

Adam GŁOWACZ

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

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

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

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

1. Wstęp


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

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

2. Proponowane podejście rozpoznawania sygnału akustycznego silnika indukcyjnego

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

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



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

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

2.1. Pomiary i wstępne przetwarzanie sygnałów akustycznych silnika indukcyjnego

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

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

2.2. Skrócona metoda wyboru częstotliwości (SMoFS-10)

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

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

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

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


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

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


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

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


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



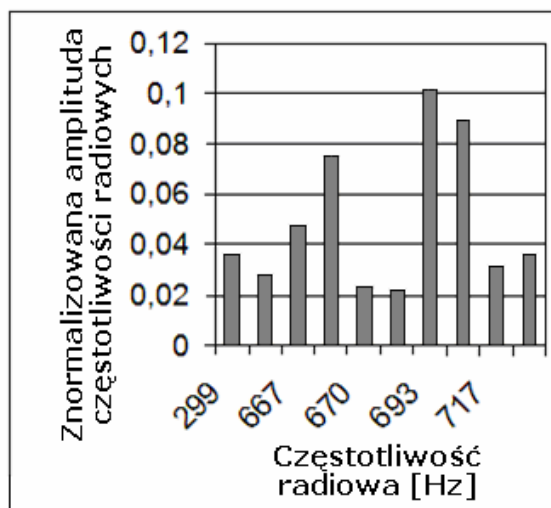
Rys. 2. Różnica między widmem sygnału akustycznego silnika indukcyjnego bez uszkodzeń i widmem sygnału akustycznego silnika indukcyjnego z uszkodzonym prętem wirnika



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




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



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

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



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

2.3. Liniowa maszyna wektorów wspierających

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

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


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

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


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

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

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



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



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

3. Analiza sygnałów akustycznych trójfazowych silników indukcyjnych

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

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



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

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

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

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

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

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

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

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

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

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

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

4. Podsumowanie

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

Podziękowania

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

Literatura

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

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