

Adam GLOWACZ  
Witold GLOWACZ  
Zygfryd GLOWACZ

## RECOGNITION OF ARMATURE CURRENT OF DC GENERATOR DEPENDING ON ROTOR SPEED USING FFT, MSAF-1 AND LDA

### ROZPOZNAWANIE SYGNAŁÓW PRĄDU TWORNIKA GENERATORA PRĄDU STAŁEGO W ZALEŻNOŚCI OD PRĘDKOŚCI OBROTOWEJ WIRNIKA Z ZASTOSOWANIEM FFT, MSAF-1 I LDA\*

*Recognition of states of electrical systems is very important in industrial plants. Article describes a recognition method of early fault detection of DC generator. The proposed approach is based on an analysis of the patterns. These patterns are the armature currents of selected electrical machine. Information contained in signals of armature current is depending on generator state. Researches were carried out for four states of generator with the use of Fast Fourier Transform (FFT), method of selection of amplitudes of frequencies (MSAF-1) and Linear Discriminant Analysis (LDA). The results of analysis show that the method is efficient and can be used to protect DC generators. This method was verified with the aid of acoustic signals recognition method.*

**Keywords:** fault detection, pattern recognition, armature current, DC generator.

Rozpoznawanie stanów układów elektrycznych jest bardzo ważne w zakładach przemysłowych. W artykule opisano metodę rozpoznawania stanów przedawaryjnych generatora prądu stałego. Proponowane podejście jest oparte na badaniu wzorców. Wzorce te są prądami twornika wybranej maszyny elektrycznej. Informacja zawarta w sygnałach prądu twornika jest zależna od stanu generatora. Przeprowadzono badania dla czterech stanów generatora z zastosowaniem FFT, metody wyboru amplitud częstotliwości (MSAF-1) i liniowej analizy dyskryminacyjnej (LDA). Wyniki analizy pokazują, że metoda jest skuteczna i metoda może być stosowana do ochrony generatorów prądu stałego. Metoda została zweryfikowana za pomocą metody rozpoznawania sygnałów akustycznych.

**Słowa kluczowe:** detekcja uszkodzenia, rozpoznawanie wzorców, prąd twornika, generator prądu stałego.

### 1. Introduction

Nowadays rotating machines are more complex than 20 years ago. Electrical generators deteriorate over time gradually. Condition of machines can be recovered through appropriate maintenance activities. In recent years, many signal processing methods were applied for diagnostics of electrical devices and machines [6, 7, 10, 11, 41]. Most of them were based on patterns recognition. Development of diagnostic systems is important to guarantee quality of machines and materials [2, 8, 11-14, 27, 29, 30, 33, 35, 36, 40, 44]. Diagnostic of electric machines can be based on various signals such as: electric, acoustic, thermal, magnetic or vibroacoustic [6, 8-11, 15, 16, 42, 43]. An armature current is a diagnostic signal. It can be measured by measuring card and LEM current sensor. Armature current can be used to diagnose type of fault. The analysis of armature current of Direct Current generator can decrease the costs of maintenance of these types of generators in the industrial plant and wind plants. It can also lead to the more modern diagnostic systems.

In this paper authors propose early fault detection technique. This technique uses method of selection of amplitudes of frequencies (MSAF-1) and Linear Discriminant Analysis to classify feature vector.

### 2. Recognition of armature current of Direct Current generator

Recognition of armature current is not an easy problem. The database of patterns is needed to solve this problem. This database is used in a pattern creation process. Second database of test samples is needed in an identification process. These databases should be prepared properly.

The process of recognition of armature current can be defined as two processes: pattern creation process and identification process. First of them starts with registering of armature current. Signal of armature current is converted to the TXT file with data. After that TXT file is split into small samples of current. The next step is selection of amplitudes of frequencies. In this purpose authors propose new method described in chapter 2.2. The method gives us 1 feature vector from 1 sample. At the end of the pattern creation process Linear Discriminant Analysis is used to create patterns (Fig. 1).

The identification process is based on the same methods as previous process. Feature vectors are calculated by the same processing methods. After that feature vectors are compared by Linear Discriminant Analysis.

(\*) Tekst artykułu w polskiej wersji językowej dostępny w elektronicznym wydaniu kwartalnika na stronie [www.ein.org.pl](http://www.ein.org.pl)

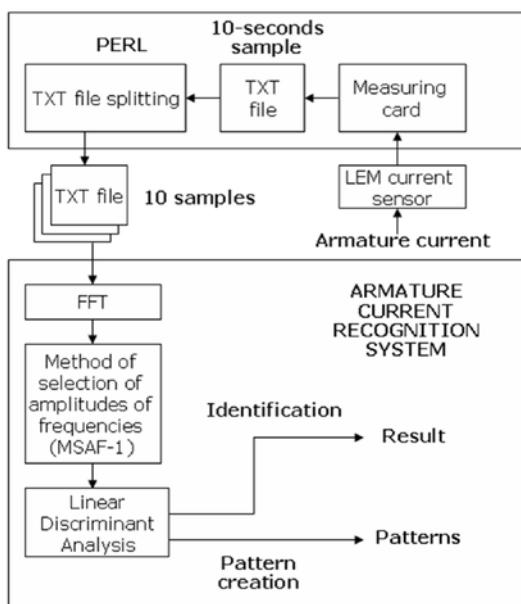


Fig. 1. Process of recognition of armature current of DC generator with the use of method of selection of amplitudes of frequencies and Linear Discriminant Analysis

## 2.1. Measurement of armature current

Direct current generator has been loaded by an external resistance. This armature current was measured by LEM current sensor and measuring card. Then signal of armature current was converted to the text file. After that TXT file was split into small samples of current. Each sample had duration time of 1 second. Sampling frequency of measuring card was 20000 Hz, so sample contained 20000 values. Spectrum of frequency of armature current was presented in Figure 2.

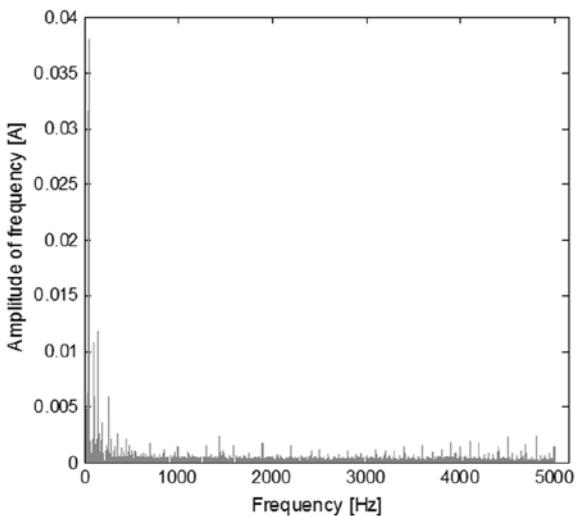


Fig. 2. Amplitudes of frequencies of armature current depending on frequency for faultless DC generator with rotor speed 600 rpm

## 2.2. Method of selection of amplitudes of frequencies

Proposed method of selection of amplitudes of frequencies (MSAF-1) was based on differences between amplitudes of various states of DC generator. The armature current was dependent on the state, rotor speed and construction of generator.

Steps of MSAF-1 are following:

- 1) Calculate spectrum of frequency for each state of DC generator.
- 2) Calculate differences between states of DC generator: **a-b**, **a-c**, **a-d**, **b-c**, **b-d**, **c-d**, where **a** denoted the spectrum of armature current of faultless DC generator, **b** denoted the spectrum of armature current of DC generator with 3 shorted rotor coils, **c** denoted the spectrum of armature current of DC generator with 6 shorted rotor coils, **d** denoted the spectrum of armature current of DC generator with broken rotor coil.
- 3) Calculate absolute values of differences between states of DC generator:  $|a-b|$ ,  $|a-c|$ ,  $|a-d|$ ,  $|b-c|$ ,  $|b-d|$ ,  $|c-d|$ .
- 4) Select 8 maximal amplitudes of the frequencies for each difference between states of DC generator:  $\max_1|a-b|$ , ...,  $\max_8|a-b|$ , ...,  $\max_1|c-d|$ , ...,  $\max_8|c-d|$  and determine corresponding frequencies.
- 5) Find common frequencies (1-8) and then determine for these frequencies the amplitudes of spectrum for each state of DC generator.

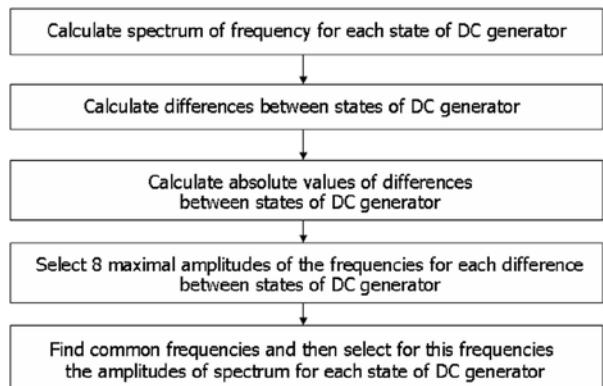


Fig. 3. Block scheme of MSAF-1

The method of selection of amplitudes of frequencies of DC generator in form of block scheme has been presented in Fig. 3.

Differences between spectra for 4 states of DC generator with rotor speed 600 rpm were presented in Figures 4–6. Selection of common amplitudes of frequencies for 4 states of DC generator with rotor speed 600 rpm was presented in Figure 7.

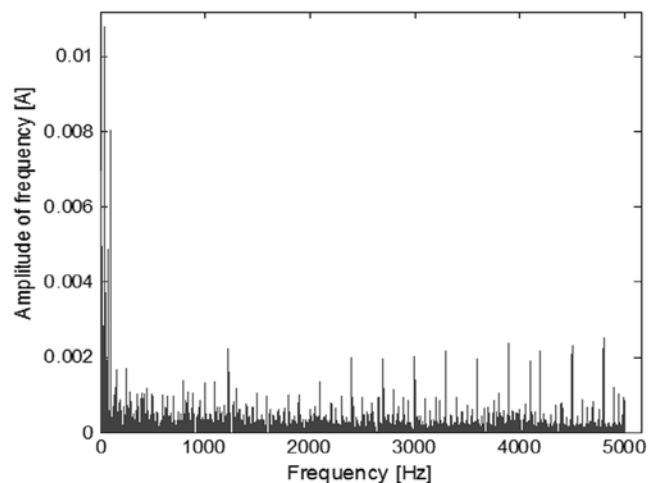


Fig. 4. Difference between frequency spectrum of armature current of faultless DC generator and DC generator with 3 shorted rotor coils (**a-b**) with rotor speed 600 rpm

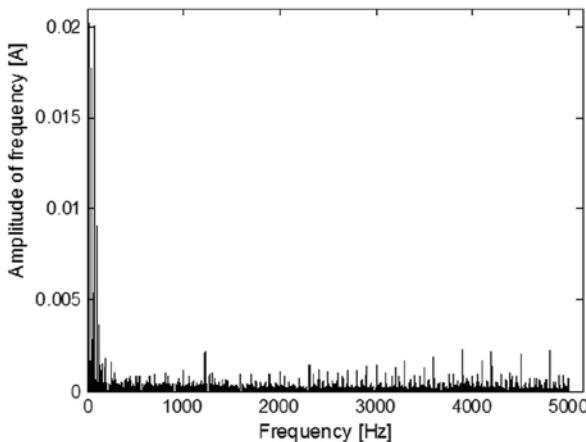


Fig. 5. Difference between frequency spectrum of armature current of faultless DC generator and DC generator with 6 shorted rotor coils ( $|a-c|$ ) with rotor speed 600 rpm

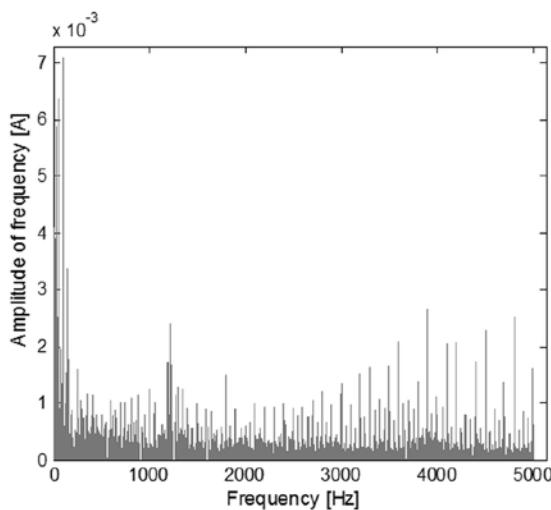


Fig. 6. Difference between frequency spectrum of armature current of faultless DC generator and DC generator with broken coil ( $|a-d|$ ) with rotor speed 600 rpm

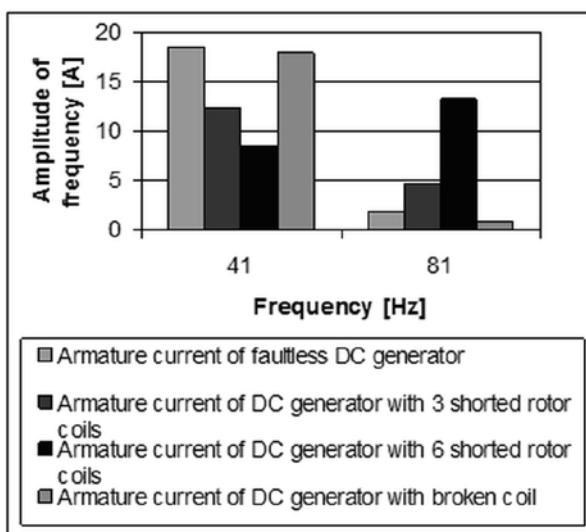


Fig. 7. Selection of common amplitudes of frequencies for 4 states of DC generator with rotor speed 600 rpm (41 and 81 Hz)

Selected amplitudes of frequencies formed the feature vector used by Linear Discriminant Analysis.

### 2.3. Linear Discriminant Analysis

There are many methods for data processing and feature vectors classification [3–5, 17–26, 28, 31, 32, 34, 37–39, 41, 45–48]. The feature vectors are processed by Linear Discriminant Analysis (LDA). LDA maximizes the ratio (quotient) of between-class variance to the within-class variance. Maximal ratio guarantees separability between the classes. Data sets and the test sets should be formulated appropriately at the beginning of classification. Training sets are defined as  $\text{set}_1, \dots, \text{set}_k$ . Next the mean for each training set and mean of all training sets are computed.

The means of sets  $\text{set}_1, \dots, \text{set}_k$  are defined as  $\mu_1, \dots, \mu_k$ . Whereas the mean of all training sets is called  $\mu$ . This mean is given by equation 1:

$$\mu = p_1 \times \mu_1 + \dots + p_k \times \mu_k \quad (1)$$

where  $p_1, \dots, p_k$  are the a priori probabilities of the classes.

Next a linear combination of features is created by Linear Discriminant Analysis. This method uses within-class scatter matrix and between-class scatter matrix [1, 32]. Both matrices are used to formulate criteria for separability of the classes. Within-class scatter matrix is defined as follows:

$$W = \sum_{k=1}^c \sum_{i=1}^{N_k} (x_i^k - \mu_k)(x_i^k - \mu_k)^T \quad (2)$$

where  $\mu_k$  denotes the mean of class  $k$ ,  $x_i^k$  is the sample with the index  $i$  of class  $k$ ,  $c$  denotes the number of classes of training sets, and  $N_k$  is the number of samples of class  $k$  [1, 31].

Between-class scatter matrix is expressed by formula:

$$B = \sum_{k=1}^c (\mu_k - \mu)(\mu_k - \mu)^T \quad (3)$$

where  $\mu$  denotes the mean of all training sets,  $\mathbf{x}$ ,  $\boldsymbol{\mu}$  vectors of dimensions equal to the selected number of common frequencies.

The ratio of between-class scatter matrix determinant to the within-class scatter matrix determinant is the criterion of Linear Discriminant Analysis. In this method it is essential to maximize the ratio ( $\text{Det}[B] / \text{Det}[W]$ ) [31]. The axes of the transformed space are defined by the solution obtained by maximizing the ratio ( $\text{Det}[B] / \text{Det}[W]$ ).

### 3. The results of recognition of armature current

Measuring card and LEM current sensor were used to record armature current signals. Parameters of current signal were: sampling frequency - 20000 Hz, format - TXT. Operation parameters of DC generator with rotor speed 600 rpm were following:

- faultless DC generator:  $U_a = 51$  V,  $I_a = 70$  A,  $U_e = 159.1$  V,  $I_e = 2.5$  A,
- DC generator with 3 shorted rotor coils:  $U_a = 50.5$  V,  $I_a = 71.5$  A,  $U_e = 160.8$  V,  $I_e = 2.5$  A,  $I_{sc} = 58$  A,
- DC generator with 6 shorted rotor coils:  $U_a = 50$  V,  $I_a = 70.5$  A,  $U_e = 161.2$  V,  $I_e = 2.5$  A,  $I_{sc} = 138$  A,

– DC generator with broken coil:  $U_a = 50.5$  V,  $I_a = 70$  A,  $U_e = 163.3$  V,  $I_e = 2.5$  A,  
where  $U_a$  - armature voltage of DC generator,  $I_a$  - armature current of DC generator,  $U_e$  - excitation voltage of DC generator,  $I_e$  - excitation current of DC generator,  $I_{sc}$  - current of the short-circuit.

Groups of three and six loops rotor coils were shorted with the use of resistance  $R_{sc} = 0.085$  mΩ. This resistance was connected with DC generator to protect the rotor windings. Investigations were carried out for four current signals: armature current of faultless DC generator, armature current of generator with 3 shorted rotor coils, armature current of generator with 6 shorted rotor coils (Fig. 8), armature current of generator with broken coil. 32 training samples with a duration of one second were used in the pattern creation process. 128 test samples with a duration of one second were used in the identification process.

#### SHORT CIRCUIT

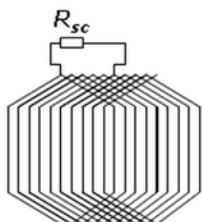


Fig. 8. Scheme of rotor windings of DC generator with 6 shorted coils

Armature current recognition efficiency determines the relationship:

$$ACRE = \frac{NoWRTS}{NoATS} \cdot 100\% \quad (4)$$

where:  $ACRE$  – armature current recognition efficiency,  $NoWRTS$  – number of well recognized test samples,  $NoATS$  – number of all test samples.

Researches were carried out for DC generator with rotor speed 700 rpm, 600 rpm, 500 rpm, 400 rpm. Armature current recognition efficiency depending on the rotations of rotor is presented in Figures 9 and 10.

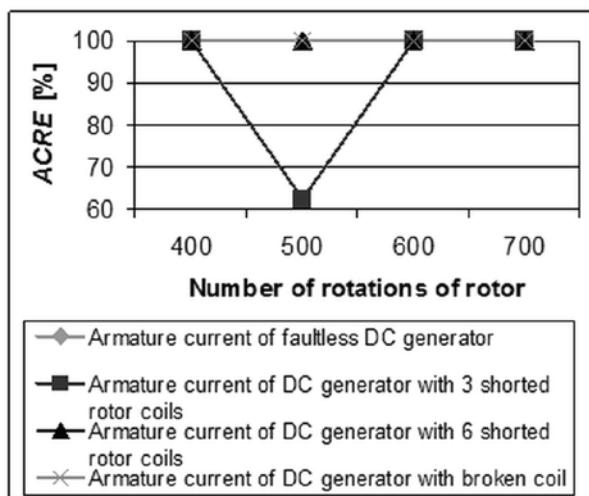


Fig. 9. Armature current recognition efficiency depending on the rotor speed of DC generator

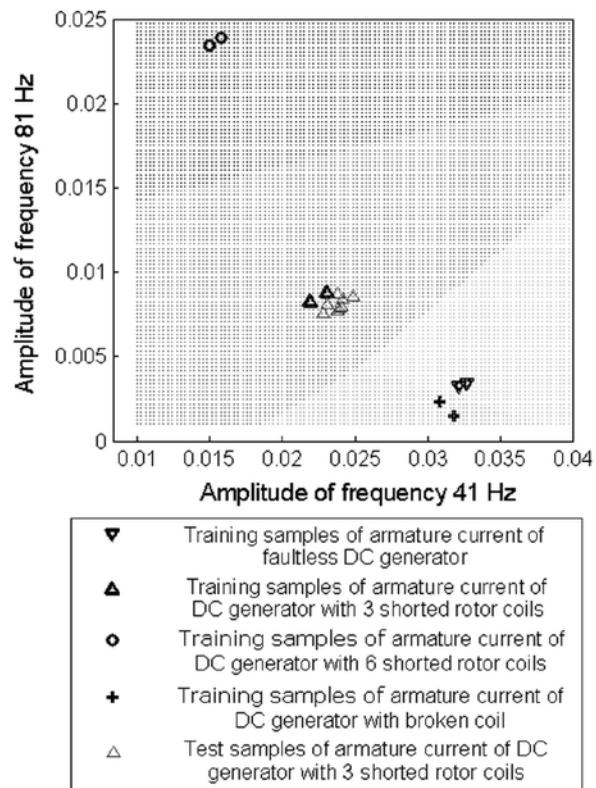


Fig. 10. Recognition of test samples of armature current of DC generator with 3 shorted rotor coils with rotor speed 600 rpm

Armature current recognition efficiency of faultless generator was 100%. 8 of 8 test samples were classified as faultless generator. The samples were prepared on the basis of measurements and authors knew that these 8 test samples were generated by faultless generator. Armature current recognition efficiency of generator with 3 shorted rotor coils was 62.5-100%. Armature current recognition efficiency of generator with 6 shorted rotor coils was 100%. Armature current recognition efficiency of generator with broken coil was 100%. Results for the two-element vectors were good. If the system selects the number of common amplitudes of frequency equal 1-8, then LDA will process 1-8 element vectors.

#### 4. Conclusion

In this paper authors proposed technique and a system of recognition of armature current of DC generator. Researches involving the application of signal processing methods to armature current recognition has been carried out for faultless DC generator and faulty DC generator.

The experiments proved that the methods such as MSAF-1, FFT, and LDA were sufficient enough for diagnostics of DC generator. Armature current recognition efficiency of DC generator was 100% for rotor speed 400 rpm, 600 rpm, 700 rpm. When the rotor speed was equal 500, then armature current recognition efficiency of DC generator was 62.5-100%.

Advantage of this method over acoustic signal recognition is that the armature current is easier to process. Further researches will focus on implementations of new processing methods and cooperation of various diagnostic signals.

**Acknowledgments:**

*This work has been partly supported by AGH University of Science and Technology, grant nr 11.11.120.612 (Adam Glowacz).*

*This work has been partly supported by AGH University of Science and Technology, grant nr 11.11.120.815 (Witold Glowacz).*

*This work has been partly supported by AGH University of Science and Technology, grant nr 11.11.120.354 (Zygfryd Glowacz).*

**References**

1. Balakrishnama S, Ganapathiraju A. Linear Discriminant Analysis - A brief tutorial. Presentation, Institute for Signal and Information Processing Department of Electrical and Computer Engineering Mississippi State University.
2. Krolczyk G, Legutko S, Stoic A. Influence of cutting parameters and conditions onto surface hardness of Duplex Stainless Steel after turning process. *Tehnicki Vjesnik-Technical Gazette* 2013; 20 (6): 1077-1080.
3. 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.
4. Czopek K. Cardiac Activity Based on Acoustic Signal Properties. *Acta physica polonica A* 2012; 121 (1A): A42-A45.
5. 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.
6. Dudzikowski I, Ciurys M. Analysis of operation of a car starter with BLDC motor. *Przeglad Elektrotechniczny* 2010; 86 (4): 166-169.
7. Florkowski M, Furgal J, Kuniewski M. Impact of transformers from overvoltages transferred through windings. *Przeglad Elektrotechniczny* 2012; 88 (5A): 104-107.
8. Glowacz A, Glowacz W. Dc machine diagnostics based on sound recognition with application of FFT and fuzzy logic. *Przeglad Elektrotechniczny* 2008; 84 (12): 43-46.
9. 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.
10. Glowacz A, Glowacz A, Glowacz Z. Diagnostics of Direct Current generator based on analysis of monochrome infrared images with the application of cross-sectional image and nearest neighbor classifier with Euclidean distance. *Przeglad Elektrotechniczny* 2012; 88 (6): 154-157.
11. Glowacz W. Diagnostics of Induction motor based on Spectral Analysis of Stator Current with Application of Backpropagation Neural Network. *Archives of Metallurgy and Materials* 2013; 58 (2): 559-562.
12. Stepien K. Research on a surface texture analysis by digital signal processing methods. *Tehnicki Vjesnik-Technical Gazette* 2014; 21 (3): 485-493.
13. Gogola D, Krafcik A, Strbak O, Frollo I. Magnetic Resonance Imaging of Surgical Implants Made from Weak Magnetic Materials. *Measurement Science Review* 2013; 13 (4): 165-168.
14. Smolnicki T, Stanco M, Pietrusiak D. Distribution of loads in the large size bearing – problems of identification. *Tehnicki Vjesnik-Technical Gazette* 2013; 20 (5): 831-836.
15. Golebiowski L, Golebiowski M, Mazur D. Unscented kalman filter in rotor diagnostic testing of the asynchronous motor. *Przeglad Elektrotechniczny* 2011; 87 (8): 48-52.
16. Golebiowski L, Golebiowski M, Mazur D. Controlling of the 1-and 3-phase power factor correction (PFC) rectifiers, *Przeglad Elektrotechniczny* 2011; 87 (8): 53-58.
17. Gorski P, Morzynski L. Active Noise Reduction Algorithm Based on NOTCH Filter and Genetic Algorithm. *Archives of Acoustics* 2013; 38 (2): 185-190.
18. Hachaj T, Ogiela MR. Application of neural networks in detection of abnormal brain perfusion regions. *Neurocomputing* 2013; 122 (Special Issue): 33-42.
19. Hachaj T, Ogiela MR. A system for detecting and describing pathological changes using dynamic perfusion computer tomography brain maps. *Computers in Biology and Medicine* 2011; 41 (6): 402-410.
20. Valis D, Zak L, Walek A, Pietrucha-Urbaniak K. Selected mathematical functions used for operation data information. 22nd Annual Conference on European Safety and Reliability (ESREL), Amsterdam, Netherlands, Sep 29-Oct 02, Safety, Reliability and Risk Analysis: Beyond the Horizon 2014, 1303-1308.
21. Jaworek J, Augustyniak P. A cardiac telerehabilitation application for mobile devices. *IEEE Conference on Computing in Cardiology* 2011; Hangzhou, China: 241-244.
22. Glowacz A. Diagnostics of DC and Induction Motors Based on the Analysis of Acoustic Signals. *Measurement Science Review* 2014; 14 (5): 257-262.
23. Kantoch E, Smolen M, Augustyniak P, Kowalski P. Wireless Body Area Network System based on ECG and Accelerometer Pattern. *IEEE Conference on Computing in Cardiology* 2011; Hangzhou, China: 245-248.
24. Kmiec M, Glowacz A, Dziech A. Towards robust visual knife detection in images: active appearance models initialised with shape-specific interest points. *Multimedia communications, services and security, MCSS, Book Series: Communications in Computer and Information Science* 2012, 287, 148–158.
25. Zajdel M, Filipowicz B. Exit selection process during crowd evacuation, modelled on the cockroach emergent behaviour. *Bulletin of the Polish Academy of Sciences-Technical Sciences* 2014; 62 (3): 557-563.
26. Korohoda P, Dabrowski A. Wavelet-like decomposition stage with windowed filters defined for the Discrete Trigonometric Transforms (DTTs). *Przeglad Elektrotechniczny* 2012; 88 (6): 30-35.
27. Kulesza G, Panek P, Zieba P. Silicon Solar Cells Efficiency Improvement by the Wet Chemical Texturization in the HF/HNO<sub>3</sub>/diluent solution. *Archives of Metallurgy and Materials* 2013; 58 (1): 291-295.
28. Lin DF, Chen PH, Williams M. Measurement and Analysis of Current Signals for Gearbox Fault Recognition of Wind Turbine. *Measurement Science Review* 2013; 13 (2): 89-93.
29. Kozlowski M, Choromanski W. Dynamics simulation studies on the electric city car with an electromechanical differential and the rear wheels drive. *Bulletin of the Polish Academy of Sciences-Technical Sciences* 2013; 61 (3): 661-673.

30. Koscielny JM, Syfert M. Application properties of methods for fault detection and isolation in the diagnosis of complex large-scale processes. Bulletin of the Polish Academy of Sciences-Technical Sciences 2014; 62 (3): 571-582.
31. Martinez AM, Kak AC. PCA versus LDA IEEE Transactions on Pattern Analysis and Machine Intelligence 2001; 23 (2): 228-233.
32. MathWorks – MATLAB and SimuLink for Technical Computing 2014; www.mathworks.com.
33. Mazurkiewicz D. Problems of identification of strength properties of rubber materials for purposes of numerical analysis: a review. Archives of Civil and Mechanical Engineering 2010; 10 (1): 69-84.
34. Pleban D, Piochowicz J, Kosala K. The Inversion Method in Measuring Noise Emitted by Machines in Opencast Mines of Rock Material. International Journal of Occupational Safety and Ergonomics 2013; 19 (2): 321-331.
35. Pietrzak K, Olesinska W, Kalinski D, Strojny-Nedza A. The relationship between microstructure and mechanical properties of directly bonded copper-alumina ceramics joints. Bulletin of the Polish Academy of Sciences-Technical Sciences 2014; 62 (1): 23-32.
36. Kulka Z. Advances in Digitization of Microphones and Loudspeakers. Archives of Acoustics 2011; 36 (2): 419-436.
37. Orzechowski T, Izworski A, Tadeusiewicz R, Chmurzynska K, Radkowski P, Gatkowska I. Processing of pathological changes in speech caused by dysarthria. Proceedings of ISPACS 2005, IEEE International Symposium on Intelligent Signal Processing and Communication Systems ISPACS 2005: 49-52.
38. Roj J. Neural Network Based Real-time Correction of Transducer Dynamic Errors. Measurement Science Review 2013, 13 (6), 286-291.
39. Skrodzka EB, Linde BBJ, Krupa A. Effect of Bass Bar Tension on Modal Parameters of a Violin's Top Plate. Archives of Acoustics 2014; 39 (1): 145-149.
40. Barglik J, Smalcerz A, Przylucki R, Dolezel I. 3D modeling of induction hardening of gear wheels. Journal of Computational and Applied Mathematics 2014; Vol. 270: 231-240.
41. Smolen M, Kantoch E, Augustyniak P, Kowalski P. Wearable Patient Home Monitoring Based on ECG and ACC Sensors. 5th European Conference of the International Federation for Medical and Biological Engineering, IFMBE Proceedings 2012; 37: 941-944.
42. Sulowicz M, Borkowski D, Wegiel T, Weinreb K. Specialized diagnostic system for induction motors. Przeglad Elektrotechniczny 2010; 86 (4): 285-291.
43. Szymanski Z. Application of the Magnetic Field Distribution in Diagnostic Method of Special Construction Wheel Traction Motors. Advanced Computer Techniques in Applied Electromagnetics, Book Series: Studies in Applied Electromagnetics and Mechanics, 2008; 30: 449-456.
44. Tokarski T, Wzorek L, Dybiec H. Microstructure and Plasticity of Hot Deformed 5083 Aluminum Alloy Produced by Rapid Solidification and Hot Extrusion. Archives of Metallurgy and Materials 2012; 57 (4): 1253-1259.
45. Trzupek M, Ogiela MR, Tadeusiewicz R. Intelligent image content semantic description for cardiac 3D visualisations. Engineering Applications of Artificial Intelligence 2011; 24 (8): 1410-1418.
46. Tu YQ, Yang HY, Zhang HT, Liu XY. CMF Signal Processing Method Based on Feedback Corrected ANF and Hilbert Transformation. Measurement Science Review 2014; 14 (1): 41-47.
47. Pleban D. Definition and Measure of the Sound Quality of the Machine. Archives of Acoustics 2014; 39 (1): 17-23.
48. Ziolk M, Galka J, Ziolk B, Drwiga T. Perceptual Wavelet Decomposition for Speech Segmentation. 11th Annual Conference of the International Speech Communication Association 2010 (INTERSPEECH 2010), Vols 3 and 4; 2234-2237.

---

**Adam GLOWACZ****Witold 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 Krakow, Poland

**Zygfryd GLOWACZ**

AGH University of Science and Technology  
 Faculty of Electrical Engineering, Automatics, Computer Science  
 and Biomedical Engineering  
 Department of Power Electronics and Energy Control Systems  
 al. A. Mickiewicza 30, 30-059 Krakow, Poland

---

E-mails: adglow@agh.edu.pl, wglowacz@agh.edu.pl,  
 glowacz@agh.edu.pl

---

## **Adam GŁOWACZ**

AGH Akademia Górnictwo-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

## **Witold GŁOWACZ**

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

## **Zygfryd GŁOWACZ**

AGH Akademia Górnictwo-Hutnicza,  
Wydział Elektrotechniki, Automatyki, Informatyki i Inżynierii Biomedycznej,  
Katedra Energoelektroniki i Automatyki Systemów Przetwarzania Energii,  
al. A. Mickiewicza 30, 30-059 Kraków,  
e-mail: glowacz@agh.edu.pl

### **Rozpoznawanie sygnałów prądu twornika generatora prądu stałego w zależności od prędkości obrotowej wirnika z zastosowaniem FFT, MSAF-1 i LDA**

**Słowa kluczowe:** *Detekcja uszkodzenia, rozpoznawanie wzorców, prąd twornika, generator prądu stałego*

**Streszczenie:** Rozpoznawanie stanów układów elektrycznych jest bardzo ważne w zakładach przemysłowych. W artykule opisano metodę rozpoznawania stanów przedawaryjnych generatora prądu stałego. Proponowane podejście jest oparte na badaniu wzorców. Wzorce te są prądami twornika wybranej maszyny elektrycznej. Informacja zawarta w sygnałach prądu twornika jest zależna od stanu generatora. Przeprowadzono badania dla czterech stanów generatora z zastosowaniem szybkiej transformaty Fouriera (FFT), metody wyboru amplitud częstotliwości (MSAF-1) i liniowej analizy dyskryminacyjnej (LDA). Wyniki analizy pokazują, że metoda jest skuteczna i może być stosowana do ochrony generatorów prądu stałego. Metoda została zweryfikowana za pomocą metody rozpoznawania sygnałów akustycznych.

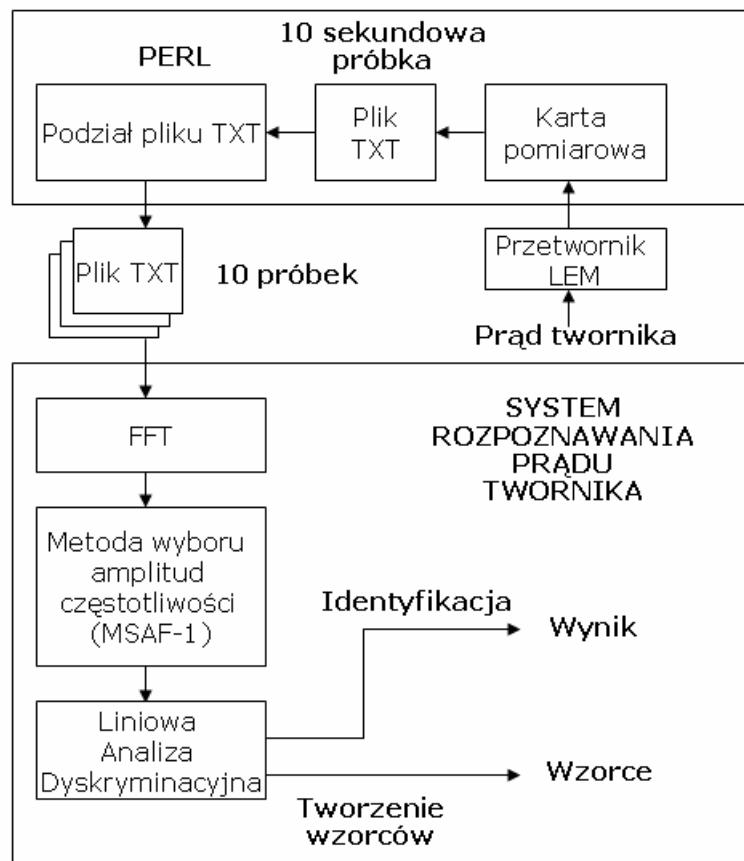
## **1. Wstęp**

Obecnie maszyny wirujące są bardziej złożone niż 20 lat temu. Generatory elektryczne ulegają z czasem stopniowo degradacji. Stan maszyn może być przywrócony do poprzedniego za pomocą odpowiednich czynności odnowy. W ostatnich latach wiele metod przetwarzania sygnału zastosowano do diagnozowania urządzeń i maszyn elektrycznych [6, 7, 10, 11, 41]. Większość z nich opiera się na rozpoznawaniu wzorców. Rozwój systemów diagnostycznych jest ważny dla zapewnienia jakości maszyn i materiałów [2, 8, 11-14, 27, 29, 30, 33, 35, 36, 40, 44]. Diagnostyka maszyn elektrycznych może być oparta na różnych sygnałach, takich jak: elektryczne, akustyczne, cieplne, magnetyczne lub wibroakustyczne [6, 8-11, 15, 16, 42,

43]. Prąd twornika jest sygnałem diagnostycznym. Może być zmierzony przez przetwornik LEM i kartę pomiarową. Prąd twornika może być używany do diagnozowania rodzaju uszkodzenia. Analiza prądu twornika generatora prądu stałego może zmniejszyć koszty utrzymania tego typu generatorów w zakładach przemysłowych i elektrowniach wiatrowych. To może również prowadzić do bardziej nowoczesnych systemów diagnostycznych. W tym artykule autorzy proponują technikę detekcji stanów przedawaryjnych. Technika ta używa metody wyboru amplitud częstotliwości (MSAF-1) i wykorzystuje Liniową Analizę Dyskryminacyjną, aby sklasyfikować wektor cech.

## 2. Rozpoznawanie prądu twornika generatora prądu stałego

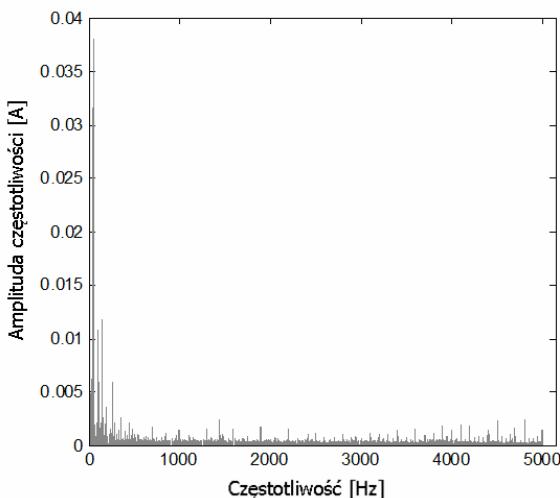
Rozpoznawanie prądu twornika nie jest łatwym problemem. Baza wzorców jest potrzebna, aby rozwiązać ten problem. Ta baza danych jest stosowana w procesie tworzenia wzorca. Druga baza danych prób testowych jest potrzebna w procesie identyfikacji. Bazy te powinny być przygotowane właściwie. Proces rozpoznawania prądu twornika może być zdefiniowany jako dwa procesy: proces tworzenia wzorca i proces identyfikacji. Pierwszy z nich rozpoczyna się rejestracją prądu twornika. Sygnał prądu twornika jest przekształcany w plik tekstowy z danymi. Po tym plik tekstowy jest dzielony na małe próbki prądu. Następnym krokiem jest wybór amplitud częstotliwości. W tym celu autorzy proponują nową metodę opisaną w podrozdziale 2.2. Metoda daje nam 1 wektor cech z 1 próbki. Na koniec procesu tworzenia wzorca Liniowa Analiza Dyskryminacyjna jest stosowana do tworzenia wzorców (rys. 1). Proces identyfikacji oparty jest na tych samych metodach jak proces poprzedni. Wektory cech są obliczane przez te same metody przetwarzania. Następnie wektory cech są porównywane przez Liniową Analizę Dyskryminacyjną.



Rys.1. Proces rozpoznawania prądu twornika generatora prądu stałego z użyciem metody wyboru amplitud częstotliwości i Liniowej Analizy Dyskryminacyjnej

## 2.1. Pomiar prądu twornika

Generator prądu stałego obciążono rezystancją zewnętrzną. Prąd twornika był mierzony przez przetwornik prądowy LEM i kartę pomiarową. Następnie sygnał prądu twornika został przekształcony w plik tekstowy. Kolejno plik TXT został podzielony na małe próbki prądu. Każda próbka miała czas trwania 1 sekundę. Częstotliwość próbkowania karty pomiarowej wynosiła 20000 Hz, więc próbka zawierała 20000 wartości. Widmo częstotliwości prądu twornika zostało przedstawione na rysunku 2.



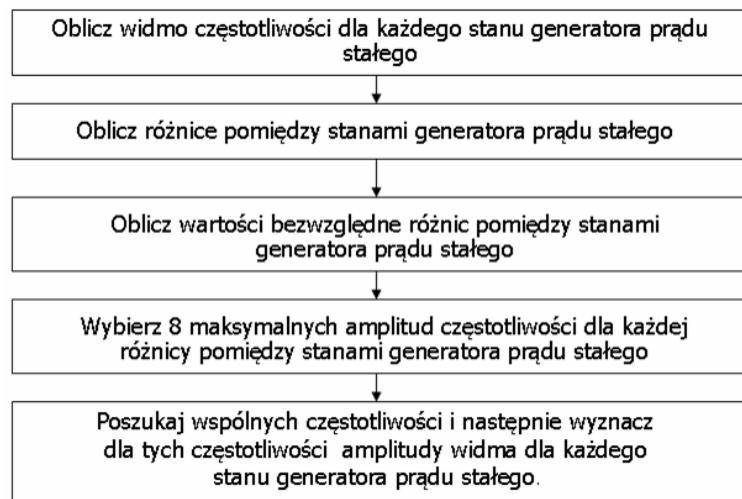
Rys. 2. Amplitudy częstotliwości prądu twornika zależnie od częstotliwości generatora prądu stałego bez uszkodzeń z prędkością obrotową wirnika 600 obrotów na minutę

## 2.2. Metoda wyboru amplitud częstotliwości

Propozowana metoda wyboru amplitud częstotliwości (MSAF-1) została oparta na różnicach pomiędzy amplitudami różnych stanów generatora prądu stałego. Prąd twornika był zależny od stanu, prędkości obrotowej wirnika i budowy generatora. Kroki MSAF-1 są następujące:

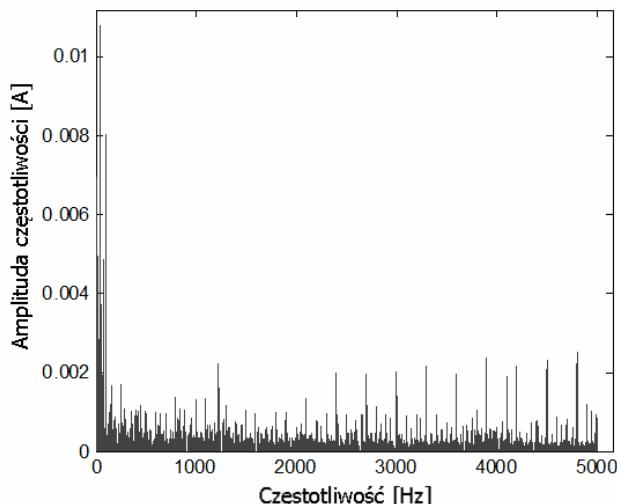
- 1) Oblicz widmo częstotliwości dla każdego stanu generatora prądu stałego.
- 2) Oblicz różnice pomiędzy stanami generatora prądu stałego: **a-b**, **a-c**, **a-d**, **b-c**, **b-d**, **c-d**, gdzie **a** oznacza widmo prądu twornika generatora prądu stałego bez uszkodzeń, **b** oznacza widmo prądu twornika generatora prądu stałego z 3 zwartymi zezwojami, **c** oznacza widmo prądu twornika generatora prądu stałego z 6 zwartymi zezwojami, **d** oznacza widmo prądu twornika generatora prądu stałego z 1 przerwą.
- 3) Oblicz wartości bezwzględne różnic pomiędzy stanami generatora prądu stałego:  $|a-b|$ ,  $|a-c|$ ,  $|a-d|$ ,  $|b-c|$ ,  $|b-d|$ ,  $|c-d|$ .
- 4) Wybierz 8 maksymalnych amplitud częstotliwości dla każdej różnicy pomiędzy stanami generatora prądu stałego:  $\max_1|a-b|$ , ...,  $\max_8|a-b|$ , ...,  $\max_1|c-d|$ , ...,  $\max_8|c-d|$  i wyznacz odpowiadające częstotliwości.
- 5) Poszukaj wspólnych częstotliwości (1-8) i następnie wyznacz dla tych częstotliwości amplitudy widma dla każdego stanu generatora prądu stałego.

Metoda wyboru amplitud częstotliwości generatora prądu stałego została przedstawiona w postaci schematu blokowego na rys. 3.

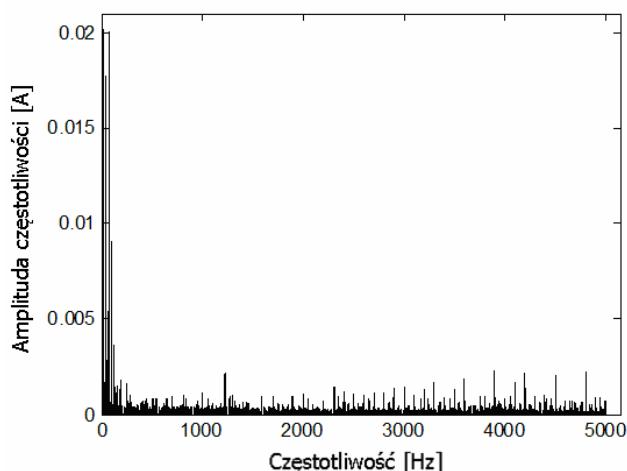


Rys. 3. Schemat blokowy MSAF-1

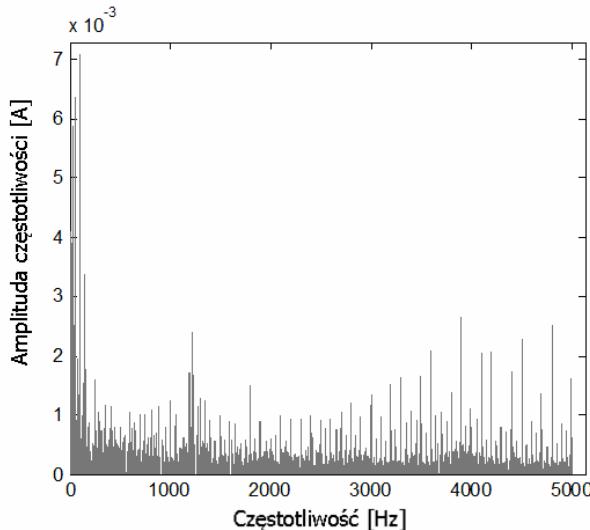
Różnice pomiędzy widmami dla 4 stanów generatora prądu stałego z prędkością obrotową wirnika 600 obrotów na minutę zostały przedstawione na rysunkach 4-6.



Rys. 4. Różnice pomiędzy widmem częstotliwości prądu twornika generatora prądu stałego bez uszkodzeń i generatora prądu stałego z 3 zwartymi zezwojami wirnika (a-b) z prędkością obrotową wirnika 600 obrotów na minutę

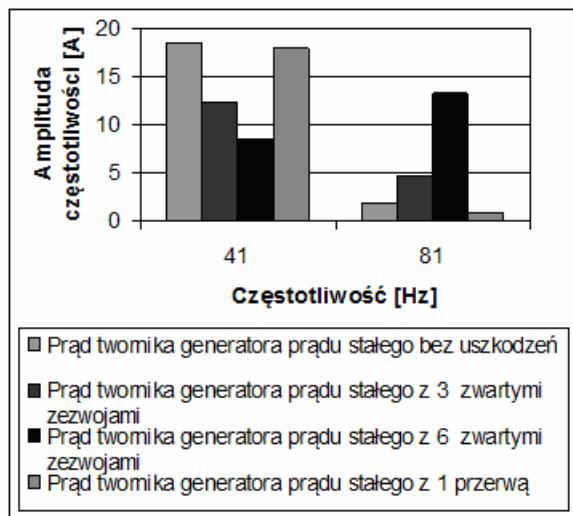


Rys. 5. Różnice pomiędzy widmem częstotliwości prądu twornika generatora prądu stałego bez uszkodzeń i generatora prądu stałego z 6 zwartymi zezwojami wirnika (a-c) z prędkością obrotową wirnika 600 obrotów na minutę



Rys. 6. Różnice pomiędzy widmem częstotliwości prądu twornika generatora prądu stałego bez uszkodzeń i generatora prądu stałego z 1 przerwą (|a-d|) z prędkością obrotową wirnika 600 obrotów na minutę

Wybór wspólnych amplitud częstotliwości dla 4 stanów generatora prądu stałego z 600 obrotami wirnika na minutę przedstawiony został na rysunku 7.



Rys.7. Wybór wspólnych amplitud częstotliwości dla 4 stanów generatora prądu stałego z prędkością obrotową wirnika 600 obrotów na minutę (41 i 81 Hz)

Wybrane amplitudy częstotliwości tworzyły wektor cech używany przez Liniową Analizę Dyskryminacyjną.

### 2.3. Liniowa Analiza Dyskryminacyjna

Istnieje wiele metod przetwarzania danych i klasyfikacji wektorów cech [3-5, 17-26, 28, 31, 32, 34, 37-39, 41, 45-48]. Wektory cech są przetwarzane przez Liniową Analizę Dyskryminacyjną (LDA). LDA maksymalizuje współczynnik (iloraz) wariancji międzyklasowej do wariancji wewnętrzklasowej. Maksymalny współczynnik gwarantuje rozdzielność między klasami. Zbiory uczące i testowe powinny być określone odpowiednio na początku klasyfikacji. Zbiory trenujące są zdefiniowane jako  $\text{set}_1, \dots, \text{set}_k$ . Następne średnia dla każdego zbioru trenującego i średnia wszystkich zbiorów uczących są obliczane.

Średnie zbiorów  $\text{set}_1, \dots, \text{set}_k$  są zdefiniowane jako  $\mu_1, \dots, \mu_k$ . Podczas gdy średnia wszystkich zbiorów uczących nazywana jest  $\mu$ . Średnia ta zdefiniowana jest przez równanie 1.

$$\mu = p_1 \times \mu_1 + \dots + p_k \times \mu_k \quad (1)$$

gdzie  $p_1, \dots, p_k$  są prawdopodobieństwami a priori klas.

Następnie liniowa kombinacja cech jest utworzona przez Liniową Analizę Dyskryminacyjną. Liniowa Analiza Dyskryminacyjna używa macierzy rozproszonej wewnętrzklasowej i macierzy rozproszonej międzyklasowej [1, 32]. Obie macierze są używane do formułowania kryterium rozdzielnosci klas. Macierz rozproszona wewnętrzklasowa jest zdefiniowana następująco:

$$W = \sum_{k=1}^c \sum_{i=1}^{N_k} (x_i^k - \mu_k)(x_i^k - \mu_k)^T \quad (2)$$

gdzie  $\mu_k$  oznacza średnią klasy  $k$ ,  $x_i^k$  jest próbką z indeksem  $i$  klasy  $k$ ,  $c$  oznacza liczbę klas zbiorów trenujących i  $N_k$  jest liczbą próbek klasy  $k$  [1, 31].

Macierz rozproszona międzyklasowa jest wyrażona wzorem:

$$B = \sum_{k=1}^c (\mu_k - \mu)(\mu_k - \mu)^T \quad (3)$$

gdzie  $\mu$  oznacza średnią wszystkich zbiorów uczących,  $\mathbf{x}$ ,  $\boldsymbol{\mu}$  to wektory o wymiarze równym liczbie wybranych wspólnych częstotliwości.

Współczynnik wyznacznika macierzy rozproszonej międzyklasowej do wyznacznika macierzy wewnętrzklasowej jest kryterium Liniowej Analizy Dyskryminacyjnej. W metodzie tej istotne jest aby maksymalizować współczynnik ( $\text{Det}|B| / \text{Det}|W|$ ) [31]. Osie przekształconej przestrzeni są zdefiniowane przez rozwiązanie otrzymane przez maksymalizację współczynnika ( $\text{Det}|B| / \text{Det}|W|$ ).

### 3. Wyniki rozpoznawania prądu twornika

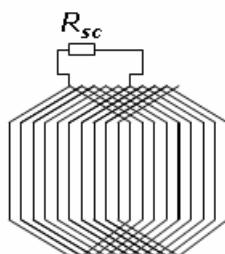
Karta pomiarowa i przetwornik prądowy LEM były użyte do rejestracji sygnałów prądu twornika. Parametry sygnału prądu były: częstotliwość próbkowania - 20000 Hz, format - TXT. Parametry operacyjne generatora prądu stałego z prędkością obrotową wirnika 600 obrotów na minutę były następujące:

- generator prądu stałego bez uszkodzeń:  $U_a = 51 \text{ V}$ ,  $I_a = 70 \text{ A}$ ,  $U_e = 159.1 \text{ V}$ ,  $I_e = 2.5 \text{ A}$ ,
- generator prądu stałego z 3 zwartymi zezwojami:  $U_a = 50.5 \text{ V}$ ,  $I_a = 71.5 \text{ A}$ ,  $U_e = 160.8 \text{ V}$ ,  $I_e = 2.5 \text{ A}$ ,  $I_{sc} = 58 \text{ A}$ ,
- generator prądu stałego z 6 zwartymi zezwojami:  $U_a = 50 \text{ V}$ ,  $I_a = 70.5 \text{ A}$ ,  $U_e = 161.2 \text{ V}$ ,  $I_e = 2.5 \text{ A}$ ,  $I_{sc} = 138 \text{ A}$ ,
- generator prądu stałego z 1 przerwą:  $U_a = 50.5 \text{ V}$ ,  $I_a = 70 \text{ A}$ ,  $U_e = 163.3 \text{ V}$ ,  $I_e = 2.5 \text{ A}$ ,

gdzie  $U_a$  - napięcie twornika generatora prądu stałego,  $I_a$  - prąd twornika generatora prądu stałego,  $U_e$  - napięcie wzbudzenia generatora prądu stałego,  $I_e$  - prąd wzbudzenia generatora prądu stałego,  $I_{sc}$  - prąd zwarcia.

Grupy trzech i sześciu pętli zezwojów wirnika zostały zwarte z użyciem rezystancji  $R_{sc} = 0.085 \text{ m}\Omega$ . Została ona połączona z generatorem prądu stałego do ochrony uzwojeń wirnika. Badania zostały przeprowadzone dla 4 sygnałów prądu: prądu twornika generatora prądu stałego bez uszkodzeń, prądu twornika generatora z 3 zwartymi zezwojami, prądu twornika generatora z 6 zwartymi zezwojami (rys. 8), prądu twornika generatora z 1 przerwą. 32 próbki uczące o czasie trwania 1 sekundy zostało użytych w procesie tworzenia wzorca. 128 próbki testowe o czasie trwania 1 sekundy zostały użyte w procesie identyfikacji.

### ZWARCIE



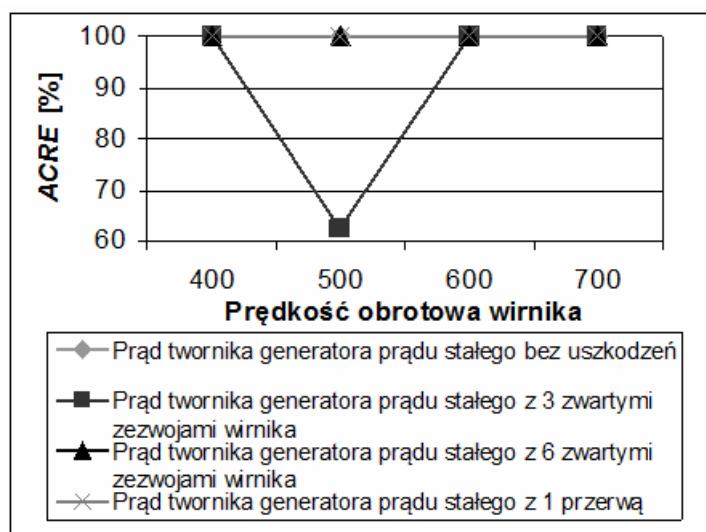
Rys. 8. Schemat uzwojeń wirnika generatora prądu stałego z 6 zwartymi zezwojami

Skuteczność rozpoznawania prądu twornika określa zależność:

$$ACRE = \frac{NoWRTS}{NoATS} \cdot 100\% \quad (4)$$

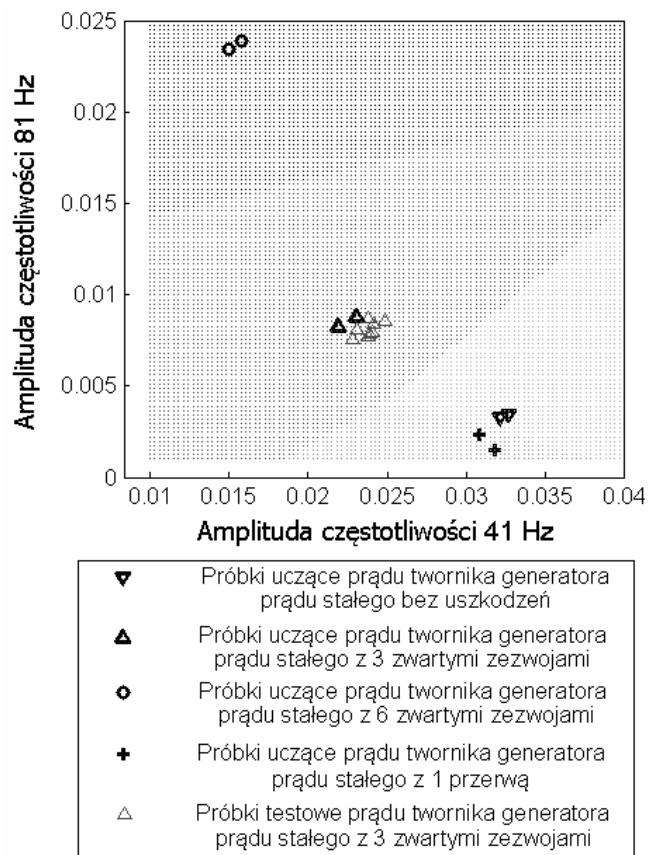
gdzie:  $ACRE$  – skuteczność rozpoznawania prądu twornika,  $NoWRTS$  – liczba dobrze rozpoznanych próbek testowych,  $NoATS$  – liczba wszystkich próbek testowych.

Badania były przeprowadzone dla generatora prądu stałego z prędkością obrotową wirnika 400, 500, 600, 700 obrotów na minutę. Skuteczność rozpoznawania prądu twornika zależnie od prędkości obrotowej wirnika generatora została zaprezentowana na rysunkach 9 i 10.



Rys. 9. Skuteczność rozpoznawania prądu twornika zależnie od prędkości obrotowej wirnika generatora

Skuteczność rozpoznawania prądu twornika generatora bez uszkodzeń wynosiła 100% 8 próbek testowych na 8 zostało sklasyfikowanych jako generator bez uszkodzeń. Próbki zostały przygotowane na podstawie pomiarów i autorzy wiedzieli, że te 8 próbek testowych należały do generatora bez uszkodzeń. Skuteczność rozpoznawania prądu twornika generatora z 3 zwartymi zezwojami była 62.5-100%. Skuteczność rozpoznawania prądu twornika generatora z 6 zwartymi zezwojami wynosiła 100%. Skuteczność rozpoznawania prądu twornika generatora z 1 przerwą była 100%. Wyniki dla wektorów dwu-elementowych były dobre. W przypadku gdy system wybierze liczbę wspólnych amplitud częstotliwości 1-8, to LDA będzie przetwarzać wektory 1-8 elementowe.



Rys. 10. Rozpoznawanie próbek testowych prądu twornika generatora prądu stałego z 3 zwartymi zezwojami z prędkością obrotową wirnika 600 obrotów na minutę

#### 4. Wnioski

W artykule autorzy zaproponowali technikę i system rozpoznawania prądu twornika generatora prądu stałego. Badania dotyczące zastosowania metod przetwarzania sygnału do rozpoznawania prądu twornika zostały wykonane dla generatora prądu stałego bez uszkodzeń i generatora prądu stałego z uszkodzeniem. Eksperymenty udowodniły, że metody takie jak MSAF-1, FFT i LDA były dobre dla diagnostyki generatora prądu stałego. Skuteczność rozpoznawania prądu twornika generatora prądu stałego wynosiła 100% dla prędkości obrotowej wirnika 400, 600, 700 obrotów na minutę. Kiedy prędkość obrotowa wirnika była równa 500, wtedy skuteczność rozpoznawania prądu twornika wynosiła 62.5-100%. Zaletą tej metody w porównaniu do metody rozpoznawania sygnałów akustycznych jest to, że prąd twornika jest łatwiejszy do przetwarzania. Dalsze badania będą koncentrować się na implementacjach nowych metod przetwarzania i współpracy z różnymi sygnałami diagnostycznymi.

## **Podziękowania**

Praca została częściowo zrealizowana ze środków AGH, umowa AGH nr 11.11.120.612 (Adam Głowacz).

Praca została częściowo zrealizowana ze środków AGH, umowa AGH nr 11.11.120.815 (Witold Głowacz).

Praca została częściowo zrealizowana ze środków AGH, umowa AGH nr 11.11.120.354 (Zygfryd Głowacz).

## **Literatura**

1. Balakrishnama S, Ganapathiraju A. Linear Discriminant Analysis - A brief tutorial. Presentation, Institute for Signal and Information Processing Department of Electrical and Computer Engineering Mississippi State University.
2. Bogucka J. Influence of Temperature of Accumulative Roll Bonding on the Microstructure and Mechanical Properties of AA5251 Aluminum Alloy. Archives of Metallurgy and Materials 2014; 59 (1): 127-131.
3. Carletti E. A Perception-Based Method for the Noise Control of Construction Machines. Archives of Acoustics 2013; 38 (2): 253-258.
4. Czopek K. Cardiac Activity Based on Acoustic Signal Properties. Acta physica polonica A 2012; 121 (1A): A42-A45.
5. Dudek-Dydych E, Tadeusiewicz R, Horzyk A. Neural network adaptation process effectiveness dependent of constant training data availability. Neurocomputing 2009; 72 (13-15): 3138-3149.
6. Dudzikowski I, Ciurys M. Analysis of operation of a car starter with BLDC motor. Przeglad Elektrotechniczny 2010; 86 (4): 166-169.
7. Florkowski M, Furgal J, Kuniewski M. Impact of transformers from overvoltages transferred through windings. Przeglad Elektrotechniczny 2012; 88 (5A): 104-107.
8. 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.
9. 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.
10. 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.
11. Glowacz W. Diagnostics of Induction motor based on Spectral Analysis of Stator Current with Application of Backpropagation Neural Network. Archives of Metallurgy and Materials 2013; 58 (2): 559-562.
12. Gluchowski WJ, Rdzawski ZM, Stobrawa JP, Marszowski KJ. Microstructure and Properties of Cu-Nb Wire Composites. Archives of Metallurgy and Materials 2014; 59 (1): 35-40.
13. Gogola D, Krafcík A, Strbak O, Frollo I. Magnetic Resonance Imaging of Surgical Implants Made from Weak Magnetic Materials. Measurement Science Review 2013; 13 (4): 165-168.
14. Golanski G, Slania J. Effect of Different Heat Treatments on Microstructure and Mechanical Properties of the Martensitic GX12CrMoVNbN9-1 Cast Steel. Archives of Metallurgy and Materials 2013; 58(1): 25-30.
15. Golebiowski L, Golebiowski M, Mazur D. Unscented kalman filter in rotor diagnostic testing of the asynchronous motor. Przeglad Elektrotechniczny 2011; 87 (8): 48-52.
16. Golebiowski L, Golebiowski M, Mazur D. Controlling of the 1-and 3-phase power factor correction (PFC) rectifiers, Przeglad Elektrotechniczny 2011; 87 (8): 53-58.
17. Gorski P, Morzynski L. Active Noise Reduction Algorithm Based on NOTCH Filter and Genetic Algorithm. Archives of Acoustics 2013; 38 (2): 185-190.
18. Hachaj T, Ogiela MR. Application of neural networks in detection of abnormal brain perfusion regions. Neurocomputing 2013; 122 (Special Issue): 33-42.

19. Hachaj T, Ogiela MR. A system for detecting and describing pathological changes using dynamic perfusion computer tomography brain maps. *Computers in Biology and Medicine* 2011; 41 (6): 402-410.
20. Huang CW, Chen GM, Yu H, Bao YQ, Zhao L. Speech Emotion Recognition under White Noise. *Archives of Acoustics* 2013; 38 (4): 457-463.
21. Jaworek J, Augustyniak P. A cardiac telerehabilitation application for mobile devices. *IEEE Conference on Computing in Cardiology* 2011; Hangzhou, China: 241-244.
22. Jun S, Kochan O. Investigations of Thermocouple Drift Irregularity Impact on Error of their Inhomogeneity Correction. *Measurement Science Review* 2014; 14 (1): 29-34.
23. Kantoch E, Smolen M, Augustyniak P, Kowalski P. Wireless Body Area Network System based on ECG and Accelerometer Pattern. *IEEE Conference on Computing in Cardiology* 2011; Hangzhou; China: 245-248.
24. Kmiec M, Glowacz A, Dziech A. Towards robust visual knife detection in images: active appearance models initialised with shape-specific interest points. *Multimedia communications, services and security, MCSS, Book Series: Communications in Computer and Information Science* 2012, 287, 148–158.
25. Knap M, Falkus J, Rozman A, Konopka K, Lamut J. The Prediction of Hardenability using Neural Networks. *Archives of Metallurgy and Materials* 2014; 59 (1): 133-136.
26. Korohoda P, Dabrowski A. Wavelet-like decomposition stage with windowed filters defined for the Discrete Trigonometric Transforms (DTTs). *Przeglad Elektrotechniczny* 2012; 88 (6): 30-35.
27. Kulesza G, Panek P, Zieba P. Silicon Solar Cells Efficiency Improvement by the Wet Chemical Texturization in the HF/HNO<sub>3</sub>/diluent solution. *Archives of Metallurgy and Materials* 2013; 58 (1): 291-295.
28. Lin DF, Chen PH, Williams M. Measurement and Analysis of Current Signals for Gearbox Fault Recognition of Wind Turbine. *Measurement Science Review* 2013; 13 (2): 89-93.
29. Madej M. Phase Reactions During Sintering of M3/2 Based Composites with WC Additions. *Archives of Metallurgy and Materials* 2013; 58 (3): 703-708.
30. Mamala A, Sciezor W. Evaluation of the Effect of Selected Alloying Elements on the Mechanical and Electrical Aluminium Properties. *Archives of Metallurgy and Materials* 2014; 59 (1): 413-417.
31. Martinez AM, Kak AC. PCA versus LDA *IEEE Transactions on Pattern Analysis and Machine Intelligence* 2001; 23 (2): 228-233.
32. MathWorks – MATLAB and SimuLink for Technical Computing 2014; [www.mathworks.com](http://www.mathworks.com).
33. Mazurkiewicz D. Problems of identification of strength properties of rubber materials for purposes of numerical analysis: a review. *Archives of Civil and Mechanical Engineering* 2010; 10 (1): 69-84.
34. Meo A, Profumo L, Rossi A, Lanzetta M. Optimum Dataset Size and Search Space for Minimum Zone Roundness Evaluation by Genetic Algorithm. *Measurement Science Review* 2013; 13 (3): 100-107.
35. Musial D. Numerical Analysis of the Process of Heating of a Bed of Steel Bars. *Archives of Metallurgy and Materials* 2013; 58 (1): 63-66.
36. Olszewski R, Trawinski Z, Wojcik J, Nowicki A. Mathematical and Ultrasonographic Model of the Left Ventricle: in Vitro Studies. *Archives of Acoustics* 2012; 37 (4): 583-595.
37. Orzechowski T, Izworski A, Tadeusiewicz R, Chmurzynska K, Radkowski P, Gatkowska I. Processing of pathological changes in speech caused by dysarthria. *Proceedings of ISPACS 2005, IEEE International Symposium on Intelligent Signal Processing and Communication Systems* ISPACS 2005: 49-52.
38. Roj J. Neural Network Based Real-time Correction of Transducer Dynamic Errors. *Measurement Science Review* 2013, 13 (6), 286-291.
39. Skrodzka EB, Linde BBJ, Krupa A. Modal Parameters of Two Violins with Different Varnish Layers and Subjective Evaluation of Their Sound Quality. *Archives of Acoustics* 2013; 38 (1): 75-81.
40. Smalcerz A. Aspects of Application of Industrial Robots in Metallurgical Processes. *Archives of Metallurgy and Materials* 2013; 58 (1): 203-209.

41. Smolen M, Kantoch E, Augustyniak P, Kowalski P. Wearable Patient Home Monitoring Based on ECG and ACC Sensors. 5th European Conference of the International Federation for Medical and Biological Engineering, IFMBE Proceedings 2012; 37: 941-944.
42. Sulowicz M, Borkowski D, Wegiel T, Weinreb K. Specialized diagnostic system for induction motors. Przeglad Elektrotechniczny 2010; 86 (4): 285-291.
43. Szymanski Z. Application of the Magnetic Field Distribution in Diagnostic Method of Special Construction Wheel Traction Motors. Advanced Computer Techniques in Applied Electromagnetics, Book Series: Studies in Applied Electromagnetics and Mechanics, 2008; 30: 449-456.
44. Tokarski T, Wzorek L, Dybiec H. Microstructure and Plasticity of Hot Deformed 5083 Aluminum Alloy Produced by Rapid Solidification and Hot Extrusion. Archives of Metallurgy and Materials 2012; 57 (4): 1253-1259.
45. Trzupek M, Ogiela MR, Tadeusiewicz R. Intelligent image content semantic description for cardiac 3D visualisations. Engineering Applications of Artificial Intelligence 2011; 24 (8): 1410-1418.
46. Tu YQ, Yang HY, Zhang HT, Liu XY. CMF Signal Processing Method Based on Feedback Corrected ANF and Hilbert Transformation. Measurement Science Review 2014; 14 (1): 41-47.
47. Yan JJ, Wang XL, Gu WY, Ma LL. Speech Emotion Recognition Based on Sparse Representation. Archives of Acoustics 2013; 38 (4): 465-470.
48. Ziaran S. Low Frequency Noise and Its Assessment and Evaluation. Archives of Acoustics 2013; 38 (2): 265-270.