

## Diagnostyka generatora prądu stałego oparta na analizie sygnałów akustycznych z użyciem transformaty falkowej biortogonalnej i klasyfikatora najbliższej średniej

**Streszczenie.** W artykule przedstawiono problematykę diagnostyki stanów przedawaryjnych generatora prądu stałego. Przedstawiono stanowisko badawcze razem z oprogramowaniem pozwalającym na przeprowadzenie badań. Badania zostały przeprowadzone dla algorytmów przetwarzania danych: Dyskretnej transformaty falkowej Biortogonalnej i klasyfikatora Najbliższej Średniej z metryką Minkowskiego. Na podstawie zaimplementowanego systemu, przeanalizowano możliwość diagnostyki defektu generatora prądu stałego. Opracowane algorytmy metod diagnostycznych mają wysoką skutecznością rozpoznawania. To sprawia, że możliwe jest stosowanie ich w przemyśle.

**Abstract.** The paper presented problems of diagnostics of imminent failure conditions of Direct Current generator. There is presented a measuring stand together with a software enabling to research the diagnostic processes. Studies were conducted for algorithms of data processing: Biorthogonal Wavelet Transform and Nearest Mean classifier with Minkowski distance. On the basis of implemented system, a possibility of diagnosing of Direct Current generator defect has been analyzed. Developed algorithms of diagnostic methods have high efficiency of recognition. This makes it possible to use them in the industry (**Diagnostics of Direct Current generator based on analysis of acoustic signals with the use of bi-orthogonal wavelet transform and nearest mean classifier**).

**Słowa kluczowe:** Diagnostyka, Rozpoznawanie, Sygnał akustyczny, Falki, Generator prądu stałego

**Keywords:** Diagnostics, Recognition, Acoustic signal, Wavelets, Direct Current generator

doi:10.12915/pe.2014.11.47

### Wstęp

Diagnostyka maszyn od drugiej połowy XX wieku jest pobudzana rosnącą potrzebą diagnozowania. Na początku opierała się na obserwacji i interpretacji symptomów stanów maszyny. Obecnie możliwa obserwacja i rejestracja wielu sygnałów pochodzących od maszyny. Łatwość pomiaru i przetwarzania sygnałów umożliwia minimalizację ryzyka, przez zastosowanie algorytmów rozpoznawania. Algorytmy te wraz z odpowiednimi układami elektronicznymi dają możliwość tworzenia urządzeń i systemów samodiagnostycznych i samonaprawczych. Rozbudowane systemy kontrolne już teraz dają możliwości zbierania i porównywania informacji diagnostycznych z określonej maszyny elektrycznej. Diagnostyka maszyn elektrycznych polega głównie na kontroli ciągłości połączeń instalacji elektrycznej, pomiarze prądów i spadków napięć w różnych jej punktach, pomiarze wartości elementów elektrycznych ma na celu wykrycie przyczyn tych usterek. Na podstawie wyników takich pomiarów można określić stan techniczny poszczególnych urządzeń [1-13]. W diagnostyce ważne są również badania właściwości materiałów [14-17].

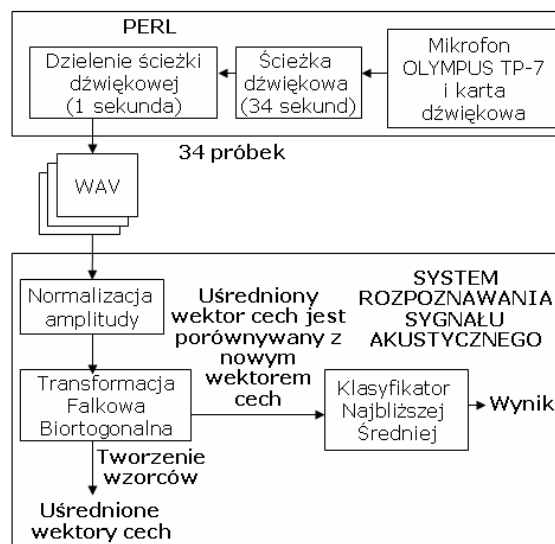
W artykule przedstawiono oprogramowanie i dane uczące dla stosowania klasyfikatora najbliższej średniej i testowania wybranej metryki. W dalszej części artykułu będą opisane: proces rozpoznawania sygnału akustycznego generatora prądu stałego, wybrane algorytmy przetwarzania danych i wyniki rozpoznawania sygnałów akustycznych generatora prądu stałego.

### Proces rozpoznawania sygnału akustycznego generatora prądu stałego

Proces rozpoznawania sygnału akustycznego generatora prądu stałego składa się z procesu tworzenia wzorców do rozpoznawania i procesu identyfikacji. Na początku procesu tworzenia wzorców do rozpoznawania wykonywana jest normalizacja amplitudy.

W kolejnym kroku dane są przekształcane przez Transformację Falkową Biortogonalną. Następnie z tak otrzymanych cech tworzony jest wektor cech danej kategorii. Kolejno wektory danej kategorii są uśredniane w wyniku czego powstaje uśredniony wektor cech.

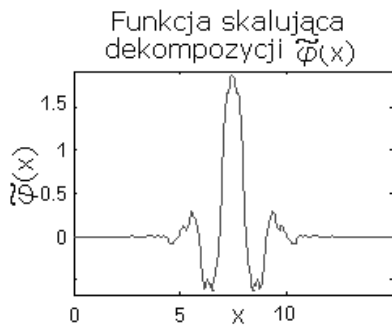
W procesie identyfikacji etapy przetwarzania sygnału akustycznego są takie same jak dla procesu tworzenia wzorców do rozpoznawania. Istotna zmiana polega na dodaniu etapu klasyfikacji (Rys. 1). W tym etapie porównywane są ze sobą wektory cech (wzorcowy uśredniony wektor cech z nieznanym wektorem nowej próbki dźwięku). W tym celu stosowana jest metryka Minkowskiego.



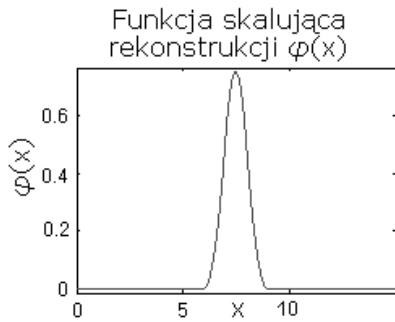
Rys.1. Proces rozpoznawania sygnału akustycznego generatora prądu stałego z użyciem Transformacji Falkowej Biortogonalnej i klasyfikatora Najbliższej Średniej

### Transformata Falkowa Biortogonalna

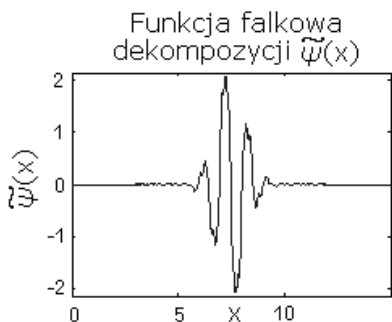
Analiza Falkowa polega na dekompozycji sygnału przy użyciu falek otrzymanych poprzez przesunięcie i skalowania falki podstawowej (ang. mother wavelet). Dyskretna transformata falkowa oryginalnego sygnału jest liczona za pomocą serii dolnoprzepustowych i górno-przepustowych filtrów [18]. Funkcje falkowe i skalujące dla falki Biortogonalnej (bior3.7) zostały przedstawione na rysunkach 2-5.



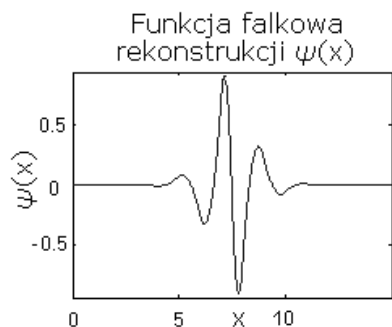
Rys.2. Funkcja skalująca dekompozycji falki Biorotogonalnej (bior3.7)



Rys.3. Funkcja skalująca rekonstrukcji falki Biorotogonalnej (bior3.7)




Rys.4. Funkcja falkowa dekompozycji falki Biorotogonalnej (bior3.7)



Rys.5. Funkcja falkowa rekonstrukcji falki Biorotogonalnej (bior3.7)

Kolejno współczynniki ( $d_1, d_2, d_3, \dots, d_n$ ) są otrzymywane po użyciu górnoprzepustowego filtru. Natomiast współczynniki ( $a_1, a_2, a_3, \dots, a_n$ ) są obliczane po użyciu filtru dolnoprzepustowego, gdzie  $n$  jest poziomem dekompozycji (Rys. 6).

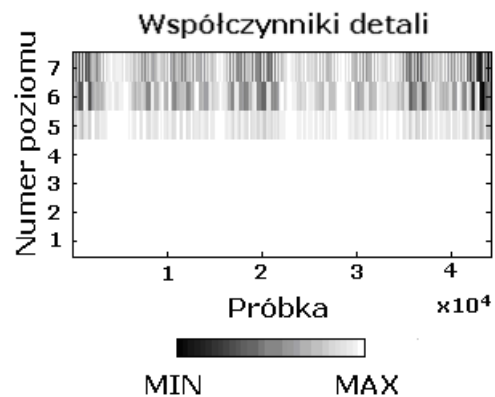
Wektory  $d_1, \dots, d_n$  są ważne w procesie rozpoznawania sygnału akustycznego (Rys. 7, 8). Wartości bezwzględne wektorów  $d_1, \dots, d_n$  będą używane w kolejnym etapie klasyfikacji.



Rys.6. Współczynniki dla siódmego poziomu dekompozycji



Rys.7. Współczynniki detali dla sygnału akustycznego generatora prądu stałego bez uszkodzeń po filtracji cyfrowej od 223 Hz do 235 Hz



Rys.8. Współczynniki detali dla sygnału akustycznego generatora prądu stałego ze zwartymi zezwojami wirnika po filtracji cyfrowej od 223 Hz do 235 Hz

### Klasyfikator najbliższej średniej

W literaturze jest wiele metod klasyfikacji [19-29]. W algorytmie najbliższej średniej wzorcem klasy rozpoznawanych obiektów jest średni wektor cech. Obliczane są odległości nowego wektora cech od wszystkich wektorów wzorcowych (średnich wektorów cech), a następnie wybierana jest najmniejsza z nich. Głównymi korzyściami klasyfikatora najbliższej średniej w stosunku do klasyfikatora najbliższego sąsiada są: mniejsza liczba próbek ciągu uczącego oraz mniejsza liczba obliczeń [29].

Wektor cech jest określony następująco  $\mathbf{x}=[x_1, x_2, \dots, x_n]$ . Wektor ten powstał z przetwarzania próbki dźwięku. Klasy wzorców oznaczone są jako  $w_1, w_2, \dots, w_M$ , gdzie  $M$  jest numerem indeksu klasy. Ciąg uczący otrzymywany jest w procesie tworzenia wzorców. Zawiera on średnie wektory cech  $\mathbf{m}_1, \mathbf{m}_2, \dots, \mathbf{m}_j$  (1),

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

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

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

$$(2) \quad d(\mathbf{y}, \mathbf{x}) = \left( \sum_{i=1}^n (|y_i - x_i|)^r \right)^{\frac{1}{r}}$$

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

### Wyniki rozpoznawania sygnału akustycznego generatora prądu stałego

Maszyna prądu stałego pracowała jako generator. Generator wytwarzał określony sygnał akustyczny przy pracy normalnej (generator bez uszkodzeń) i inny charakterystyczny sygnał akustyczny przy zwarcie zezwojów wirnika (3 zwarte zezwoje z 126 zezwojów). Zwarcie zostało umiejscowione w obwodzie wirnika przy prądzie wzbudzenia generatora 0,22 A. Sygnały akustyczne zostały zarejestrowane mikrofonem OLYMPUS TP-7 i kartą dźwiękową firmy REALTEK. Zarejestrowana ścieżka dźwiękowa charakteryzowała się następującymi parametrami: format pliku - WAVE PCM, częstotliwość próbkowania - 44100 Hz, liczba bitów - 16, liczba kanałów - 1. Przy rejestracji sygnałów akustycznych parametry operacyjne maszyny przedstawiały się następująco:

$P_N = 13$  kW,  $U_N = 75$  V,  $I_N = 200$  A,  $U_{fN} = 220$  V,  $I_{fN} = 4$  A,  $n_N = 700$  obr/min,  $R_{bz} = 7,7$  m $\Omega$ ,  
gdzie:  $P_N$  – moc czynna na wirniku,  $U_N$  – napięcie znamionowe twornika,  $I_N$  – prąd znamionowy twornika,  $U_{fN}$  – napięcie znamionowe wzbudzenia,  $I_{fN}$  – prąd znamionowy wzbudzenia,  $n_N$  – ilość obrotów wirnika na minutę.

Schemat badanych uzwojeń wirnika dla generatora prądu stałego ze zwartymi zezwojami został przedstawiony na rysunku 9,

gdzie:  $R_{a1}, \dots, R_{aK}$ ,  $R_{b1}, \dots, R_{bK}$  – rezystancje komutatora,  $R_{r1}, \dots, R_{rK}$  – rezystancja zezwojów wirnika,  $L_{r1}, \dots, L_{rK}$  – indukcyjność zezwojów wirnika,  $L_f$  – indukcyjność uzwojenia wzbudzenia,  $R_f$  – rezystancja uzwojenia wzbudzenia,  $i_f$  – prąd wzbudzenia,  $R_{bz}$  – rezystancja zwierająca,  $i_{bz}$  – prąd rezystancji zwierającej,  $i_{w1}$  – prąd wyrównawczy w pierwszym połączeniu wyrównawczym,  $R_{w1}$  – rezystancja uzwojenia pierwszego połączenia wyrównawczego,  $R_{w2}$  – rezystancja uzwojenia drugiego połączenia wyrównawczego,  $L_c$  – indukcyjność uzwojenia komutacyjnego,  $R_c$  – rezystancja uzwojenia komutacyjnego,  $U_t$  – napięcie twornika,  $i_t$  – prąd twornika.

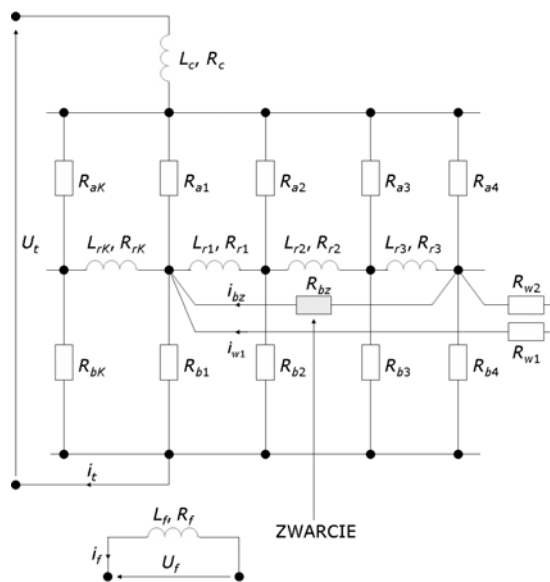
Proces tworzenia wzorców do rozpoznawania został przeprowadzony dla 14 próbek dźwięku. Proces identyfikacji został przeprowadzony dla 68 próbek dźwięku.

Każdy wektor cech zawierał 359 cech. Zbiory testowe i uczący zawierał współczynniki  $d7$ .

Skuteczność rozpoznawania sygnału akustycznego była określona następująco:

$$(3) \quad E = \frac{N_1}{N} \cdot 100\%$$

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



Rys.9. Schemat uzwojeń wirnika generatora prądu stałego ze zwartymi zezwojami

Skuteczność rozpoznawania sygnału akustycznego dla generatora prądu stałego bez uszkodzeń była na poziomie 100%. Skuteczność rozpoznawania sygnału akustycznego dla generatora prądu stałego ze zwartymi zezwojami w obwodzie wirnika wynosiła 100%.

### Podsumowanie

W artykule zaproponowano metodę opartą na badaniu sygnałów akustycznych generatora prądu stałego. Proponowana metoda diagnostyki wykorzystywała Transformację Falkową Biorotogonalną i klasyfikator Najbliższej Średniej z metryką Minkowskiego. Uzyskane wyniki przeprowadzone na stanowisku badawczym potwierdziły słuszność opracowanej koncepcji badania sygnału akustycznego generatora prądu stałego. Skuteczność rozpoznawania sygnału akustycznego dla generatora prądu stałego była na poziomie 100%. Opracowane algorytmy metod diagnostycznych charakteryzują się dużą skutecznością rozpoznawania, pozwalając na zastosowanie ich w systemach diagnostycznych w przemyśle.

### Podziękowania

Praca została zrealizowana częściowo w ramach grantu dziekańskiego w roku 2014 (Adam Głowacz).

Praca została częściowo zrealizowana ze środków AGH w 2014 r., umowa AGH nr 11.11.120.815 (Witold Głowacz).

Praca została częściowo zrealizowana ze środków AGH w 2014 r., umowa AGH nr 11.11.120.354 (Zygfryd Głowacz).

### LITERATURA

- [1] Jastriebow A., Gad S., Ston G., Computer analysis of alternator defects diagnosing using artificial neural network, *Diagnostyka*, Vol. 27 (2002), 7-10

- [2] Golebiowski L., Golebiowski M., Mazur D., Unscented kalman filter in rotor diagnostic testing of the asynchronous motor, *Przegląd Elektrotechniczny*, Vol. 87 (2011), Iss. 8, 48-52
- [3] Golebiowski L., Golebiowski M., Mazur D., Controlling of the 1- and 3-phase power factor correction (PFC) rectifiers, *Przegląd Elektrotechniczny*, Vol. 87 (2011), Iss. 8, 53-58
- [4] Wegiel T., Mathematical Model of PM Synchronous Machine for Diagnostics Purpose, *Przegląd Elektrotechniczny*, Vol. 84 (2008) Iss. 12, 107-110
- [5] Sulowicz M., Borkowski D., Wegiel T., Weinreb K., Specialized diagnostic system for induction motors, *Przegląd Elektrotechniczny*, Vol. 86 (2010), Iss. 4, 285-291
- [6] Orlewski W., Siwek A., Hydroelectric power plant using dump industrial water, *Rynek Energii*, Vol. 6 (2010), 87-91
- [7] 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*, Vol. 55 (2010) Iss. 3, 707-712
- [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*, Vol. 57 (2012) Iss. 1, 179-183
- [9] Glowacz A., Glowacz W., Diagnostics of synchronous motor based on analysis of acoustic signals with application of LPCC and Nearest Mean classifier with cosine distance, *Archives of Metallurgy and Materials*, Vol. 55 (2010) Iss. 2, 563-569
- [10] Glowacz Z., Glowacz A., Simulation language for analysis of discrete-continuous electrical systems (SESL2), *Proceedings of the 26th IASTED International Conference on Modelling, Identification, and Control* (2007), Innsbruck, Austria, 94-99
- [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*, Vol. 58 (2013) Iss. 2, 561-564
- [12] Glowacz Z., Kozik J., Feature selection of the armature winding broken coils in synchronous motor using genetic algorithm and Mahalanobis distance, *Archives of Metallurgy and Materials*, Vol. 57 (2012), Iss. 3, 829-835
- [13] Warzecha A., Non-linear characteristics of AC machines based on the calculation of magnetic field co-energy, *COMPEL, The International Journal for Computation and Mathematics in Electrical and Electronic Engineering*, Vol 17 (1998) Iss. 1-3, 324-328
- [14] Smalcerz A., Aspects of application of industrial robots in metallurgical processes, *Archives of Metallurgy and Materials*, Vol. 58 (2013), Iss. 1, 203-209
- [15] Kulesza G., Panek P., Zieba P., Silicon Solar Cells Efficiency Improvement by the Wet Chemical Texturization in the HF/HNO<sub>3</sub>, *Archives of Metallurgy and Materials*, Vol. 58 (2013) Iss. 1, 291-295
- [16] Korenciak D., Gutten M., Sebok M., Kucera M., Zukowski P., Analysis of thermal processes in oil distribution transformer, *Przegląd Elektrotechniczny*, Vol. 90 (2014), Iss. 5, 79-81
- [17] Mazurkiewicz D., Tests of extendability and strength of adhesive-sealed joints in the context of developing a computer system for monitoring the condition of belt joints during conveyor operation, *Eksploatacja i Niezawodność*, Vol. 47 (2010) Iss. 3, 34-39
- [18] MathWorks – MATLAB and SimuLink for Technical Computing 2013; www.mathworks.com
- [19] Mikulik J., Zajdel M., Automatic risk control based on FSA methodology adaptation for safety assessment in intelligent buildings, *International Journal of Applied Mathematics and Computer Science*, Vol. 19 (2009) Iss. 2, 317-326
- [20] Jaworek J., Augustyniak P., A cardiac telerehabilitation application for mobile devices, *Conference on Computing in Cardiology* (2011), Hangzhou, China, 241-244
- [21] Kantoch E., Smolen M., Augustyniak P., Kowalski P., Wireless Body Area Network System based on ECG and Accelerometer Pattern, *Conference on Computing in Cardiology* (2011), Hangzhou, China, 245-248
- [22] Kantoch E., Jaworek J., Augustyniak P., Design of a wearable sensor network for home monitoring system, *Federated Conference on Computer Science and Information Systems, FedCSIS* (2011), 401-403
- [23] Trzupek M., Ogiela M. R., Tadeusiewicz R., Intelligent image content semantic description for cardiac 3D visualisations, *Engineering Applications of Artificial Intelligence*, Vol. 24 (2011), Iss. 8, 1410-1418
- [24] Strzelczyk P., Wochlik I., Tadeusiewicz R., Izvorski A., Bulka J., Telemedical System in Evaluation of Auditory Brainstem Responses and Support of Diagnosis. 2nd Asian Conference on Intelligent Information and Database Systems (ACIIDS), Lecture Notes in Artificial Intelligence (2010), Hue City; Vietnam: 21-28
- [25] Dudek-Dyduch E., Tadeusiewicz R., Horzyk A., Neural network adaptation process effectiveness dependent of constant training data availability. *Neurocomputing*, Vol. 72 (2009) Iss. 13-15, 3138-3149
- [26] Markiewicz M., Skomorowski M., Public Transport Information System for Visually Impaired and Blind People, *10th Conference on Transport Systems Telematics*, Katowice, Poland, (2010), 271-277
- [27] Duchaj T., Ogiela MR., CAD system for automatic analysis of CT perfusion maps, *Opto-Electronics Review*, Vol. 19 (2011), Iss. 1, 95-103
- [28] Walendowski P., Zastosowanie sieci neuronowych typu SVM do rozpoznawania mowy, Praca doktorska, Politechnika Wroclawska, 2008
- [29] Valis D., Pietrucha-Urbanik K., Utilization of diffusion processes and fuzzy logic for vulnerability assessment, *Eksploatacja i Niezawodność – Maintenance and Reliability*, Vol. 16 (2014), Iss. 1, 48-55

dr inż. Adam Głowacz, AGH Akademia Górniczo-Hutnicza, Wydział Elektrotechniki, Automatyki, Informatyki i Inżynierii Biomedycznej, Katedra Automatyki i Inżynierii Biomedycznej, al. Mickiewicza 30, 30-059 Kraków, E-mail: adglow@agh.edu.pl;

mgr inż. Witold Głowacz, AGH Akademia Górniczo-Hutnicza, Wydział Elektrotechniki, Automatyki, Informatyki i Inżynierii Biomedycznej, Katedra Automatyki i Inżynierii Biomedycznej, al. Mickiewicza 30, 30-059 Kraków, E-mail: wglowacz@agh.edu.pl;

dr hab. inż. Zygfryd Głowacz, AGH Akademia Górniczo-Hutnicza, Wydział Elektrotechniki, Automatyki, Informatyki i Inżynierii Biomedycznej, Katedra Energoelektroniki i Automatyki Systemów Przetwarzania Energii, al. Mickiewicza 30, 30-059 Kraków, E-mail: glowacz@agh.edu.pl;