

doi:10.15199/48.2022.10.42

Zastosowanie wybranych klasyfikatorów uczenia maszynowego do rozpoznawania form wyładowań niezupełnych

Streszczenie. Ocena intensywności oraz form wyładowań niezupełnych pozwala na określenie stanu izolacji urządzeń elektroenergetycznych. W artykule przedstawiono możliwości identyfikacji podstawowych form wyładowań niezupełnych, przy wykorzystaniu wybranych algorytmów uczenia maszynowego. Przedstawiono wpływ różnych metod przetwarzania wstępnego sygnałów na skuteczność modeli sztucznej inteligencji. Zaproponowano metodę ekstrakcji cech statystycznych z sygnałów emisji akustycznej pozwalających na klasyfikację form wyładowań.

Abstract. The assessment of the intensity and forms of partial discharges allows for the determination of the insulation condition of electrical power devices. The article presents the possibilities of partial discharge form prediction of selected machine learning algorithms. The influence of various pre-processing methods on the effectiveness of artificial intelligence models is presented. A method of extracting statistical features from acoustic emission signals has been proposed, allowing for the prediction of discharge forms. (The use of selected machine learning classifiers to recognize forms of partial discharges).

Słowa kluczowe: wyładowania niezupełne, uczenie maszynowe, metoda emisji akustycznej, dekompozycja falkowa.

Keywords: partial discharges, machine learning, acoustic emission method, wavelet decomposition.

Wstęp

Ocena stanu technicznego urządzeń elektrycznych jest kluczowa do zapewnienia stabilnej pracy całego systemu elektroenergetycznego. Nierozłączną częścią tego systemu są transformatory mocy, których kompleksowa diagnostyka nie jest zwykle możliwa do wykonania bez ich czasowego wyłączenia. Jednym z czynników pozwalających zmniejszyć ilość przerw w eksploatacji transformatorów, związanych z koniecznością wykonania planowych badań, są pomiary wybranych parametrów diagnostycznych tych urządzeń w czasie rzeczywistym (on-line). Aktualnie intensywnie rozwijanymi systemami monitoringu on-line transformatorów mocy są systemy umożliwiające ocenę stanu technicznego ich układu izolacyjnego, w szczególności pod kątem detekcji, oceny intensywności i lokalizacji wyładowań niezupełnych (WZN). Wśród tych metod można m.in. wyróżnić:

- metodę elektryczną (pomiar ładunku pozornego),
- metodę emisji akustycznej (EA),
- metodę wysokiej częstotliwości (UHF) [1-4].

Spośród wymienionych powyżej metod, w warunkach tzw. polowej eksploatacji transformatorów, dość powszechnie i skutecznie stosowana jest metoda EA, która charakteryzuje się dużą odpornością na zakłócenia występujące w miejscu zainstalowania monitorowanej jednostki. Metoda ta pozwala nie tylko na określenie intensywności mierzonych WZN, lecz także na ich lokalizację – przy użyciu kilku przetworników pomiarowych. Dodatkowo poprzez porównanie zmierzonych sygnałów EA z tzw. wzorcami sygnałów generowanych przez podstawowe formy WZN, możliwe jest wstępne określenie typu defektu występującego w układzie izolacyjnym danego transformatora. Zadanie identyfikacji i klasyfikacji sygnałów EA od WZN z wykorzystaniem klasycznych algorytmów przetwarzania jest niestety bardzo złożone do realizacji, niemniej jednak prowadzone aktualnie badania dotyczące zastosowania nowoczesnych metod cyfrowej analizy danych z użyciem metod uczenia maszynowego wskazują na efektywne rozpoznawanie poszczególnych form WZN na podstawie ich sygnałów EA.


W ramach przeprowadzonych badań, dotyczących oceny skuteczności klasyfikacji zarejestrowanych sygnałów EA od WZN z użyciem wybranych metod uczenia maszynowego, pracownicy naukowcy Katedry Elektroenergetyki i Energii Odnawialnej Politechniki

Opolskiej zaproponowali następujący podział form WZN, które mogą występować w układzie izolacyjnym transformatorów:

- wyładowania w układzie ostrze – ostrze w oleju (Klasa 1),
- wyładowania w układzie ostrze – płyta w oleju (Klasa 2),
- wyładowania w układzie wieloostrze – płyta w oleju (Klasa 3),
- wyładowania w układzie powierzchniowym dwóch elektrod płaskich, między którymi znajduje się izolacja papierowo – olejowa (Klasa 4),
- wyładowania w układzie powierzchniowym jednej elektrody płaskiej, drugiej wieloostrzowej, między którymi znajduje się izolacja papierowo-olejowa (Klasa 5),
- wyładowania w układzie ostrze – ostrze w oleju z pęcherzykami gazowymi (Klasa 6),
- wyładowania w układzie wieloostrze – płyta w oleju z pęcherzykami gazowymi (Klasa 7),
- wyładowania na cząstkach o nieokreślonym potencjale, które przemieszczają się w oleju (Klasa 8) [5-6].

Układ pomiarowy

Układ pomiarowy służący do modelowania badanych form WZN przedstawiono na rysunku 1. Zestawy iskierników modelujących umieszczano kolejno w kadzi wypełnionej olejem. Przy modelowaniu WZN w oleju z pęcherzykami gazowymi wykorzystano generator pęcherzyków gazowych. W celu generowania WZN na cząstkach o nieokreślonym potencjale zanieczyszczono olej włóknami celulozowymi. Układ mieszający zapewniał równomierne rozproszenie zanieczyszczeń.

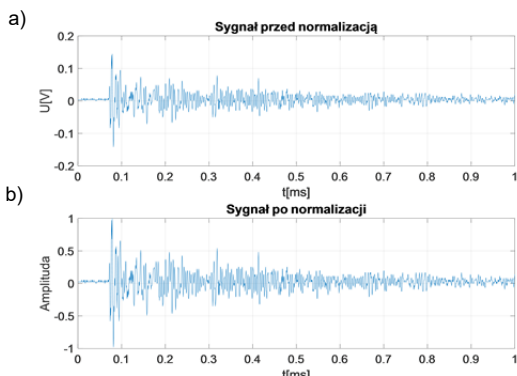


Rys.1. Schemat układu pomiarowego. 1 – kadź wypełniona olejem, 2 – iskiernik modelujący, 3 – generator pęcherzyków gazowych, 4 – przetwornik pomiarowy, 5 – wzmacniacz oraz filtr pomiarowy, 6 – komputer z kartą pomiarową [6].

Do akwizycji danych został wykorzystano przetwornik piezoelektryczny przymocowany do kadzi przy pomocy magnesów. Pasma przenoszenia przetwornika wynosiło od 100kHz do 1MHz. Generowane sygnały zostały wzmacnione i poddane filtracji, a następnie zarejestrowane przy pomocy karty pomiarowej o częstotliwości próbkowania 2,56MHz. Przebiegi czasowe zostały zapisane w formie plików .txt [5].

Wstępne przetwarzanie sygnałów

Wykorzystana baza sygnałów EA generowanych przez WNZ składała się z 898 plików, podzielonych ze względu na każdą analizowaną formę WNZ. Każdy zarejestrowany z częstotliwością 2,56 MHz plik zawierał 51200 próbek sygnału EA, co odpowiada czasowi pomiaru 20ms. W dalszym procesie przetwarzania, wykorzystano jednak fragment sygnału EA, który wg. autorów zawierał istotne informacje umożliwiające efektywną klasyfikację danej formy WNZ z użyciem badanych algorytmów klasyfikacyjnych. Na rysunku 2 przedstawiono przebieg czasowy wyodrębnionego sygnału EA od badanych form WNZ (2a) oraz wynik po procesie dodatkowej normalizacji tego sygnału (2b).



Rys.2. Proces normalizacji, a) sygnał EA przed normalizacją, b) sygnał EA po normalizacji

Ekstrakcja fragmentów odbywała się przy pomocy algorytmu opisanego równaniem (1):

$$(1) \quad x = y[I_{\max} - a; I_{\max} + b]$$

gdzie: x - fragment znaczący sygnału EA, y - sygnał EA, I_{\max} - numer próbki o największej wartości modułu amplitudy, a - liczba próbek określająca początek wycinanego fragmentu, b - liczba próbek określająca koniec wycinanego fragmentu.

W celu określenia wpływu długości zarejestrowanych sygnałów EA na skuteczność identyfikacji poszczególnych, zamodelowanych form WNZ, przebadano dwa przypadki. Dalszej obróbce cyfrowej oraz analizie poddano fragmenty sygnałów EA o długość 4700 i 6800 próbek. Wszystkie rejestrowane sygnały EA były generowane przez WNZ w niedalekiej odległości od przetwornika. W warunkach rzeczywistych zjawiska te mogą zachodzić w różnych miejscach diagnozowanego urządzenia. Dla zniwelowania wpływu zmiennej odległości na amplitudę mierzonych sygnałów EA zastosowano normalizację według wzoru (2):

$$(2) \quad n = \frac{x}{\max(|x|)}$$

gdzie: x - sygnał pierwotny, n - sygnał znormalizowany.


Należy jednak zaznaczyć, że proces normalizacji skutkuje utratą pewnej części informacji o analizowanym

sygnale EA, dlatego w trakcie oceny skuteczności klasyfikacji badanych algorytmów, weryfikację przeprowadzono na sygnałach znormalizowanych oraz nie poddanych temu procesowi. **Uczenie maszynowe**

Algorytmy uczenia maszynowego służą do tworzenia matematycznych modeli zjawisk na podstawie zebranych danych. Modele te można następnie wykorzystywać do predykcji (identyfikacji) zjawisk towarzyszących nowym danym, którymi w pierwotnej wersji nie został nauczonych dany algorytm. Modele uczenia maszynowego jako wyniki identyfikacji zwracają wartości rzeczywiste - dla regresji lub dyskretne - dla klasyfikacji. Ze względu na dyskretny charakter podziału rozpatrywanych form WNZ, przyjęto że analizowanym efektem działania wybranych metod uczenia maszynowego będzie skuteczność klasyfikacji. W ramach przeprowadzonych badań analizie porównawczej poddano trzy algorytmy klasyfikacyjne:

- drzewa decyzyjne (ang. Decision Tree),
- k-najbliższych sąsiadów (KNN - ang. K-Nearest Neighbours),
- maszyny wektorów nośnych (SVM - ang. Support Vector Machines).

Drzewa decyzyjne są zbiorem warunków „jeżeli – to” determinujących „gałąź” którą porusza się algorytm dokonując klasyfikacji. Po dotarciu do jednego z tzw. „liści”, w których przechowywane są wartości wyjściowe, klasyfikator zwraca wynik klasyfikacji [7]. Algorytm KNN przechowuje wszystkie dane wykorzystane w procesie uczenia. Model w trakcie predykcji szuka k najbliższych sąsiadów nowej danej. Następnie zlicza liczbę instancji każdej klasy w populacji najbliższych sąsiadów. Klasa z największą reprezentacją jest wynikiem klasyfikacji [8]. Natomiast algorytm SVM wyszukuje hiperpłaszczyznę, która najsukuteczniej separuje dane różnych klas. Wiele zestawów danych jest liniowo nierozdzielna. W takim przypadku stosuje się tzw. „sztuczkie jądra”. Modyfikuje ona istniejący układ zwiększając wymiarowość zestawu danych. Współrzędne w nowych wymiarach są obliczane przy pomocy funkcji jądra. W badaniach wykorzystano jądro Gaussa [9]. Do tworzenia modeli uczenia maszynowego wykorzystano środowisko MatLab z toolboxem „Classification Learner”.



Rys.3. Przykładowe wyniki dekompozycji DWT sygnałów EA

Ekstrakcja cech statystycznych

Jako dane wejściowe sygnałów EA od WNZ, które zostały użyte w procesie oceny skuteczności klasyfikacji przez badane algorytmy, zaproponowano wykorzystanie deskryptorów wyznaczonych w oparciu o wyniki przekształceń dyskretnej transformaty falkowej (DWT - ang. Discrete Wavelet Transform). Przy pomocy zestawu falek stworzonych z macierzystej funkcji „sym8” dokonano dekompozycji falkowej, w wyniku której otrzymano z

każdego sygnału EA 8 detali. Na rysunku 3 przedstawiono przykładowe wyniki przeprowadzonej dekompozycji falkowej DWT.

Następnie, dla każdego detalu dekompozycji DWT, wyznaczono deskrytory statystyczne, które umożliwiły „liczbowy” opis analizowanych sygnałów EA. Obliczone w ten sposób deskrytory:

- wartość średnia,
- mediana,
- wartość skuteczna,
- współczynnik kształtu,
- współczynnik szczytu,
- odchylenie standardowe,
- rozstęp międzykwartylowy,
- współczynnik skośności,

posłużyły jako dane wejściowe tzw. uczenia maszynowego. W przeprowadzonych badaniach porównano skuteczność klasyfikacji sygnałów EA od WNZ przez rozpatrywane algorytmy przy wykorzystaniu pojedynczych deskrytorów oraz ich pełnego zestawu. Zestawienie wykorzystanych macierzy poszczególnych deskrytorów zaprezentowano w Tabeli 1.

Uzyskane wyniki

Największą skutecznością spośród badanych modeli wykazał się model stworzony przy pomocy algorytmu SVM, wytrenowanego na wszystkich deskrytorach, bez normalizacji, z sygnałami o długości 4700 próbek. Macierz rozkładu analizowanych klas, reprezentowanych przez badane formy WNZ, dla algorytmu SVM zaprezentowano na rysunku 4.

1.	92,2%	0,0%	0,0%	0,0%	0,0%	2,4%	7,4%	0,0%
2.	0,0%	96,0%	2,0%	4,1%	0,0%	4,8%	0,0%	0,0%
3.	0,0%	0,0%	98,0%	0,0%	0,0%	0,0%	0,0%	0,0%
4.	0,0%	0,0%	0,0%	93,9%	2,2%	4,8%	0,0%	0,0%
5.	2,0%	0,0%	0,0%	0,0%	95,7%	0,0%	0,0%	0,0%
6.	3,8%	2,0%	0,0%	0,0%	0,0%	88,0%	9,0%	0,0%
7.	0,0%	2,0%	0,0%	0,0%	0,0%	0,0%	80,6%	2,0%
8.	2,0%	0,0%	0,0%	2,0%	2,2%	0,0%	3,0%	98,0%
	1.	2.	3.	4.	5.	6.	7.	8.

Rys.4. Macierz rozkładu skuteczności klasyfikacji klas WNZ dla maszyny SVM i numeru macierzy deskrytorów 17

Macierz rozkładu jest przyjętą przez autorów metodą reprezentacji wyników klasyfikacji pozwalającą na analizę skuteczności identyfikacji rozpatrywanych klas. W macierzach zaprezentowano jaka część sygnałów EA od WNZ dla danych klas została sklasyfikowana poprawnie, oraz z jakimi innymi klasami były one mylone.

Na podstawie analizy danych zaprezentowanych na rysunku 4 można zauważyć, że najwięcej niepoprawnych klasyfikacji dokonano rozpoznając WNZ klasy 6 oraz 7, czyli kolejno WNZ typu ostrze – ostrze i wieloostre – płyta w oleju z pęcherzykami gazowymi. Formy te, ze względu na obecność losowo poruszających się pęcherzyków gazowych, charakteryzują się największą zmiennością wyznaczonych deskrytorów. Podobna sytuacja zachodzi w przypadku klasy 8 - WNZ na cząstkach o nieokreślonym potencjale, które przemieszczają się w oleju. Ten typ WNZ na tyle odróżnia się od pozostałych, że pomimo dużej przypadkowości zjawiska, zbiór deskrytorów opisujących tą formę nie zachodzą na pozostałe zbiory, co pozwala je skutecznie rozpoznawać.

Model stworzony przy pomocy algorytmu KNN z

wykorzystaniem 17. macierzy deskrytorów nie popełnił błędu klasyfikacji w przypadku identyfikacji sygnałów EA WNZ typu wieloostre – płyta w oleju. Ponownie można zauważyć, że najbardziej problematyczne do identyfikacji są sygnały EA generowane przez WNZ klasy 6 oraz 7. Macierz rozkładu klas dla najlepszego modelu KNN zaprezentowano na rysunku 5.

1.	90,4%	2,3%	0,0%	0,0%	0,0%	5,0%	0,0%	1,9%
2.	0,0%	93,2%	0,0%	2,0%	0,0%	7,5%	9,5%	0,0%
3.	0,0%	0,0%	100,0%	0,0%	0,0%	5,0%	0,0%	0,0%
4.	0,0%	0,0%	0,0%	92,2%	4,0%	0,0%	0,0%	0,0%
5.	0,0%	0,0%	0,0%	0,0%	94,0%	0,0%	0,0%	0,0%
6.	7,7%	0,0%	0,0%	0,0%	2,0%	80,0%	11,1%	1,9%
7.	1,9%	4,5%	0,0%	0,0%	0,0%	2,5%	79,4%	1,9%
8.	0,0%	0,0%	0,0%	5,9%	0,0%	0,0%	0,0%	94,3%
	1.	2.	3.	4.	5.	6.	7.	8.

Rys.5. Macierz rozkładu skuteczności klasyfikacji klas WNZ dla algorytmu KNN i numeru macierzy deskrytorów 17

Jedynym z badanych algorytmów, który lepiej klasyfikował znormalizowane sygnały EA okazały się drzewa decyzyjne. Macierz rozkładu klas dla modelu drzew decyzyjnych stworzonego z wykorzystaniem 18. macierzy deskrytorów przedstawiono na rysunku 6. Algorytm drzew decyzyjnych sklasyfikował poprawnie wszystkie sygnały EA pochodzące z klas 3 i 4. Ponownie jak dla algorytmu SVM, najbardziej problematyczna dla tej maszyny wnioskującej była identyfikacja WNZ typu ostrze – ostrze (Klasa 6) oraz wieloostre – płyta w oleju z pęcherzykami gazowymi (Klasa 7).

1.	94,0%	0,0%	0,0%	0,0%	0,0%	1,9%	3,5%	0,0%
2.	0,0%	88,0%	0,0%	0,0%	0,0%	3,8%	7,0%	0,0%
3.	0,0%	2,0%	100,0%	0,0%	0,0%	7,5%	3,5%	0,0%
4.	0,0%	0,0%	0,0%	100,0%	8,0%	0,0%	0,0%	3,7%
5.	0,0%	0,0%	0,0%	0,0%	92,0%	0,0%	0,0%	0,0%
6.	0,0%	8,0%	0,0%	0,0%	0,0%	75,5%	3,5%	0,0%
7.	0,0%	2,0%	0,0%	0,0%	0,0%	11,3%	82,5%	1,9%
8.	6,0%	0,0%	0,0%	0,0%	0,0%	0,0%	0,0%	94,4%
	1.	2.	3.	4.	5.	6.	7.	8.

Rys.6. Macierz rozkładu skuteczności klasyfikacji klas WNZ dla drzew decyzyjnych i numeru macierzy deskrytorów 18

Skuteczności uzyskane przez każdy z badanych przez autorów algorytmów uczenia maszynowego, dla wszystkich macierzy deskrytorów, zaprezentowano w tabeli 2.

Na podstawie przeprowadzonych badań stwierdzono, że spośród macierzy deskrytorów składających się z pojedynczych cech statystycznych, największą skutecznością klasyfikacji charakteryzowały się macierze z odchyleniami standardowymi oraz z wartością skuteczną. Zauważono także wyraźną tendencję do obniżenia skuteczności identyfikacji badanych sygnałów EA po ich normalizacji. Zwiększenie liczby próbek przetwarzanego sygnału EA spowodowało również spadek skuteczności rozpoznawania analizowanych form WNZ. Zjawisko to jest spowodowane większym udziałem zmierzonego sygnału EA, który nie zawiera istotnych informacji na temat danej formy WNZ.

Tabela 1. Zestawienie macierzy deskryptorów sygnałów EA przekształceń DWT wykorzystanych w procesie klasyfikacji

Numer macierzy deskryptorów	Liczba próbek sygnału	Normalizacja sygnału	Analizowany deskryptor	Numer macierzy deskryptorów	Liczba próbek sygnału	Normalizacja sygnału	Analizowany deskryptor
1.	4700	nie	Wartość średnia	11.	4700	nie	Odchylenie standardowe
2.	4700	tak		12.	4700	tak	
3.	4700	nie	Mediana	13.	4700	nie	Rozstęp międzykwartylowy
4.	4700	tak		14.	4700	tak	
5.	4700	nie	Wartość skuteczna	15.	4700	nie	Współczynnik skośności
6.	4700	tak		16.	4700	tak	
7.	4700	nie	Współczynnik kształtu	17.	4700	nie	Wszystkie deskryptory łącznie
8.	4700	tak		18.	4700	tak	
9.	4700	nie	Współczynnik szczytu	19.	6800	nie	
10.	4700	tak		20.	6800	tak	

Tabela 2. Całkowite wartości skuteczności klasyfikacji wszystkich ośmiu badanych form WNZ przez badane algorytmy uczenia maszynowego, w zależności od analizowanego deskryptora

Numer macierzy deskryptorów	Analizowany deskryptor	SVM	KNN	Drzewa decyzyjne	Numer macierzy deskryptorów	Analizowany deskryptor	SVM	KNN	Drzewa decyzyjne
1.	Wartość średnia	29,40%	28,00%	41,75%	11.	Odchylenie standardowe	83,25%	77,25%	71,50%
2.		27,50%	34,75%	36,50%	12.		80,75%	75,00%	73,50%
3.	Mediana	21,20%	24,00%	39,25%	13.	Rozstęp międzykwartylowy	78,81%	75,00%	75,50%
4.		30,25%	25,00%	40,00%	14.		77,80%	75,25%	73,80%
5.	Wartość skuteczna	81,20%	77,50%	72,00%	15.	Współczynnik skośności	38,75%	12,50%	30,25%
6.		77,75%	73,25%	74,50%	16.		36,50%	12,75%	29,25%
7.	Współczynnik kształtu	12,17%	25,25%	34,75%	17.	Wszystkie deskryptory łącznie	94,16%	91,10%	86,40%
8.		21,00%	31,25%	40,00%	18.		92,32%	90,70%	89,20%
9.	Współczynnik szczytu	70,75%	58,25%	65,25%	19.		93,25%	90,75%	88,40%
10.		65,25%	53,00%	66,50%	20.		91,95%	89,32%	88,80%

Podsumowanie

Przeprowadzone badania wykazały, że zastosowanie analizowanych metod uczenia maszynowego umożliwia efektywne rozpoznawanie podstawowych form WNZ na podstawie analizy ich wybranych parametrów sygnału EA przetworzonego z użyciem przekształceń DWT. Zaletą badanych metod uczenia maszynowego jest relatywnie niskie, w porównaniu np. do zastosowania sztucznych sieci neuronowych, zapotrzebowanie na moc obliczeniową, a proces uczenia oraz predykcji jest relatywnie krótki. Najwyższe skuteczności klasyfikacji uzyskano trenując badane algorytmy macierzami deskryptorów z pełnym zestawem wyznaczanych cech statystycznych – stopniowe zwiększanie danych wejściowych do uczenia maszynowego o kolejne deskryptory powodowało wzrost skuteczności klasyfikacji. Dodatkowo stwierdzono, że maszyny SVM i KNN największą skuteczność osiągały na zestawach danych nie poddanych normalizacji. Na uwagę zasługuje również fakt, iż wyładowania elektryczne generowane w oleju z pęcherzykami gazowymi (Klasy 6, 7) oraz cząsteczkami (Klasa 8) cechują się największym podobieństwem, dlatego są najbardziej problematyczne do klasyfikacji. Identyfikacja sygnałów EA od przyjętych form WNZ najskuteczniej realizowana była jednak przez maszynę SVM, a dalsze prace winny zostać ukierunkowane nad zindywidualizowaną funkcją jądra tego algorytmu, co z pewnością zwiększyłoby jeszcze uzyskaną aktualnie skuteczność identyfikacyjną.

Autorzy: dr hab. inż. Andrzej Cichoń, Politechnika Opolska, Katedra Elektroenergetyki i Energii Odnawialnej, ul. Próżkowska 76, 45-758 Opole, E-mail: a.cichon@po.edu.pl; prof. dr hab. inż. Sebastian Borucki, Politechnika Opolska, Katedra Elektroenergetyki i Energii Odnawialnej, ul. Próżkowska 76, 45-758 Opole, E-mail: s.borucki@po.edu.pl; inż. Michał Włodarz, Politechnika Opolska, Katedra Elektroenergetyki i Energii Odnawialnej, ul. Próżkowska 76, 45-758 Opole, E-mail: michal.wlodarz@student.po.edu.pl.

LITERATURA

- [1] Kraetge A., Hoek S., Koch M., Kołtunowicz W., Robust measurement, monitoring and analysis of partial discharges in transformers and other HV apparatus, *IEEE Trans. Dielect. El. Ins.*, 20 (2013), 2043–2051
- [2] Rubio-Serrano J., Rojas-Moreno M.V., Posada J., Martinez-Tarifa J.M., Robles G., Garcia-Souto J.A., Electro-acoustic detection, identification and location of PD sources in oil-paper insulation systems, *IEEE Trans. on Dielect. and El. Ins.*, 19 (2012), 1569–1578
- [3] Mirzaei H., Akbari A., Gockenbach E., Miralikhani K., Advancing new techniques for UHF PD detection and localization in the power transformers in the factory tests, *IEEE Trans. Dielectr. Electr. Ins.*, 22, (2015), 448–455
- [4] Yaaacob M.M., Alsaedi M.A., Rashed J.R., Dakhil A.M., Atyah S.F., Review on partial discharge detection techniques related to high voltage power equipment using different sensors, *Photonic Sens.*, 4 (2014), 325–337
- [5] Boczar T., Cichoń A., Borucki S., Diagnostic expert system of transformer insulation systems using the acoustic emission method, *IEEE Trans. on Dielect. and El. Ins.*, 21, (2014), 854–865
- [6] Borucki S., Łuczak J., Lorenc M., The Application of Selected Hierarchical Clustering Methods for Classification the Acoustic Emission Signals Generated by Partial Discharges. *Arch. of Acoust.*, 46, (2021), 409–417
- [7] Breiman, L., Random forest, *Mach. Learn.*, 45 (2001), 5–32
- [8] Aha D.W., Kibler D., Albert M.K., Instance-based learning algorithms, *Mach Learn.*, 6 (1991), 37–66
- [9] Keerthi S. S., Shevade S. K., Bhattacharyya C., Murthy K. R. K., Improvements to Platt's SMO Algorithm for SVM Classifier Design, *Neural Computation*, 13, (2001), 637-649