

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

Diagnostyka maszyny prądu stałego oparta na analizie sygnałów akustycznych z zastosowaniem transformacji falkowej Symlet i zmodyfikowanego klasyfikatora opartego na słowach

Słowa kluczowe: *Eksploatacja, rozpoznawanie, sygnały akustyczne, maszyna prądu stałego, falka*

Streszczenie: W pracy autor zaproponował oryginalne podejście do wykrywania, lokalizacji usterek występujących w maszynie prądu stałego. Opisano implementację systemu do diagnostyki maszyn prądu stałego. System przeprowadzał analizę sygnałów akustycznych maszyny prądu stałego. Przeprowadzono badania dla dwóch stanów maszyny prądu stałego. Badania zostały przeprowadzone dla algorytmów przetwarzania danych: Transformacji falkowej Symlet i zmodyfikowanego klasyfikatora opartego na słowach. Proces tworzenia wzorców do rozpoznawania został przeprowadzony dla 10 próbek dźwięku. Proces identyfikacji został przeprowadzony dla 40 próbek dźwięku. Opisana implementacja systemu może być przydatna do ochrony maszyn. Ponadto podejście takie pozwoli zmniejszyć koszty utrzymania i liczbę uszkodzonych maszyn.

1. Wstęp

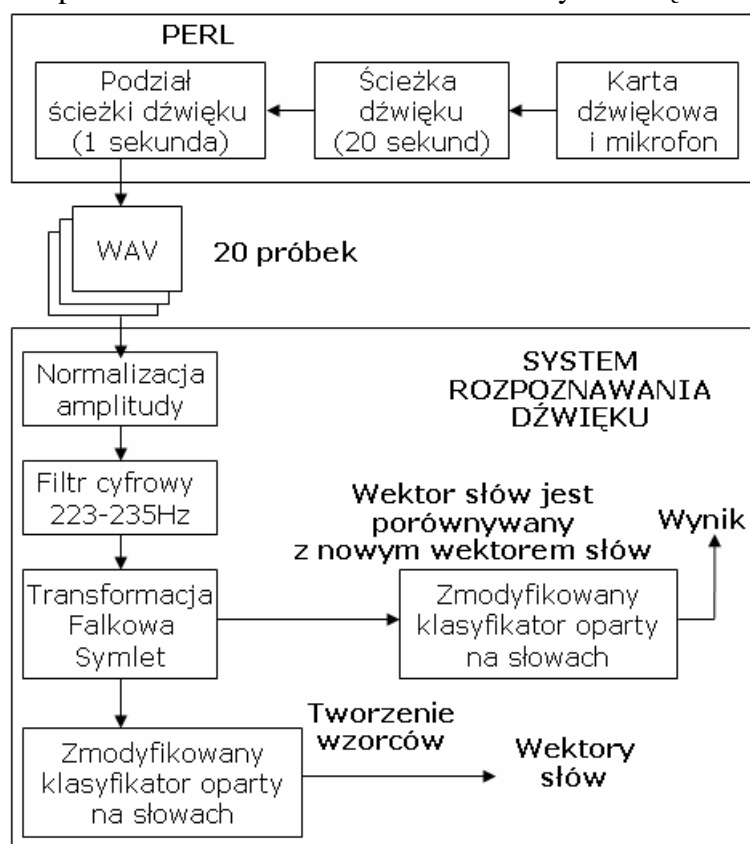
Analiza maszyn elektrycznych jest ważna pod względem kosztów produkcji i konserwacji. Rozpoznawanie wad maszyn elektrycznych jest istotne dla diagnostyki. Projektowanie maszyn elektrycznych stało się złożone w wyniku szybkiego postępu prac w dziedzinie technologii. Monitoring stanu przedawaryjnego musi stać się bardziej zaawansowany, aby radzić sobie z nowymi problemami. Czasem usterki zdarzają się i maszyna przestaje działać. W takim przypadku wynikiem może być utrata produkcji i dochodów. W innym przypadku wypadki dla procesu przemysłowego są bardzo niebezpieczne dla operatorów. Problemy monitorowania stanu przedawaryjnego są następujące: starzenie się maszyn, wymagania wysokiej niezawodności, konkurencyjność kosztów [29]. Właściwości mechaniczne, elektryczne i magnetyczne materiałów opisano w literaturze [1, 11, 14, 15, 21, 23, 26, 34, 37, 39, 40]. Badania właściwości materiałów są bardzo ważne dla diagnostyki, ponieważ operatorzy mogą przewidzieć, jak długo urządzenie będzie pracująca. Diagnostyka jest szczególnie ważna dla hutnictwa, górnictwa i przemysłu przetwórczego.

Diagnostyka maszyn dotyczy znajdowania uszkodzeń powstałych w maszynach. Jest ona stosowana do maszyn wirnikowych. Te maszyny są często używane w przemyśle na przykład w elektrowniach. Aby określić najbardziej prawdopodobne uszkodzenia, stosuje się wiele metod używających różnych sygnałów diagnostycznych. Główne metody diagnostyki stanów przedawaryjnych maszyn oparte są na badaniu: pola magnetycznego, ultradźwięków, sygnałów elektrycznych, sygnałów akustycznych, sygnałów wibroakustycznych. W literaturze popularne metody oparte są na badaniu sygnałów elektrycznych i akustycznych

[6-10, 12-14, 22, 28, 41]. W niniejszej pracy, badania koncentrują się na sygnałach akustycznych maszyny prądu stałego. Wyniki tych badań mogą być użyte do poprawy diagnostyki różnych maszyn elektrycznych. Zaproponowane rozwiązanie zmniejszy koszty eksploatacji i liczbę uszkodzonych maszyn.

2. Proces rozpoznawania sygnału akustycznego maszyny prądu stałego

Proces rozpoznawania dźwięku maszyny prądu stałego zawiera proces tworzenia wzorca i proces identyfikacji. Proces tworzenia wzorca zaczyna się rejestracją sygnałów akustycznych. Kolejno dane zawarte w ścieżce dźwiękowej są dzielone. Następnie otrzymane dane są normalizowane. Następnie sygnały cyfrowe są przetwarzane przez transformację falkową. Transformacja ta używa falki symetrycznej - Symlet. Metoda ta rozkłada oryginalny sygnał czasowy na pewną liczbę współczynników (w zależności od stopnia rozkładu). W procesie tworzenia wzorca dwa wektory słów są tworzone (Rys. 1).



Rys.1. Proces rozpoznawania dźwięku maszyny prądu stałego z zastosowaniem transformacji falkowej Symlet i zmodyfikowanego klasyfikatora opartego na słowach

Kroki procesu identyfikacji są bardzo podobne do kroków procesu tworzenia wzorca. Różnica występuje w kroku klasyfikacji. Wektor słów określonej klasy jest porównywany z nowym wektorem słów. Badana próbka dźwięku jest przydzielana do klasy, której wektor jest jak najbliższy nowego wektora słów.

2.1. Transformacja falkowa Symlet

Rodzina falek Daubechies jest jedną z ortogonalnych rodzin falek. Została ona stworzona przez Ingrid Daubechies belgijską matematyczkę w 1988 roku. Falka "Daubechies 1" jest tym samym co falka Haara. Konstrukcja baz falkowych Symlet jest podobna do

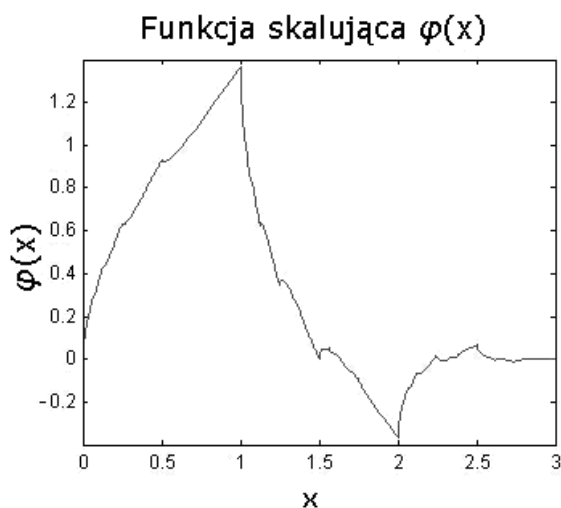
konstrukcji baz falkowych Daubechies. Falki Daubechies mają maksymalną fazę, natomiast Symlets mają minimalną fazę [36]. Falka Symlet (sym2) została zastosowana w systemie rozpoznawania dźwięku (Rys. 2, 3). Współczynniki filtrów odpowiadające temu typowi falki zostały przedstawione w tabelach 1 i 2.

Tabela 1. Filtry dekompozycji falki Sym2

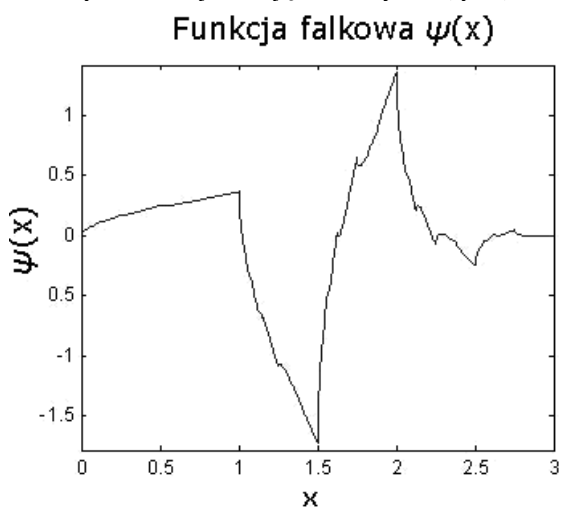
Filtr dolnoprzepustowy dekompozycji	Filtr górnoprzepustowy dekompozycji
-0.1294	-0.4830
0.2241	0.8365
0.8365	-0.2241
0.4830	-0.1294

Tabela 2. Filtry rekonstrukcji falki Sym2

Filtr dolnoprzepustowy rekonstrukcji	Filtr górnoprzepustowy rekonstrukcji
0.4830	-0.1294
0.8365	-0.2241
0.2241	0.8365
-0.1294	-0.4830




Rys. 2. Funkcja skalująca falki Symlet (sym2)

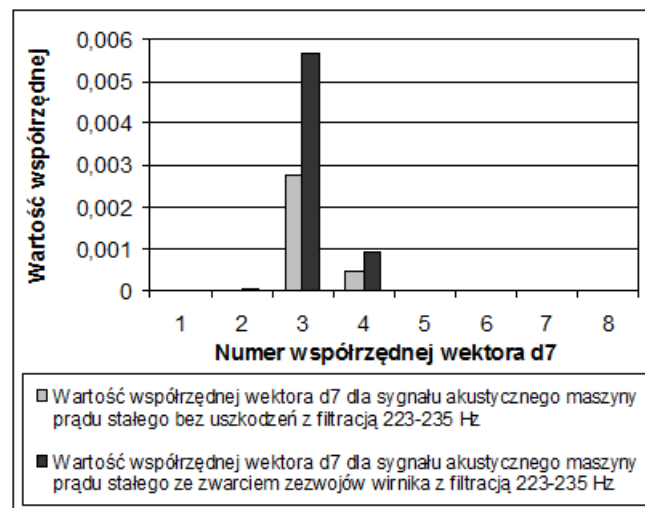


Rys. 3. Funkcja falkowa falki Symlet (sym2)

Transformacja falkowa sygnału akustycznego jest obliczana przez przepuszczenie go przez szereg filtrów: filtr dolnoprzepustowy i górnoprzepustowy [20, 25]. System rozpoznawania dźwięku otrzymuje współczynniki detali ($\mathbf{d}_1, \mathbf{d}_2, \mathbf{d}_3, \dots, \mathbf{d}_n$) z filtru górnoprzepustowego i współczynniki aproksymacji ($\mathbf{a}_1, \mathbf{a}_2, \mathbf{a}_3, \dots, \mathbf{a}_n$) z filtru dolnoprzepustowego, gdzie n jest poziomem rozkładu (Rys. 4).



Rys. 4. Współczynniki detali i aproksymacji dla 7-mego poziomu dekompozycji



Rys. 5. Współczynniki detali dźwięku maszyny prądu stałego po filtracji 223-235 Hz (falka sym2)

Wektory $\mathbf{d}_1, \dots, \mathbf{d}_n$ są ważne w procesie rozpoznawania dźwięku maszyny prądu stałego (Rys. 5). Bezwzględne wartości współrzędnych wektorów $\mathbf{d}_1, \dots, \mathbf{d}_n$ są używane w klasyfikacji.

2.2. Zmodyfikowany klasyfikator oparty na słowach

W literaturze została opisana duża liczba metod klasyfikacji [2-5, 16-19, 24, 27, 30-33, 35, 38]. Zmodyfikowany klasyfikator oparty na słowach wykorzystuje wektory słów do identyfikacji rodzaju sygnału akustycznego. Normalny klasyfikator oparty na słowach jest podobny do klasyfikatora najbliższej średniej. Zmodyfikowany klasyfikator oparty na słowach jest podobny do klasyfikatora najbliższego sąsiada. Podobieństwo to polega na tym, że wektory cech i wektory słów porównywane są ze sobą w taki sam sposób.

Współrzędne x_1, x_2, \dots, x_n wektora cech \mathbf{x} tworzą wzorec. Klasy wzorców w_1, w_2, \dots, w_j są związane z wektorami cech \mathbf{x} . Zbiór uczący jest używany w procesie tworzenia wzorca. Zbiór uczący zawiera przetworzone próbki dźwięku - wektory cech $\mathbf{x}_1, \mathbf{x}_2, \dots, \mathbf{x}_j$. Następnie, wektor cech \mathbf{x}_j jest przekształcany do wektora słów \mathbf{v}_j . Wektor słów może być zdefiniowany

następująco: $\mathbf{v}_j = [v_1, v_2, \dots, v_n]$, gdzie v_1, v_2, \dots, v_n są słowami. Każda klasa wzorców jest reprezentowana przez wektory słów. Liczba wzorców jest równa liczbie wektorów słów w procesie tworzenia wzorca. Współrzędne $x_1 \dots x_i$ wektora cech \mathbf{x}_j są przekształcane we współrzędne $v_{i1} \dots v_{ig}$ wektora słów \mathbf{v}_j . Zakres wartości jest reprezentowany przez słowo,

$$\left\{ \begin{array}{l} x_i \in [k, 2k) \Rightarrow x_i \rightarrow v_{i1} \\ x_i \in [2k, 3k) \Rightarrow x_i \rightarrow v_{i2} \\ \dots \\ x_i \in [kg, kg+k) \Rightarrow x_i \rightarrow v_{ig} \end{array} \right. \quad (1)$$

gdzie g jest liczbą słów, k jest liczbą rzeczywistą, x_i jest współrzędną wektora cech, $v_{i1} \dots v_{ig}$ oznaczają słowa.

Zmodyfikowany klasyfikator oparty na słowach używa wybranych zakresów wartości. Następnie używa on wartości współrzędnych wektora cech. Proponowany klasyfikator oparty jest na 260 słowach, ponieważ liczba ta jest wystarczająca do rozpoznawania. Następnie parametr k jest wybierany. Nowy wektor słów może być zdefiniowany jako $\mathbf{f} = [f_1, f_2, \dots, f_n]$, gdzie f_1, f_2, \dots, f_n są słowami. Proces identyfikacji używa nowej testowej próbki dźwięku. Próbka ta jest przekształcana w nowy wektor cech \mathbf{y} . Ten wektor \mathbf{y} jest przekształcany w wektor słów \mathbf{f} ,

$$\left\{ \begin{array}{l} y_i \in [k, 2k) \Rightarrow y_i \rightarrow v_{i1} \\ y_i \in [2k, 3k) \Rightarrow y_i \rightarrow v_{i2} \\ \dots \\ y_i \in [kg, kg+k) \Rightarrow y_i \rightarrow v_{ig} \end{array} \right. \quad (2)$$

gdzie g jest liczbą słów, k jest liczbą rzeczywistą, y_i jest współrzędną nowego wektora cech, $v_{i1} \dots v_{ig}$ oznaczają słowa,

Następnie próbka jest przypisywana do klasy, której wektor słów jest najbliższym wektora słów badanej próbki. Porównanie leksykograficzne jest używane, aby porównać dwa łańcuchy słów. Pierwszy łańcuch zawiera współrzędne wektora słów określonej klasy. Drugi łańcuch zawiera współrzędne nowego wektora słów badanej próbki. To może być przedstawione następująco: $f_1=v_1; f_2=v_2; \dots; f_n=v_n$. Wynik każdego porównania jest binarny (*prawda* lub *falsz*). Ostateczny wynik binarny jest używany w następującym równaniu:

$$U_j = \frac{U_1}{U_2} \cdot 100\% \quad (3)$$

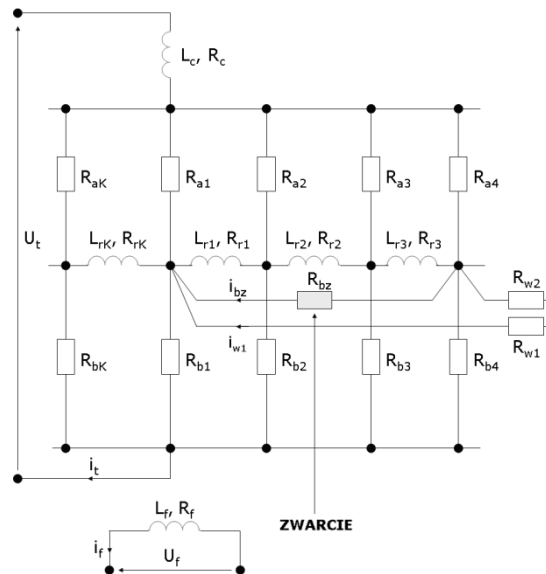
$$\max(U_j) \Rightarrow \mathbf{f} \rightarrow w_j \quad j = 1, 2, \dots, M, \quad (4)$$

gdzie: U_j jest procentową liczbą dobrze rozpoznanych słów, U_1 jest liczbą wyników *prawdy*, U_2 jest liczbą wszystkich porównań, \mathbf{f} jest nowym wektorem słów badanej próbki.

Wyniki rozpoznawania dźwięku zależą od danych zawartych w wektorze cech. Wyniki zależą również od parametru k . Parametr ten będzie dobierany w badaniach.

3. Wyniki rozpoznawania dźwięku

Mikrofon OLYMPUS TP-7 i karta dźwiękowa Realtek były użyte do nagrywania sygnałów akustycznych. Parametry pliku audio to: częstotliwość próbkowania - 44100 Hz, liczba bitów - 16, ilość kanałów - 1, format - WAVE PCM. Operacyjne parametry maszyny prądu stałego były następujące: $P_N = 13 \text{ kW}$, $U_N = 75 \text{ V}$, $I_N = 200 \text{ A}$, $U_{fN} = 220 \text{ V}$, $I_{fN} = 4 \text{ A}$, $n_N = 700 \text{ obr/min}$. Każda grupa trzech pętli zezwojów wirnika została zwarta za pomocą rezystancji $7,7 \text{ m}\Omega$. Ta rezystancja była rezystancją zewnętrzną. Została ona połączona z maszyną prądu stałego. Rezystancja ta została użyta, aby uniknąć uszkodzenia uzwojenia wirnika. Badania przeprowadzono dla dwóch sygnałów akustycznych maszyny prądu stałego: sygnału akustycznego bez uszkodzeń maszyny prądu stałego i sygnału akustycznego maszyny prądu stałego ze zwarcie zezwojów wirnika (Rys. 6).



Rys. 6. Schemat uzwojenia wirnika maszyny prądu stałego ze zwartymi zezwojami

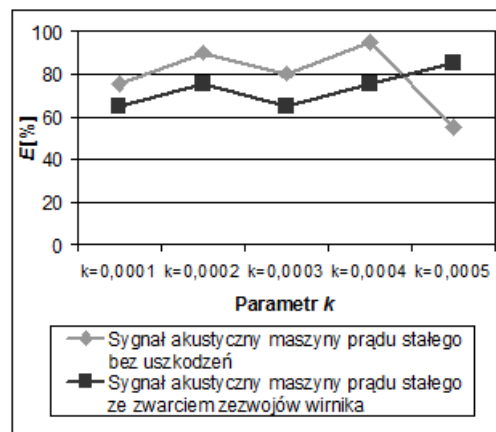
10 próbek o czasie trwania jednej sekundy było używanych w procesie tworzenia wzorców dla każdego rodzaju sygnału. 40 testowych próbek o czasie trwania jednej sekundy były używane w procesie identyfikacji. Skuteczność rozpoznawania dźwięku została wyrażona przez następujący wzór:

$$E = \frac{NCRTS}{NATS} 100\% \quad (5)$$

gdzie: $NCRTS$ – liczba prawidłowo rozpoznanych testowych próbek, $NATS$ – liczba wszystkich testowych próbek, E – Skuteczność rozpoznawania dźwięku.

Najlepsze wyniki rozpoznawania zostały uzyskane przy użyciu normalizacji amplitudy i filtru cyfrowego, który przepuszczał częstotliwości od 223 Hz do 235 Hz. Częstotliwość ta była związana z obrotami wirnika $f_c = 4Xn_N \text{ Hz}$, gdzie X wielokrotność częstotliwości. Gdy $X=5$ to częstotliwość $f_c = (20)(700/60) = 233,33 \text{ Hz}$ była zawarta w zakresie częstotliwości od 223 Hz do 235 Hz. Dolna granica filtru 223 Hz została wybrana w przypadku zmniejszenia się obrotów wirnika. Skuteczność rozpoznawania dźwięku maszyny prądu stałego bez uszkodzeń wynosiła 55-95%. Skuteczność rozpoznawania dźwięku maszyny prądu stałego ze zwarcie zezwojów wirnika wynosiła 65-85%. Skuteczność rozpoznawania dźwięku maszyny prądu stałego w zależności od parametru k

została przedstawiona na rysunku 7. Wyniki były najlepsze kiedy parametr k był równy 0,0004.



Rys. 7. Skuteczność rozpoznawania dźwięku maszyny prądu stałego w zależności od parametru k

4. Wnioski

W artykule autor zaproponował oryginalne podejście do wykrywania i lokalizacji usterek pojawiających się w maszynie prądu stałego. Wdrożenie systemu diagnostycznego maszyny prądu stałego zostało opisane. Sygnały akustyczne były analizowane przez system rozpoznawania dźwięku. Algorytmy przetwarzania danych badano dla maszyny prądu stałego. Wyniki rozpoznawania dźwięku były dobre dla transformacji falkowej Symlet i zmodyfikowanego klasyfikatora opartego na słowach. Skuteczność rozpoznawania dźwięku maszyny prądu stałego wynosiła 55-95%. Opisane wdrożenie systemu może być korzystne dla ochrony maszyn. Diagnostyka może być bardziej skuteczna kiedy różne techniki diagnostyczne będą pracować razem, takie jak rozpoznawanie obrazów termicznych, sygnałów akustycznych, sygnałów elektrycznych maszyn. Ponadto, to podejście zredukuje koszty utrzymania i liczbę uszkodzonych maszyn.

Podziękowania

Praca została zrealizowana w ramach działalności statutowej Katedry Automatyki i Inżynierii Biomedycznej, AGH (grantu dziekańskiego dla młodych naukowców) w roku 2014

Literatura

1. Antczak M, Idziak P. The influence of the sheet punching on the magnetic field distribution in a dc machine. *Przeгляд Elektrotechniczny* 2012; 88 (4a): 6-9.
2. Czopek K. Cardiac Activity Based on Acoustic Signal Properties. *Acta physica polonica A* 2012; 121 (1A): A42-A45.
3. Czopek K. Evaluation of Breathing Dynamics Using the Correlation of Acoustic and ECG signals. *IEEE Conference on Computing in Cardiology* 2011; Hangzhou; China: 33-36.
4. Długosz MM., Panek D., Maciejasz P., Chwała W., Alda W. An improved kinematic model of the spine for three-dimensional motion analysis in the Vicon system. *Research into spinal deformities 8, Studies in Health Technology and Informatics* 2012; 176: 227-231.
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. Florkowski M, Furgal J, Kuniewski M. Impact of transformers from overvoltages transferred through windings. *Przeglad Elektrotechniczny* 2012; 88 (5A): 104-107.
7. 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.
8. 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.
9. 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* 2012; 57 (3): 829-835.
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. Gogola D, Krafčík A, Strbak O, Frollo I. Magnetic Resonance Imaging of Surgical Implants Made from Weak Magnetic Materials. *Measurement Science Review* 2013; 13 (4): 165-168.
12. Golebiowski L, Golebiowski M, Mazur D. Unscented kalman filter in rotor diagnostic testing of the asynchronous motor. *Przeglad Elektrotechniczny*, 2011; 87 (8): 48-52.
13. Golebiowski L, Golebiowski M, Mazur D. Controlling of the 1- and 3-phase power factor correction (PFC) rectifiers, *Przeglad Elektrotechniczny*, 87 (8), 2011: 53-58.
14. Gronostajski Z, Hawryluk M, Krawczyk J, Marciniak M. Numerical modelling of the thermal fatigue of steel WCLV used for hot forging dies. *Eksploatacja i Niezawodnosc–Maintenance and Reliability* 2013; 15 (2): 129-133.
15. Gwozdziejewicz M, Zawilak J. Influence of the rotor construction on the single-phase line start permanent magnet synchronous motor performances. *Przeglad Elektrotechniczny* 2011; 87 (11): 135-138.
16. Hachaj T, Ogiela MR. Application of neural networks in detection of abnormal brain perfusion regions. *Neurocomputing* 2013; 122 (Special Issue): 33-42.
17. Jamro E, Cioch W. Digital signal acquisition and processing in FPGAs. *Przeglad Elektrotechniczny* 2009; 85(2): 7-9.
18. Jaworek J, Augustyniak P. A cardiac telerehabilitation application for mobile devices. *IEEE Conference on Computing in Cardiology* 2011; Hangzhou, China: 241-244.
19. 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.
20. 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.
21. Kulesza G, Panek P, Zieba P. Silicon Solar Cells Efficiency Improvement by the Wet Chemical Texturization in the HF/HNO₃/Diluent Solution. *Archives of Metallurgy and Materials* 2013; 58 (1): 291-295.
22. 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.
23. Madej M. Phase Reactions During Sintering of M₃/2 Based Composites with WC Additions. *Archives of Metallurgy and Materials* 2013; 58 (3): 703-708.
24. Markiewicz M, Skomorowski M. Public Transport Information System for Visually Impaired and Blind People. *10th Conference on Transport Systems Telematics* 2010; Katowice; Poland; *Transport Systems Telematics*; 104: 271-277.

25. MathWorks – MATLAB and SimuLink for Technical Computing 2013; www.mathworks.com.
26. 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.
27. 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.
28. Mishra P, Singla S. K. Artifact Removal from Biosignal using Fixed Point ICA Algorithm for Pre-processing in Biometric Recognition. *Measurement Science Review* 2013; 13 (1): 7-11.
29. Negrea M. D. Electromagnetic Flux Monitoring for Detecting Faults in Electrical Machines. PhD. Dissertation, 2006, Helsinki University of Technology.
30. Ogiela MR, Hachaj T. Automatic segmentation of the carotid artery bifurcation region with a region-growing approach. *Journal of Electronic Imaging* 2013; 22 (3), DOI: 10.1117/1.JEI.22.3.033029.
31. Orlewski W, Siwek A. Hydroelectric power plant using dump industrial water. *Rynek Energii* 2010; 6: 87-91.
32. 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.
33. Pieciak T. Bootstrap Uncertainty Estimation of Canine Cardiac Fibers Anisotropy and Diffusivity on DT-MRI Data. *IEEE 39th Conference on Computing in Cardiology, Book Series: Computers in Cardiology Series* 2012; 39: 369-372.
34. Pribil J, Gogola D, Dermek T, Frollo I. Design, Realization and Experiments with a new RF Head Probe Coil for Human Vocal Tract Imaging in an NMR device. *Measurement Science Review* 2012; 12 (3): 98-103.
35. 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.
36. Sun Y, Li L. Research on Wavelet Base Selection in Infrared Image Fusion. *Journal of Computational Information Systems*, 2010; 6 (11): 3823- 3831.
37. 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.
38. Trzupek M, Ogiela M R, Tadeusiewicz R. Intelligent image content semantic description for cardiac 3D visualizations. *Engineering Applications of Artificial Intelligence* 2011; 24 (8): 1410-1418.
39. Warzecha A, Mazgaj W. Identification techniques of functions approximating magnetization characteristics of synchronous machines. *COMPEL, The International Journal for Computation and Mathematics in Electrical and Electronic Engineering* 2013; 32(4): 1267-1277.
40. Zajac W, Marzec J, Molenda J. The effect of aluminium on the electrical and electrochemical properties of phospho-olivine - a cathode material for Li-ion batteries. *Materials Science-Poland* 2006; 24(1): 123-131.
41. Zawilak T. Investigation of higher harmonics in a Line-Start Permanent Magnet Synchronous Motor. *Przeglad Elektrotechniczny* 2008; 84 (12): 122-125.