object-Oriented Class Stability Prediction: A Comparison Between Artificial Neural Network and Support Vector Machine. *Arabian Journal for Science and Engineering* 2014; 39 (11): 7865-7876, <http://dx.doi.org/10.1007/s13369-014-1372-4>.
3. Andonova AV, Hinov NL. Thermographic Analysis of a Bridge Power Converter. *Journal of Electrical Engineering-Elektrotechnicky Casopis* 2014; 65 (6), 371-375.
4. Augustyniak P, Smolen M, Mikrut Z, Kantoch E. Seamless Tracing of Human Behavior Using Complementary Wearable and House-Embedded Sensors. *Sensors* 2014; 14 (5): 7831-7856, <http://dx.doi.org/10.3390/s140507831>.
5. Baranski M. New vibration diagnostic method of PM generators and traction motors - detecting of vibrations caused by unbalance. 2014 IEEE International Energy Conference (ENERGYCON 2014); Book Series: IEEE International Energy Conference: 28-32.
6. Baranski M, Decner A, Polak A. Selected Diagnostic Methods of Electrical Machines Operating in Industrial Conditions. *IEEE Transactions on Dielectrics and Electrical Insulation* 2014; 21 (5): 2047-2054, <http://dx.doi.org/10.1109/TDEI.2014.004602>.
7. Dudek-Dyduch E, Tadeusiewicz R, Horzyk A. Neural network adaptation process effectiveness dependent of constant training data availability. *Neurocomputing* 2009; 72 (13-15): 3138-3149, <http://dx.doi.org/10.1016/j.neucom.2009.03.017>.
8. Duspara M, Sabo K, Stoic A. Acoustic emission as tool wear monitoring. *Tehnicki Vjesnik-Technical Gazette* 2014; 21 (5), 1097-1101.
9. Dzwonkowski A, Swedrowski L. Uncertainty analysis of measuring system for instantaneous power research. *Metrology and Measurement Systems* 2012; 19 (3): 573-582.
10. Glowacz A. Diagnostics of Synchronous Motor Based on Analysis of Acoustic Signals with the use of Line Spectral Frequencies and K-nearest Neighbor Classifier. *Archives of Acoustics* 2014; 39 (2): 189-194.
11. Glowacz A. Diagnostics of DC and Induction Motors Based on the Analysis of Acoustic Signals. *Measurement Science Review* 2014; 14 (5): 257-262, <http://dx.doi.org/10.2478/msr-2014-0035>.
12. Glowacz A, Glowacz Z. Diagnostics of DC machine based on analysis of acoustic signals with application of MFCC and classifier based on words. *Archives of Metallurgy and Materials* 2012; 57 (1): 179-183, <http://dx.doi.org/10.2478/v10172-012-0007-6>.
13. Glowacz A, Glowacz Z. Diagnostics of induction motor based on analysis of acoustic signals with application of FFT and classifier based on words. *Archives of Metallurgy and Materials* 2010; 55 (3): 707-712.
14. Glowacz A, Glowacz A, Korohoda P. Recognition of Monochrome Thermal Images of Synchronous Motor with the Application of Binarization and Nearest Mean Classifier. *Archives of Metallurgy and Materials* 2014; 59 (1): 31-34, <http://dx.doi.org/10.2478/amm-2014-0005>.
15. Glowacz Z, Kozik J. Detection of synchronous motor inter-turn faults based on spectral analysis of park's vector. *Archives of Metallurgy and Materials* 2013; 58 (1): 19-23, <http://dx.doi.org/10.2478/v10172-012-0144-y>.
16. Hachaj T, Ogiela MR. Application of neural networks in detection of abnormal brain perfusion regions. *Neurocomputing* 2013; 122 (Special Issue): 33-42, <http://dx.doi.org/10.1016/j.neucom.2013.04.030>.
17. Jun S, Kochan O. Investigations of Thermocouple Drift Irregularity Impact on Error of their Inhomogeneity Correction. *Measurement Science Review* 2014; 14 (1): 29-34.
18. Krolczyk GM, Nieslony P, Legutko S. Determination of tool life and research wear during duplex stainless steel turning. *Archives of Civil and Mechanical Engineering* 2015; 15 (2): 347-354, <http://dx.doi.org/10.1016/j.acme.2014.05.001>.
19. Krolczyk GM, Krolczyk JB, Legutko S, Hunjet A. Effect of the disc processing technology on the vibration level of the chipper during operations. *Tehnicki Vjesnik-Technical Gazette* 2014; 21 (2), 447-450.
20. Krolczyk JB. An attempt to predict quality changes in a ten-component granular system. *Tehnicki Vjesnik-Technical Gazette* 2014; 21 (2), 255-261.
21. Kundegorski M, Jackson PJB, Ziolk B. Two-Microphone Dereverberation for Automatic Speech Recognition of Polish. *Archives of Acoustics* 2014; 39 (3): 411-420.
22. Kulka Z. Advances in Digitization of Microphones and Loudspeakers. *Archives of Acoustics* 2011; 36 (2): 419-436, <http://dx.doi.org/10.2478/v10168-011-0030-z>.
23. Mahmood A, Alsulaiman M, Muhammad G. Automatic Speaker Recognition Using Multi-Directional Local Features (MDLF). *Arabian Journal for Science and Engineering* 2014; 39 (5): 3799-3811, <http://dx.doi.org/10.1007/s13369-014-1048-0>.
24. MathWorks – MATLAB and SimuLink for Technical Computing 2015; www.mathworks.com.
25. Nadolny K, Kaplonek W. Analysis of Flatness Deviations for Austenitic Stainless Steel Workpieces after Efficient Surface Machining. *Measurement Science Review* 2014; 14 (4), 204-212, <http://dx.doi.org/10.2478/msr-2014-0028>.
26. Nafisi H, Abedi M, Gharehpetian GB. Locating Pd in Transformers through Detailed Model and Neural Networks. *Journal of Electrical Engineering-Elektrotechnicky Casopis* 2014; 65 (2), 75-82, <http://dx.doi.org/10.2478/jee-2014-0011>.
27. Paydarnia H, Hajiaghahi S, Abbaszadeh K. Improved Structure of PNN Using PCA in Transformer Fault Diagnostic. *Arabian Journal for Science and Engineering* 2014; 39 (6): 4845-4851, <http://dx.doi.org/10.1007/s13369-014-1004-z>.
28. Pleban D. Definition and Measure of the Sound Quality of the Machine. *Archives of Acoustics* 2014; 39 (1): 17-23.
29. Rusinski E, Moczko P, Odyjas P, Pietrusiak D. Investigation of vibrations of a main centrifugal fan used in mine ventilation. *Archives of Civil and Mechanical Engineering* 2014; 14 (4), 569-579, <http://dx.doi.org/10.1016/j.acme.2014.04.003>.
30. Stepień K. Research on a surface texture analysis by digital signal processing methods. *Tehnicki Vjesnik-Technical Gazette* 2014; 21 (3): 485-493.
31. Swedrowski L, Duzinkiewicz K, Grochowski M, Rutkowski T. Use of neural networks in diagnostics of rolling-element bearing of the induction motor. *Smart Diagnostics V* 2014; Book Series: Key Engineering Materials; 588: 333-342.
32. Turchenko I, Kochan V, Sachenko A, Kochan R, Stepanenko A, Daponte P, Grimaldi D. Simulation modeling of neural-based method of multi-sensor output signal recognition. 2006 IEEE Instrumentation and Measurement Technology Conference Proceedings; Vols 1-5: 1530-1535, <http://dx.doi.org/10.1109/IMTC.2006.328653>.
33. Valis D, Zak L, Pokora O. Contribution to system failure occurrence prediction and to system remaining useful life estimation based on oil field data. *Proceedings of the Institution of Mechanical Engineers Part O-Journal of Risk and Reliability* 2015; 229 (1): 36-45, <http://dx.doi.org/10.1177/1748006X14547789>.
34. Valis D, Pietrucha-Urbanik K. Utilization of diffusion processes and fuzzy logic for vulnerability assessment. *Eksploracja i Niezawodność*

- Maintenance and Reliability 2014; 16 (1): 48-55.
35. Umasankar L, Kalaiarasi N. Internal Fault Identification and Classification of Transformer with the Aid of Radial Basis Neural Network (RBNN). *Arabian Journal for Science and Engineering* 2014; 39 (6): 4865-4873, <http://dx.doi.org/10.1007/s13369-014-1030-x>.
 36. Wu RC, Tsai JI, Chiang CT, Ouyang CS. Detection of induction motor operation condition by acoustic signal. 8th IEEE International Conference on Industrial Informatics (INDIN) 2010: 792-797, <http://dx.doi.org/10.1109/indin.2010.5549641>.
 37. Zhang DZ, Xia BK. Soft Measurement of Water Content in Oil-Water Two-Phase Flow Based on RS-SVM Classifier and GA-NN Predictor. *Measurement Science Review* 2014; 14 (4), 219-226, <http://dx.doi.org/10.2478/msr-2014-0030>.
 38. Zhao Z, Wang C, Zhang YG, Sun Y. Latest progress of fault detection and localization in complex Electrical Engineering. *Journal of Electrical Engineering-Elektrotechnicky Casopis* 2014; 65 (1): 55-59, <http://dx.doi.org/10.2478/jee-2014-0008>.

Adam GLOWACZ

AGH University of Science and Technology
Faculty of Electrical Engineering, Automatics
Computer Science and Biomedical Engineering
Department of Automatics and Biomedical Engineering
al. A. Mickiewicza 30, 30-059 Kraków, Poland
e-mail: adglow@agh.edu.pl

Adam GŁOWACZ

AGH Akademia Górniczo-Hutnicza,
Wydział Elektrotechniki, Automatyki, Informatyki i Inżynierii Biomedycznej,
Katedra Automatyki i Inżynierii Biomedycznej,
al. A. Mickiewicza 30, 30-059 Kraków,
e-mail: adglow@agh.edu.pl

Rozpoznawanie sygnałów akustycznych silnika indukcyjnego z zastosowaniem FFT, SMOFS-10 i LSVM

Słowa kluczowe: *Sygnal akustyczny, silnik indukcyjny, ekstrakcja cech, klasyfikacja*

Streszczenie: Prawidłowa diagnostyka obwodów elektrycznych jest bardzo istotna w zakładach przemysłowych. Artykuł zajmuje się metodą rozpoznawania stanów przedawaryjnych silnika indukcyjnego. Opisane podejście jest oparte na rozpoznawaniu wzorców. Sygnały akustyczne określonego silnika indukcyjnego są badanymi wzorcami. Sygnały akustyczne zawierają informację o stanie silnika. Analiza wzorców została przeprowadzona dla trzech stanów silnika indukcyjnego używając FFT, skróconej metody wyboru częstotliwości (Shortened Method of Frequencies Selection SMOFS-10) i liniowej maszyny wektorów wspierających (LSVM). Wyniki obliczeń sugerują, że metoda jest skuteczna i może być również zastosowana dla celów diagnostycznych.

1. Wstęp

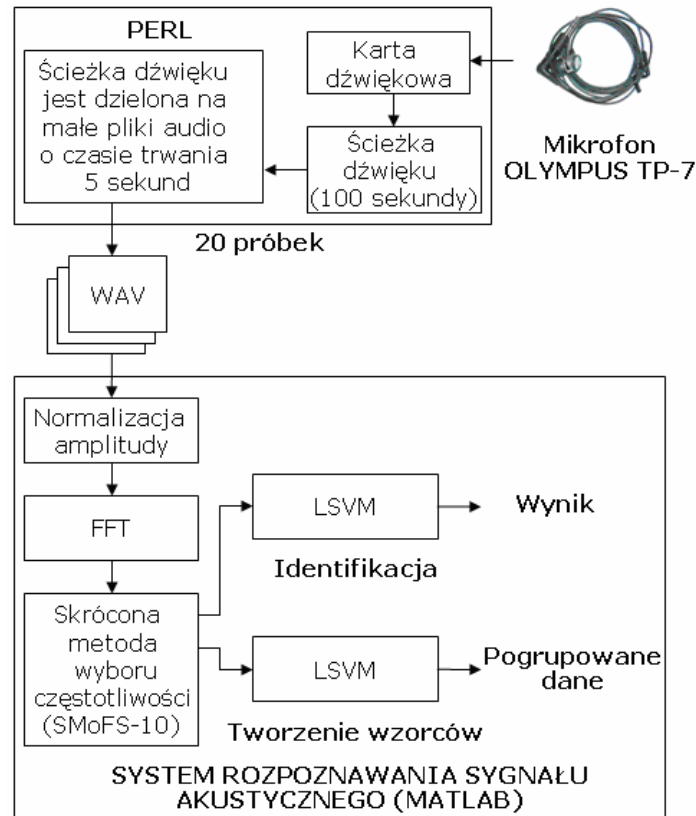
Silniki indukcyjne są używane w różnych przemysłach takich jak: górniczy, paliwowy, hutniczy. Silniki te mają niski koszt utrzymania i niską cenę. Aby zredukować koszty naukowcy badają mechaniczne właściwości materiałów [18, 20, 25, 30]. Naukowcy również rozwijają metody detekcji stanów przedawaryjnych [1, 5, 6, 10-15]. Szczególnie metody nieinwazyjne są rozwijane takie jak: akustyczne, cieplne, magnetyczne [3, 14, 19, 27, 28, 29, 35, 36, 38]. Nieinwazyjne metody są zdolne do diagnozowania stanów przedawaryjnych bez demontażu silnika indukcyjnego. Wiele z nich używa rozpoznawania wzorców i przetwarzania sygnału do identyfikacji typu uszkodzenia. Stany przedawaryjne silników mogą zamienić się w uszkodzenia i mogą zatrzymać linię produkcyjną. Zatrzymana linia produkcyjna powoduje straty surowców i czasu produkcji. Powoduje to zwiększenie kosztów eksploatacji i utrzymania.

Artykuł zajmuje się metodą rozpoznawania stanów przedawaryjnych silnika indukcyjnego. Proponowana metoda używa Szybkiej Transformacji Fouriera (FFT), skróconej metody wyboru częstotliwości (SMoFS-10) i liniowej maszyny wektorów wspierających (LSVM).

2. Proponowane podejście rozpoznawania sygnału akustycznego silnika indukcyjnego

Proponowane podejście rozpoznawania sygnału akustycznego silnika indukcyjnego zawierało dwa procesy: proces tworzenia wzorca i proces identyfikacji. Te procesy były potrzebne do właściwego rozpoznawania sygnału akustycznego (Rys. 1). Pierwszy z nich rejestrował sygnał akustyczny silnika za pomocą karty dźwiękowej i mikrofonu [22]. Sygnał akustyczny był zamieniany na ścieżkę dźwięku. Następnie ten sygnał był zamieniany w małe pliki audio o czasie trwania 5 sekund. Później amplitudy plików audio (zarejestrowanego sygnału akustycznego) były normalizowane. Następnie widma częstotliwości radiowych były obliczane przez algorytm FFT [8]. Te widma były przetwarzane przez skróconą metodę

wyboru częstotliwości (SMoFS-10). Wynikami tej metody były wektory cech zawierające określone amplitudy częstotliwości radiowych. Skrócona metoda wyboru częstotliwości (SMoFS-10) była dyskutowana w rozdziale 2.2. Następnym krokiem było grupowanie danych. W tym celu został użyty algorytm liniowej maszyny wektorów wspierających (LSVM).



Rys. 1. Proces rozpoznawania sygnału akustycznego silnika indukcyjnego z zastosowaniem FFT, skróconej metody wyboru częstotliwości (SMoFS-10) i liniowej maszyny wektorów wspierających

Te same metody jak powyżej były użyte w procesie identyfikacji. Obliczone wektory cech były rozpoznawane przez liniową maszynę wektorów wspierających. Opisane podejście było oparte na rozpoznawaniu wzorców. Wzorce sygnałów akustycznych określonego silnika indukcyjnego były badane. Tam były używane dwie bazy danych wzorców: baza danych ucząca i baza danych testowa. Ucząca baza danych wzorców była używana w procesie tworzenia wzorca. Wszystkie próbki uczące i ich klasy były znane. Testowa baza danych wzorców była użyta w procesie identyfikacji. Wszystkie testowe próbki były znane, ale ich klasy były nieznane. Proponowana metoda identyfikowała właściwą klasę.

2.1. Pomiary i wstępne przetwarzanie sygnałów akustycznych silnika indukcyjnego

Karta dźwiękowa i mikrofon OLYMPUS TP-7 były zastosowane do rejestrowania sygnału akustycznego silnika indukcyjnego. Parametry zarejestrowanej ścieżki dźwięku były następujące: 16 bitów (kwantyzacja), liczba kanałów - pojedynczy kanał, częstotliwość próbkowania - 44100 Hz, plik audio WAVE PCM. Otrzymana ścieżka dźwiękowa została zamieniona w małe pliki audio o czasie trwania 5 sekund. Następnie pliki audio były normalizowane. Normalizacja amplitudy dzieliła każdy punkt sygnału przez wartość maksymalną. W ten sposób sygnał był porównywalny w zakresie $\langle -1, 1 \rangle$. Następnie widmo

częstotliwości radiowych zostało obliczone przez algorytm FFT. Otrzymane widma częstotliwości radiowych były używane przez skróconą metodę wyboru częstotliwości SMOFS-10.

2.2. Skrócona metoda wyboru częstotliwości (SMoFS-10)

Skrócona metoda wyboru częstotliwości (SMoFS-10) była oparta na widmie częstotliwości radiowych. Metoda ta miała następujące kroki:

- 1) Oblicz różnice widm częstotliwości radiowych dwóch stanów silnika $\|F_1|-|F_2\|$, gdzie $|F_1|$ - jest widmem częstotliwości radiowych sygnału akustycznego pierwszego stanu silnika, $|F_2|$ - jest widmem częstotliwości radiowych sygnału akustycznego drugiego stanu silnika.
- 2) Wybierz częstotliwości radiowe, które spełniają kryterium:

$$\|F_1|-|F_2\|>t \quad (1)$$

gdzie t – próg wyboru amplitud częstotliwości radiowych (równanie 1), $\|F_1|-|F_2\|$ – różnica amplitud częstotliwości radiowych dla dwóch różnych stanów silnika.


Parametr t powinien być wybrany właściwie. Ten parametr zależy od liczby badanych stanów i liczby wybranych częstotliwości radiowych. Zbyt mała liczba badanych częstotliwości radiowych może powodować błędy. Różnice między wybranymi częstotliwościami radiowymi mogą mieć różne wartości (na przykład pierwsza różnica może mieć maksymalne amplitudy częstotliwości dla 100, 200, 300 Hz; druga różnica może mieć maksymalne amplitudy częstotliwości dla 150, 200, 250 Hz; trzecia różnica może mieć maksymalne amplitudy częstotliwości dla 150, 225, 275 Hz; w takim przypadku różnice 1 i 3 nie mają wspólnych częstotliwości). Z tego powodu, parametr t jest wybrany stosownie do wzorów 2 i 3. Jeśli liczba częstotliwości radiowych (liczba s) jest większa niż 10, metoda wykonuje w pętli obliczenia (wzór 3). Jeśli liczba częstotliwości radiowych jest mniejsza lub równa 10 to kończy obliczenia.

$$t = \frac{\sum_{s=1}^s \|F_1|-|F_2\|}{s} \quad (2)$$

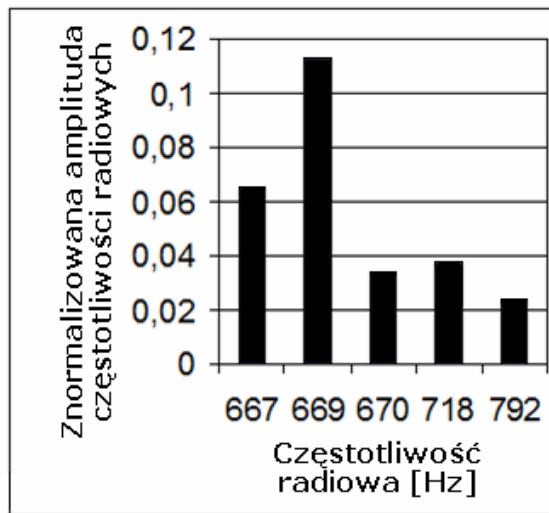
$$s \leq 10 \quad (3)$$

gdzie t – próg wyboru amplitud częstotliwości radiowych (zależy od s i badanego sygnału akustycznego), s – liczba naturalna, liczba wybranych częstotliwości radiowych (początkowo $s=16384$, 16384 jest liczbą wszystkich częstotliwości radiowych po użyciu algorytmu FFT). Amplitudy wybranych częstotliwości radiowych sygnałów akustycznych silnika są używane do tworzenia wektorów cech. Metoda SMOFS-10 oblicza wektor cech z 1-10 cechami, gdzie cecha jest amplitudą częstotliwości. Wektor cech może mieć na przykład 2 cechy lub 8, zależnie od badanych sygnałów i parametru s (dla SMOFS-10 $s=10$). Optymalizacja parametrów s i t zależy od liczby badanych stanów, ich rodzajów, zakłóceń i typu maszyny.


Różnica pomiędzy widmem sygnału akustycznego silnika indukcyjnego bez uszkodzeń i widmem sygnału akustycznego silnika indukcyjnego z uszkodzonym prętem wirnika została pokazana na rysunku 2.




Rys. 2. Różnica między widmem sygnału akustycznego silnika indukcyjnego bez uszkodzeń i widmem sygnału akustycznego silnika indukcyjnego z uszkodzonym prętem wirnika



Rys. 3. Wybrane częstotliwości radiowe dla różnic między widmem sygnału akustycznego silnika indukcyjnego bez uszkodzeń i widmem sygnału akustycznego silnika indukcyjnego z uszkodzonym prętem wirnika z użyciem SMoFS-10




Rys. 4. Wybrane częstotliwości radiowe dla różnic między widmem sygnału akustycznego silnika indukcyjnego bez uszkodzeń i widmem sygnału akustycznego silnika indukcyjnego z dwoma uszkodzonymi prętami wirnika z użyciem SMoFS-10



Rys. 5. Wybrane częstotliwości radiowe dla różnic między widmem sygnału akustycznego silnika indukcyjnego z uszkodzonym prętem wirnika i widmem sygnału akustycznego silnika indukcyjnego z dwoma uszkodzonymi prętami wirnika z użyciem SMOFS-10

Wybrane częstotliwości radiowe dla różnic między widmami sygnałów akustycznych silnika indukcyjnego były prezentowane (Rys. 3-5). Dwie częstotliwości radiowe były wspólne dla badanych stanów silnika indukcyjnego: 669 i 718 Hz (Rys. 6). Wybrane amplitudy częstotliwości 669 i 718 Hz były używane do tworzenia wektora cech.



Rys. 6. Wybór wspólnych częstotliwości radiowych dla 3 stanów silnika indukcyjnego (669 i 718 Hz) z użyciem SMOFS-10

2.3. Liniowa maszyna wektorów wspierających

Ostatnim krokiem przetwarzania sygnału była klasyfikacja. W literaturze naukowcy zaproponowali wiele metod klasyfikacji [2, 4, 7, 9, 16, 17, 21, 23, 26, 31-34]. Liniowa maszyna wektorów wspierających (LSVM) klasyfikowała wektory cech przez znajdowanie najlepszej hiperpłaszczyzny, która oddzielała wszystkie wektory jednej klasy od tych z innej klasy. Rozpatrywana hiperpłaszczyzna miała największy margines między dwoma klasami [24, 37]. Tam były jeszcze dwie hiperpłaszczyzny równoległe do hiperpłaszczyzny

oddzielającej. One przecinały najbliższe przykłady uczące (wektory wspierające) z obu stron. Te hiperpłaszczyzny były nazwane "hiperpłaszczyznami wspierającymi". Zawierały one wektory wspierające. Zbiór wektorów \mathbf{x}_i z ich kategoriami y_i były przykładami uczącymi. Hiperpłaszczyzna była zdefiniowana następującym wzorem:


$$\langle \mathbf{w}, \mathbf{x} \rangle + b = 0 \quad (4)$$

gdzie $\mathbf{w} \in R_d$, $\mathbf{x}_i \in R_d$, R_d (punkty danych), $y_i = \pm 1$, $\langle \mathbf{w}, \mathbf{x} \rangle$ było iloczynem skalarnym \mathbf{w} i \mathbf{x} , b było liczbą rzeczywistą.


Rozwiązaniem tego problemu było znalezienie \mathbf{w} i b , które minimalizują $\|\mathbf{w}\|$ dla wszystkich przykładów uczących (\mathbf{x}_i, y_i) ,

$$y_i(\langle \mathbf{w}, \mathbf{x}_i \rangle + b) \geq 1. \quad (5)$$

Więcej o liniowej maszynie wektorów wspierających może być znalezione w literaturze [24, 37]. Identyfikacja próbki testowej sygnału akustycznego silnika indukcyjnego bez uszkodzeń została pokazana (Rys. 7, 8).



Rys. 7. Identyfikacja próbki testowej (sygnału akustycznego silnika bez uszkodzeń) z użyciem SMOFS-10, LSVM i próbek uczących sygnału akustycznego silnika indukcyjnego bez uszkodzeń i sygnału akustycznego silnika indukcyjnego z uszkodzonym prętem wirnika



Rys. 8. Identyfikacja próbki testowej (sygnału akustycznego silnika bez uszkodzeń) z użyciem SMOFS-10, LSVM i próbek uczących sygnału akustycznego silnika indukcyjnego bez uszkodzeń i sygnału akustycznego silnika indukcyjnego z dwoma uszkodzonymi prętami wirnika

3. Analiza sygnałów akustycznych trójfazowych silników indukcyjnych

Trzy obciążone trójfazowe silniki indukcyjne zostały użyte w badaniu. Te silniki były takie same. Silniki były sterowane w układzie otwartym. Każdy z nich miał parametry operacyjne: $U_N=220/380$ V (Δ/Y); $I_N=2,52/1,47$ A (Δ/Y); $P_N = 0,55$ kW; $n_N = 1400$ obrotów na minutę, gdzie U_n - znamionowe napięcie stojana, I_n - znamionowy prąd stojana, P_N - moc silnika, n_N - prędkość obrotowa wirnika.

Pierwszy silnik był silnikiem indukcyjnym bez uszkodzeń. Drugi silnik był silnikiem indukcyjnym z uszkodzonym prętym wirnika. Trzeci silnik był silnikiem indukcyjnym z dwoma uszkodzonymi prętami wirnika (Rys. 9).



Rys. 9. Wirnik trójfazowego klatkowego silnika indukcyjnego z dwoma uszkodzonymi prętami wirnika

W procesie tworzenia wzorca 12 pięciosekundowych próbek uczących było przetwarzanych przez zaproponowaną metodę rozpoznawania sygnału akustycznego. Te próbki uczące były używane do grupowania danych. Proces identyfikacji używał 60 próbek

(20 dla każdej klasy). Te próbki były używane do oceny skuteczności rozpoznawania sygnału akustycznego. Skuteczność była zdefiniowana jako:

$$E = \frac{NoPITS}{NoTS} 100\% \quad (6)$$

gdzie $NoPITS$ – liczba właściwie zidentyfikowanych próbek testowych określonej klasy użytej w procesie identyfikacji, $NoTS$ – liczba próbek testowych określonej klasy użytej w procesie identyfikacji, E – skuteczność rozpoznawania sygnału akustycznego określonej klasy.

$$TEoRoAS = \frac{E_1 + E_2 + E_3}{3} \quad (7)$$

gdzie $TEoRoAS$ - całkowita skuteczność rozpoznawania sygnału akustycznego, E_1 - skuteczność rozpoznawania sygnału akustycznego silnika indukcyjnego bez uszkodzeń, E_2 - skuteczność rozpoznawania sygnału akustycznego silnika indukcyjnego z uszkodzonym prętem wirnika, E_3 - skuteczność rozpoznawania sygnału akustycznego silnika indukcyjnego z dwoma uszkodzonymi prętami wirnika.

Tabela 1 prezentowała skuteczność rozpoznawania sygnału akustycznego trójfazowego silnika indukcyjnego zależnie od stanu silnika indukcyjnego. Tabela prezentowała również całkowitą skuteczność rozpoznawania sygnału akustycznego silnika indukcyjnego.

Tab. 1. Wyniki rozpoznawania sygnału akustycznego trójfazowego silnika indukcyjnego z użyciem SMOFS-10 i LSVM

| Stan silnika indukcyjnego | E [%] |
|---|---------------|
| Silnik bez uszkodzeń | 100 |
| Silnik z uszkodzonym prętem wirnika | 90 |
| Silnik z dwoma uszkodzonymi prętami wirnika | 100 |
| | $TEoRoAS$ [%] |
| 3 badane stany silnika | 96,66 |

Na podstawie tabeli 1 można zauważyć, że E było w zakresie 90-100% i $TEoRoAS$ było 96,66%.

4. Podsumowanie

Artykuł prezentował metodę rozpoznawania sygnału akustycznego trójfazowego silnika indukcyjnego. Ta metoda zawierała metody przetwarzania takie jak: FFT, SMOFS-10 i LSVM. SMOFS-10 była również nową metodą ekstrakcji cech. Analiza sygnałów akustycznych pokazała, że proponowane rozwiązanie było dobre do rozpoznawania stanu silnika indukcyjnego. Całkowita skuteczność rozpoznawania sygnału akustycznego silnika indukcyjnego była równa 96,66% dla 3 badanych stanów silnika. Zaprezentowana metoda może być używana dla diagnostyki stanów przedawaryjnych określonych silników indukcyjnych (ten same rozmiar, parametry operacyjne). To może być używane dla innych silników elektrycznych kiedy wzorce są wybrane właściwie. Ponadto metoda oparta na sygnale akustycznym może być użyta razem z metodami diagnostycznymi opartymi na sygnałach cieplnych i prądowymi. W ten sposób może to ulepszyć diagnostykę silników elektrycznych.

Podziękowania

Praca została zrealizowana w ramach działalności statutowej Katedry Automatyki i Inżynierii Biomedycznej, AGH (grantu dziekańskiego dla młodych naukowców) w roku 2015 (Adam Głowacz).

Literatura

1. Abramov IV, Nikitin YR, Abramov AI, Sosnovich EV, Bozek P. Control and Diagnostic Model of Brushless Dc Motor. *Journal of Electrical Engineering-Elektrotechnicky Casopis* 2014; 65 (5): 277-282.
2. Alshayeb M, Eisa Y, Ahmed MA. Object-Oriented Class Stability Prediction: A Comparison Between Artificial Neural Network and Support Vector Machine. *Arabian Journal for Science and Engineering* 2014; 39 (11): 7865-7876.
3. Andonova AV, Hinov NL. Thermographic Analysis of a Bridge Power Converter. *Journal of Electrical Engineering-Elektrotechnicky Casopis* 2014; 65 (6), 371-375.
4. Augustyniak P, Smolen M, Mikrut Z, Kantoch E. Seamless Tracing of Human Behavior Using Complementary Wearable and House-Embedded Sensors. *Sensors* 2014; 14 (5): 7831-7856.
5. Baranski M. New vibration diagnostic method of PM generators and traction motors - detecting of vibrations caused by unbalance. *2014 IEEE International Energy Conference (ENERGYCON 2014); Book Series: IEEE International Energy Conference: 28-32.*
6. Baranski M, Decner A, Polak A. Selected Diagnostic Methods of Electrical Machines Operating in Industrial Conditions. *IEEE Transactions on Dielectrics and Electrical Insulation* 2014; 21 (5): 2047-2054.
7. Dudek-Dyduch E, Tadeusiewicz R, Horzyk A. Neural network adaptation process effectiveness dependent of constant training data availability. *Neurocomputing* 2009; 72 (13-15): 3138-3149.
8. Duspara M, Sabo K, Stoic A. Acoustic emission as tool wear monitoring. *Tehnicki Vjesnik-Technical Gazette* 2014; 21 (5), 1097-1101.
9. Dzwonkowski A, Swedrowski L. Uncertainty analysis of measuring system for instantaneous power research. *Metrology and Measurement Systems* 2012; 19 (3): 573-582.
10. Glowacz A. Diagnostics of Synchronous Motor Based on Analysis of Acoustic Signals with the use of Line Spectral Frequencies and K-nearest Neighbor Classifier. *Archives of Acoustics* 2014; 39 (2): 189-194.
11. Glowacz A. Diagnostics of DC and Induction Motors Based on the Analysis of Acoustic Signals. *Measurement Science Review* 2014; 14 (5): 257-262.
12. Glowacz A, Glowacz Z. Diagnostics of DC machine based on analysis of acoustic signals with application of MFCC and classifier based on words. *Archives of Metallurgy and Materials* 2012; 57 (1): 179-183.
13. Glowacz A, Glowacz Z. Diagnostics of induction motor based on analysis of acoustic signals with application of FFT and classifier based on words. *Archives of Metallurgy and Materials* 2010; 55 (3): 707-712.
14. Glowacz A, Glowacz A, Korohoda P. Recognition of Monochrome Thermal Images of Synchronous Motor with the Application of Binarization and Nearest Mean Classifier. *Archives of Metallurgy and Materials* 2014; 59 (1): 31-34.
15. Glowacz Z, Kozik J. Detection of synchronous motor inter-turn faults based on spectral analysis of park's vector. *Archives of Metallurgy and Materials* 2013; 58 (1): 19-23.
16. Hachaj T, Ogiela MR. Application of neural networks in detection of abnormal brain perfusion regions. *Neurocomputing* 2013; 122 (Special Issue): 33-42.
17. Jun S, Kochan O. Investigations of Thermocouple Drift Irregularity Impact on Error of their Inhomogeneity Correction. *Measurement Science Review* 2014; 14 (1): 29-34.
18. Krolczyk GM, Nieslony P, Legutko S. Determination of tool life and research wear during duplex stainless steel turning. *Archives of Civil and Mechanical Engineering* 2015; 15 (2): 347-354.

19. Krolczyk GM, Krolczyk JB, Legutko S, Hunjet A. Effect of the disc processing technology on the vibration level of the chipper during operations. *Tehnicki Vjesnik-Technical Gazette* 2014; 21 (2), 447-450.
20. Krolczyk JB. An attempt to predict quality changes in a ten-component granular system. *Tehnicki Vjesnik-Technical Gazette* 2014; 21 (2), 255-261.
21. Kundegorski M, Jackson PJB, Ziolk B. Two-Microphone Dereverberation for Automatic Speech Recognition of Polish. *Archives of Acoustics* 2014; 39 (3): 411-420.
22. Kulka Z. Advances in Digitization of Microphones and Loudspeakers. *Archives of Acoustics* 2011; 36 (2): 419-436.
23. Mahmood A, Alsulaiman M, Muhammad G. Automatic Speaker Recognition Using Multi-Directional Local Features (MDLF). *Arabian Journal for Science and Engineering* 2014; 39 (5): 3799-3811.
24. MathWorks – MATLAB and SimuLink for Technical Computing 2015; www.mathworks.com.
25. Nadolny K, Kaplonek W. Analysis of Flatness Deviations for Austenitic Stainless Steel Workpieces after Efficient Surface Machining. *Measurement Science Review* 2014; 14 (4), 204-212.
26. Nafisi H, Abedi M, Gharehpetian GB. Locating Pd in Transformers through Detailed Model and Neural Networks. *Journal of Electrical Engineering-Elektrotechnicky Casopis* 2014; 65 (2), 75-82.
27. Paydarnia H, Hajiaghahi S, Abbaszadeh K. Improved Structure of PNN Using PCA in Transformer Fault Diagnostic. *Arabian Journal for Science and Engineering* 2014; 39 (6): 4845-4851.
28. Pleban D. Definition and Measure of the Sound Quality of the Machine. *Archives of Acoustics* 2014; 39 (1): 17-23.
29. Rusinski E, Moczko P, Odyjas P, Pietrusiak D. Investigation of vibrations of a main centrifugal fan used in mine ventilation. *Archives of Civil and Mechanical Engineering* 2014; 14 (4), 569-579.
30. Stepien K. Research on a surface texture analysis by digital signal processing methods. *Tehnicki Vjesnik-Technical Gazette* 2014; 21 (3): 485-493.
31. Swedrowski L, Duzinkiewicz K, Grochowski M, Rutkowski T. Use of neural networks in diagnostics of rolling-element bearing of the induction motor. *Smart Diagnostics V* 2014; Book Series: Key Engineering Materials; 588: 333-342.
32. Turchenko I, Kochan V, Sachenko A, Kochan R, Stepanenko A, Daponte P, Grimaldi D. Simulation modeling of neural-based method of multi-sensor output signal recognition. *2006 IEEE Instrumentation and Measurement Technology Conference Proceedings; Vols 1-5: 1530-1535. DOI: 10.1109/IMTC.2006.328653.*
33. Valis D, Zak L, Pokora O. Contribution to system failure occurrence prediction and to system remaining useful life estimation based on oil field data. *Proceedings of the Institution of Mechanical Engineers Part O-Journal of Risk and Reliability* 2015; 229 (1): 36-45.
34. Valis D, Pietrucha-Urbanik K. Utilization of diffusion processes and fuzzy logic for vulnerability assessment. *Eksplatacja i Niezawodnosc-Maintenance and Reliability* 2014; 16 (1): 48-55.
35. Umasankar L, Kalaiarasi N. Internal Fault Identification and Classification of Transformer with the Aid of Radial Basis Neural Network (RBNN). *Arabian Journal for Science and Engineering* 2014; 39 (6): 4865-4873.
36. Wu RC, Tsai JI, Chiang CT, Ouyang CS. Detection of induction motor operation condition by acoustic signal. *8th IEEE International Conference on Industrial Informatics (INDIN) 2010: 792-797.*
37. Zhang DZ, Xia BK. Soft Measurement of Water Content in Oil-Water Two-Phase Flow Based on RS-SVM Classifier and GA-NN Predictor. *Measurement Science Review* 2014; 14 (4), 219-226.
38. Zhao Z, Wang C, Zhang YG, Sun Y. Latest progress of fault detection and localization in complex Electrical Engineering. *Journal of Electrical Engineering-Elektrotechnicky Casopis* 2014; 65 (1): 55-59.