

Zastosowanie sieci neuronowych do wspomagania diagnostyki podobciążeniowych przełączników zacze­pów metodą oscylograficzną oraz metodą emisji akustycznej

Streszczenie. Podobciążeniowe przełączniki zacze­pów są częstą przyczyną awarii transformatorów. Interpretacja wyników uzyskanych różnymi metodami oceny stanu technicznego przełączników, wymaga od diagnosty dużego doświadczenia praktycznego. W artykule zaproponowano wykorzystanie konwolucyjnych sieci neuronowych do wspomagania procesu diagnostyki podobciążeniowych przełączników zacze­pów. Przedstawiono wyniki klasyfikacji sygnałów oscylograficznych oraz emisji akustycznej. W efekcie końcowym osiągnięto bardzo wysokie skuteczność klasyfikacji przekraczające 98%.

Abstract. On-load tap-changers are a common cause of transformer failures. Interpreting the results obtained by methods for assessing the condition of the tap-changers, requires a lot of experience. The use of convolutional neural networks is proposed to support the diagnostic process of on-load tap changers. This paper presents the results of classification of oscillographic and acoustic emission signals. The end result was very high classification efficiencies in excess of 98%. (The use of neural networks to support the diagnosis of on-load tap changers by oscillographic and acoustic emission methods).

Słowa kluczowe: sieci neuronowe, podobciążeniowe przełączniki zacze­pów, metoda emisji akustycznej, metoda oscylograficzna
Keywords: neural network, on-load tap-changer, acoustic emission method, oscillographic method

Wstęp

Transformatory pełnią kluczową rolę w systemie elektroenergetycznym. Awarie jednostek zdarzają się stosunkowo rzadko, jednak proces usuwania skutków awarii transformatorów jest kosztowny i czasochłonny. Jedną z częstych przyczyn wyłączenia transformatorów są awarie podobciążeniowych przełączników zacze­pów (PPZ) [1]. PPZ umożliwiają regulację poziomów napięcia w sieci elektroenergetycznej poprzez zmianę liczby aktywnych zwojów w transformatorze. Mechanizm PPZ działa w warunkach obciążenia, dzięki czemu energia może być dostarczana do odbiorców w sposób ciągły [2].

Ze względu na sposób gaszenia łuku elektrycznego można wyróżnić dwie najpopularniejsze grupy PPZ [3]:

- olejowe,
- próżniowe.

Prezentowane badania skupiają się na PPZ olejowych. Przyczyny uszkodzeń przełączników olejowych można podzielić na trzy grupy [4]:

- degradacja oleju,
- defekty mechaniczne,
- defekty elektryczne.

Powszechnie uznaną metodą oceny stanu technicznego PPZ jest metoda oscylograficzna. Polega ona na wymuszeniu prądu stałego w obwodach przełącznika oraz rejestracji ich zmiany podczas przełączenia [5]. Przebiegi czasowe prądów w poszczególnych fazach pozwalają diagnoście na ocenę stopnia zużycia podzespołów PPZ. Interpretacja wyników uzyskanych z wykorzystaniem metody oscylograficznej wymaga dużego doświadczenia [6], dlatego zaproponowano zastosowanie narzędzi uczenia maszynowego do wspomagania procesu diagnostyki PPZ. Głównym ograniczeniem metody oscylograficznej jest brak możliwości przeprowadzenia diagnostyki podczas pracy transformatora pod obciążeniem [6].


Podczas pracy PPZ następuje generacja sygnałów emisji akustycznej (EA) [7]. Niosą one informacje na temat charakteru pracy przełącznika. Rejestracja sygnałów EA może być przeprowadzona podczas normalnej pracy transformatorów pod obciążeniem, jednak korelacja sygnałów EA z występującymi defektami w PPZ jest niezwykle trudna i często niejednoznaczna [8].

Opracowanie metody interpretacji sygnałów EA może przyczynić się do zwiększenia zakresu wykorzystania metody diagnostyki PPZ w warunkach rzeczywistych. Autorzy przedstawionych badań zaproponowali zastosowanie w tym celu sieci neuronowych.

Trenowanie oraz ocena skuteczności wykorzystania sieci neuronowej wymaga obszernej bazy pomiarowej. We wstępnej fazie prac badawczych utworzono autorską bazę pomiarową sygnałów EA oraz przebiegów oscylograficznych. Podczas badań skupiono się na mechanicznych defektach PPZ takich jak: symetryczne i asymetryczne zużycie styków oraz uszkodzenie sprężynowego magazynu energii mechanicznej.

Układ pomiarowy

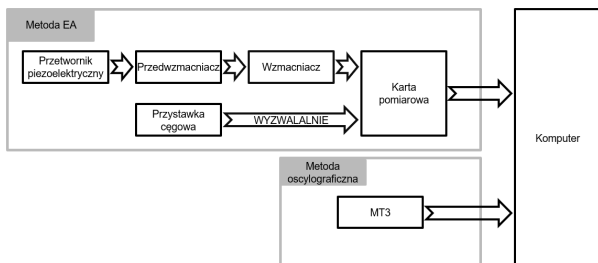
Podczas pomiarów laboratoryjnych wykorzystano rzeczywisty model olejowego PPZ wyposażonego w przełącznik mocy typu VEL-110. Został on umieszczony w kadzi wypełnionej olejem, co pozwoliło na odwzorowanie naturalnego środowiska pracy PPZ. Widok Przełącznika mocy umieszczonego w kadzi zaprezentowano na rysunku 1.



Rys.1. Przełącznik mocy typu VEL-110 umieszczony w kadzi

Pomiary laboratoryjne wykonano metodą oscylograficzną oraz metodą EA. Przebiegi oscylograficzne rejestrowano z wykorzystaniem urządzenia MT3. Równocześnie rejestrowano sygnały EA. Tor pomiarowy

składał się z przetwornika piezoelektrycznego, przedwzmacniacza, wzmacniacza oraz karty pomiarowej. Zastosowano szerokopasmowy przetwornik piezoelektryczny WD17AH firmy Physical Acoustics, o paśmie przenoszenia 100-900 kHz. Jako warunek wyzwolenia karty pomiarowej zdefiniowano wzrost prądu w układzie napędu PPZ mierzonego z wykorzystaniem przystawki cęgowej. Schemat układu pomiarowego przedstawiono na rysunku 2.



Rys.2. Schemat układu pomiarowego


Pierwsza seria pomiarowa została wykonana dla sprawnego PPZ, serię tą opisano jako Klasa 1. Następnie wykonano pomiary dla PPZ z zamodelowanym symetrycznym zużyciem styków. Mechaniczna obróbka pozwoliła na odwzorowanie w warunkach laboratoryjnych stopniowej degradacji styków. W przypadku modelowania asymetrycznego zużycia styków, zastosowano zmodyfikowane styki o różnej grubości dla każdej z faz. Uszkodzenie sprężynowego magazynu energii zamodelowano poprzez demontaż jednej z dwóch sprężyn wchodzących w jego skład. Modelowane defekty PPZ, wraz z przydzielonymi etykietami obejmowały 7 klas:

- symetrycznie zużyte styki o 1mm (Klasa 2),
- symetrycznie zużyte styki o 2mm (Klasa 3),
- symetrycznie zużyte styki o 3mm (Klasa 4),
- symetrycznie zużyte styki o 4mm (Klasa 5),
- asymetrycznie zużyte styki o 0/0/2mm (Klasa 6),
- asymetrycznie zużyte styki o 0/3/2mm (Klasa 7),
- uszkodzony magazyn energii kinetycznej (Klasa 8).


Wyniki pomiarów laboratoryjnych

Metoda oscylograficzna, jako uznana metoda oceny stanu technicznego PPZ, pozwoliła na rzetelne zweryfikowanie poprawności modelowania defektów. Analizę przebiegów oscylograficznych można wykonać poprzez odczytanie trzech czasów charakterystycznych, T_1 , T_2 , T_c [9]. Czas T_1 określany jest jako odstęp czasu od otwarcia pierwszego styku głównego do zamknięcia drugiego styku rezystancyjnego. Czas T_2 odczytywany jest od chwili zamknięcia drugiego styku rezystancyjnego do otwarcia pierwszego styku rezystancyjnego. Czas T_c opisuje całkowity czas przełączenia. Przebiegi czasowe prądów w poszczególnych fazach powinny się pokrywać, w innym wypadku można mówić o asymetrii przełączania poszczególnych faz. Rysunek 3 przedstawia przykładowe dwa przebiegi oscylograficzne, dla sprawnego PPZ (a) oraz dla PPZ z asymetrycznym zużyciem styków (b).

Równoległe do pomiarów PPZ metodą oscylograficzną, przeprowadzono pomiary metodą EA. Rejestrowano 5 sekundy przebiegi z częstotliwością próbkowania 350 kHz. W celu zminimalizowania wpływu umieszczenia przetworników, znormalizowano przebiegi czasowe. Samo przełączenie stanowiło niewielki fragment zarejestrowanych sygnałów EA, dlatego postanowiono wyizolować fragmenty znaczące obejmujące 150 ms. Pozwoliło to na ułatwienie oraz przyspieszenie dalszych badań. Cały zarejestrowany przebieg, wraz z wyizolowanym fragmentem znaczącym zaprezentowano na rysunku 4.




Rys.3. Wyniki pomiarów metodą oscylograficzną dla a) sprawnego PPZ, b) PPZ z asymetrycznie zużytymi stykami



Rys.4. Przykładowy znormalizowany sygnał EA, a) cały zarejestrowany przebieg, b) znaczący fragment sygnału EA

Przebiegi czasowe EA charakteryzują się występowaniem szeregu zdarzeń akustycznych. Ze względu na brak możliwości przypisania poszczególnych zdarzeń akustycznych do etapów przełączenia PPZ, interpretacja wyników jest trudna i często niejednoznaczna. W praktyce porównuje się zarejestrowane przebiegi z wzorcowym przebiegiem EA, nazywanym „odciskiem palca”. W trakcie kontroli okresowej porównuje się przebiegi EA z wzorcem. Odstępstwa pomiędzy porównywanymi przebiegami mogą świadczyć o zużyciu elementów składowych PPZ. Rysunek 5 przedstawia przykładowe przebiegi EA dla każdej z modelowanych klas.




Rys.5. Przykładowe sygnały EA dla każdej z modelowanych klas defektów PPZ

Sieci neuronowe

Rozwiązując zagadnienie klasyfikacji obrazów, często wykorzystuje się konwolucyjne sieci neuronowe (CNN). Dzięki zastosowaniu zestawu filtrów, CNN ucą się wyodrębnić cechy pozwalające skutecznie klasyfikować obrazy. Każda kolejna warstwa konwolucyjna wykrywa struktury o większej skali niż warstwa poprzednia. CNN można wykorzystać również do klasyfikacji jednowymiarowych przebiegów czasowych, takich jak sygnały EA.

Zaproponowano stworzenie dwóch modeli CNN, klasyfikujący sygnały oscylograficzne oraz EA. Jako dane wejściowe dla modelu CNN postanowiono wykorzystać całe przebiegi czasowe, natomiast dla modelu analizującego wyniki metody oscylograficznej - trzy przebiegi czasowe prądów, odpowiadające trzem fazom PPZ. Każdy z przebiegów składał się z 2500 próbek, co daje łącznie 7500 cech przekazywanych na wejście modelu. Zbiór uczący składał się z 1521 przebiegów. Zestaw treningowy dla sygnałów EA obejmował 1516 sygnałów EA składających się z 53000 próbek. Schemat przedstawiający kształty zestawów uczących zaprezentowano na rysunku 6.



Rys.6. Kształt zestawów uczących dla stworzonych modeli CNN

Dla obu modeli zastosowano bliźniaczą architekturę sieci neuronowej. Po warstwie wejściowej następował szereg warstw konwolucyjnych umieszczanych przemiennie z warstwami łączącymi. Zadaniem warstw łączących jest zmniejszenie cech przekazywanych do dalszych warstw poprzez odrzucenie danych o mniejszej istotności. Pozwala to na przyspieszenie procesu uczenia. Po wykonaniu wszystkich konwolucji wykorzystywano warstwę spłaszczającą, której zadaniem było zmodyfikowanie kształtu macierzy wielowymiarowej do macierzy jednowymiarowej. Zabieg taki był konieczny przed przekazaniem danych do warstw gęstych. Pomiędzy warstwami gęstymi umieszczono warstwy porzucenia. Zastosowanie ich zmniejszało ryzyko przetrenowania sieci. Rozwiązywane zagadnienie klasyfikacji obejmuje 8 klas, dlatego też warstwę wyjściową stanowiło 8 neuronów.

Uzyskane wyniki

Liczbę epok, czas trwania szkolenia, rozmiar zestawu testowego oraz osiągnięte skuteczności dla obu stworzonych modeli CNN zaprezentowano w tabeli 1. Oba modele osiągnęły wysoką skuteczność przekraczającą 98%.

Tabela 1. Wyniki procesu trenowania CNN

	EA	Oscylografia
Liczba epok	30	50
Średni czas trwania epoki	12 min 52sek	4min 28sek
Łączny czas uczenia	6h 26min	3h 43min
Skuteczność na zestawie uczącym	99,1%	99,5%
Rozmiar zestawu testowego	1517	1520
Skuteczność na zestawie testowym	98,9%	99,8%

Stworzone klasyfikatory zostały sprawdzone z wykorzystaniem zestawów przebiegów, których nie dostarczono im podczas procesu trenowania. Osiągnięte wyniki klasyfikacji zestawów testowych były zbliżone do wyników uzyskanych na danych treningowych. Pozwala to stwierdzić, że nie doszło do przetrenowania sieci neuronowych. Model klasyfikujący wyniki oscylograficzne osiągnął większą skuteczność na zestawie testowym w

stosunku do zestawu uczącego. Zjawisko takie może zachodzić, w przypadku zastosowania warstw porzucenia. Są one aktywne podczas uczenia modeli, a następnie, po zakończeniu, procesu uczenia są one pomijane. Brak wprowadzanego przez nie losowych zakłóceń podczas klasyfikacji zestawu testowego często doprowadza do osiągnięcia większych skuteczności.

Rzeczywista klasa \ Przewidziana klasa	Klasa 1	Klasa 2	Klasa 3	Klasa 4	Klasa 5	Klasa 6	Klasa 7	Klasa 8
Klasa 1	100.00%	0.00%	0.00%	0.00%	0.00%	0.00%	0.00%	0.00%
Klasa 2	0.00%	99.42%	0.00%	0.58%	0.00%	0.00%	0.00%	0.00%
Klasa 3	0.00%	0.00%	100.00%	0.00%	0.00%	0.00%	0.00%	0.00%
Klasa 4	0.00%	0.00%	0.00%	100.00%	0.00%	0.00%	0.00%	0.00%
Klasa 5	0.00%	0.00%	0.00%	0.57%	99.43%	0.00%	0.00%	0.00%
Klasa 6	0.00%	0.00%	0.00%	0.00%	0.00%	100.00%	0.00%	0.00%
Klasa 7	0.00%	0.00%	0.00%	0.00%	0.00%	0.00%	100.00%	0.00%
Klasa 8	0.00%	0.00%	0.00%	0.00%	0.00%	0.00%	0.00%	100.00%

Rys.7. Przykładowa macierz pomyłek dla modelu klasyfikującego przebiegi oscylograficzne

Macierze pomyłek pozwalają na zweryfikowanie skuteczności klasyfikacji poszczególnych klas, oraz na stwierdzenie które defekty PPZ są najczęściej mylone. Model klasyfikujący przebiegi oscylograficzne najwięcej pomyłek popełnił w obrębie klas 2 i 5. Klasy te opisują defekty symetrycznego zużycia się styków. Sygnały te są do siebie najbardziej podobne, dlatego można spodziewać się największej liczby niepoprawnych klasyfikacji w tym obszarze. Na przekątnej macierzy pomyłek znajdują się poprawnie sklasyfikowane przebiegi.

W celu dokładniejszej oceny jakości klasyfikacji poszczególnych defektów wyznaczono następujące wskaźniki:

- (1)
$$\text{Dokładność} = \frac{TP + TN}{TP + FP + FN + TN}$$
- (2)
$$\text{Precyzja} = \frac{TP}{TP + FP}$$
- (3)
$$F1 = \frac{2TP}{2TP + FP + FN}$$
- (4)
$$\text{Czułość} = \frac{TP}{TP + FN}$$
- (5)
$$\text{Swoistość} = \frac{TN}{TN + FP}$$

gdzie: TP – prawdziwie pozytywne, TN – prawdziwie negatywne, FP – fałszywie pozytywne, FN – fałszywie negatywne.

Dokładność	1.000	0.999	1.000	0.998	0.999	1.000	1.000	1.000
Precyzja	1.000	0.994	1.000	1.000	0.994	1.000	1.000	1.000
F1	1.000	0.997	1.000	0.996	0.997	1.000	1.000	1.000
Czułość	1.000	1.000	1.000	0.991	1.000	1.000	1.000	1.000
Swoistość	1.000	0.999	1.000	1.000	0.999	1.000	1.000	1.000
	Klasa 1	Klasa 2	Klasa 3	Klasa 4	Klasa 5	Klasa 6	Klasa 7	Klasa 8

Rys.8. Metryki opisujące jakość klasyfikacji poszczególnych klas dla modelu klasyfikującego przebiegi oscylograficzne

Metryki wyznaczono dla każdej z klas, każdorazowo traktując klasę, dla której wyznaczano wskaźniki, jako klasę prawdziwą, a pozostałe klasy przypisano do klasy fałszywej.

Na rysunku 8 zaprezentowano wyznaczone wskaźniki jakości klasyfikacji dla modelu interpretującego przebiegi oscylograficzne. Ponownie można zauważyć, że najwięcej niepoprawnych klasyfikacji dokonano w obrębie defektów symetrycznego zużycia się styków. Dla sprawnego PPZ (klasy 1), wskaźniki precyzji oraz czułości osiągnęły wartość 1. Oznacza to, że w żadnym przypadku nie sklasyfikowano niepoprawnie PPZ z defektem jako sprawnego oraz nie pomyłono sprawnego PPZ z uszkodzonym.

Rzeczywista Klasa	Klasa 1	Klasa 2	Klasa 3	Klasa 4	Klasa 5	Klasa 6	Klasa 7	Klasa 8
Klasa 1	98,24%	0,00%	0,00%	0,00%	0,00%	0,88%	0,44%	0,44%
Klasa 2	0,58%	97,69%	0,00%	0,00%	1,16%	0,58%	0,00%	0,00%
Klasa 3	0,00%	0,41%	99,59%	0,00%	0,00%	0,00%	0,00%	0,00%
Klasa 4	0,00%	0,00%	0,00%	100,00%	0,00%	0,00%	0,00%	0,00%
Klasa 5	0,00%	0,48%	0,00%	0,48%	99,04%	0,00%	0,00%	0,00%
Klasa 6	0,96%	0,00%	0,00%	0,00%	0,00%	99,04%	0,00%	0,00%
Klasa 7	0,00%	0,00%	0,00%	0,00%	0,93%	0,93%	98,15%	0,00%
Klasa 8	1,08%	0,00%	0,00%	0,00%	0,00%	0,00%	0,00%	98,92%

Rys.9. Przykładowa macierz pomyłek dla modelu klasyfikującego przebiegi EA

Pomimo, że skuteczność rozpoznawania poszczególnych defektów klasyfikatora sygnałów EA jest niższa niż w przypadku klasyfikatora przebiegów oscylograficznych, nadal klasyfikuje defekty PPZ z dużą trafnością. Na rysunku 9 można zaobserwować na, że oprócz niepoprawnych klasyfikacji defektów symetrycznego zużycia się styków, pojawiły się pomyłki w klasyfikacji asymetrycznej zużytych styków. Jako sprawny PPZ najczęściej razy niepoprawnie sklasyfikowano przełącznik z uszkodzeniem sprężynowego magazynu energii.

	Klasa 1	Klasa 2	Klasa 3	Klasa 4	Klasa 5	Klasa 6	Klasa 7	Klasa 8
Dokładność	0.995	0.996	0.999	0.999	0.996	0.996	0.998	0.999
Precyzja	0.982	0.977	0.996	1.000	0.990	0.990	0.981	0.989
F1	0.985	0.983	0.998	0.998	0.988	0.976	0.986	0.989
Czułość	0.987	0.988	1.000	0.995	0.986	0.963	0.991	0.989
Swoistość	0.997	0.997	0.999	1.000	0.998	0.999	0.998	0.999

Rys.10. Metryki opisujące jakość klasyfikacji poszczególnych klas dla modelu klasyfikującego przebiegi EA

Dla klasyfikatora sygnałów EA wskaźniki przedstawiono na rysunku 10. Wszystkie wartości wskaźników są bliskie 1, co oznacza, że wszystkie defekty są klasyfikowane skutecznie.

Podsumowanie

Zastosowanie konwolucyjnych sieci neuronowych umożliwia skuteczną klasyfikację sygnałów EA oraz przebiegów oscylograficznych, pozwalającą na wykrycie defektów w PPZ. Model klasyfikujący przebiegi oscylograficzne wykazuje większą skuteczność

w porównaniu do modelu klasyfikującego sygnały EA, dodatkowo uczenie klasyfikatora przebiegów oscylograficznych jest mniej wymagające obliczeniowo. Jednak, dużą zaletą metody EA w stosunku do metody oscylograficznej, jest możliwość przeprowadzenia pomiarów w trakcie normalnej pracy transformatora pod obciążeniem.

Wykorzystany szerokopasmowy przetwornik piezoelektryczny WD17AH obejmuje pasmo występowania sygnałów EA generowanych przez wyładowania niepełne, co może pozwolić na przeprowadzenie kompleksowej diagnostyki PPZ zarówno pod kątem występowania defektów mechanicznych oraz elektrycznych.

Przedstawione w artykule wyniki badań mogą być podstawą do opracowania systemu wspomagania interpretacji wyników pomiarowych w diagnostyce PPZ.

Można się spodziewać, że pomiary wykonane w warunkach rzeczywistych będą zawierały znacznie więcej zakłóceń. Należałoby w takim przypadku zastosować dodatkowo metody przetwarzania sygnałów.

Dalsze badania skupią się na porównaniu przydatności innych przetworników piezoelektrycznych, w rozpoznawaniu defektów PPZ. Przewiduje się, że zastosowanie jako dane wejściowe spektrogramów pozwoli na przyspieszenie procesu trenowania sieci neuronowych, z zachowaniem wysokich skuteczności.

Autorzy: ; mgr inż. Michał Włodarz, Politechnika Opolska, Katedra Elektroenergetyki i Energii Odnawialnej, ul. Prószkowska 76, 45-758 Opole, E-mail: michal.wlodarz@student.po.edu.pl; prof. dr hab. inż. Andrzej Cichoń, Politechnika Opolska, Katedra Elektroenergetyki i Energii Odnawialnej, ul. Prószkowska 76, 45-758 Opole, E-mail: a.cichon@po.edu.pl; prof. dr hab. inż. Jerzy Skubis, Politechnika Opolska, Katedra Elektroenergetyki i Energii Odnawialnej, ul. Prószkowska 76, 45-758 Opole, E-mail: j.skubis@po.edu.pl.

LITERATURA

- [1] Working Group A2.37, "Transformer reliability survey, *CIGRÉ*, Tech. Rep. 642 (2015)
- [2] Jafari M. R., Parniani, M., Ravanji M. H., Decentralized Control of OLTC and PV Inverters for Voltage Regulation in Radial Distribution Networks With High PV Penetration. *IEEE Transactions on Power Delivery*, 37(2022), vol 6, 4827–4837
- [3] Shen D., Kraemer A., Dohnal D., Vacuum Switching Technology Improves the Switching Capacity of On-Load Tap-Changers in HVDC Applications, *International Conference on Power System Technology* (2006), 1-6
- [4] Dabaghi-Zarandi F., Behjat V., Gauvin M., Picher P., Ezzaidi H., Fofana I., Power Transformers OLTC Condition Monitoring Based on Feature Extraction from Vibro-Acoustic Signals: Main Peaks and Euclidean Distance, *Sensors* 23(2023); nr. 23:7020
- [5] Baran, P., Varetsky Y., Kidyba V., Pryshliak, Y., Sabadash, I., A DRM Technique for OLTC Testing by the Transformer Secondary Winding DC Voltage Curve, *Przegląd Elektrotechniczny* 98 (2022), nr 17, 178-181
- [6] Abdollah M., Razi-Kazemi A. A., Intelligent Failure Diagnosis for Gas Circuit Breakers Based on Dynamic Resistance Measurements. *IEEE Transactions on Instrumentation and Measurement*, 68(2019), vol 9, 3066–3077
- [7] Osmanbasic E., Skelo g., Tap Changer Condition Assessment Using Dynamic Resistance Measurement, *Procedia Engineering* (2017), vol 202 52-64
- [8] Raja Pagalavan B., Gayathri Monicka J., Somakumar R., Fault Diagnosis of On-Load Tap-Changer Using Acoustic Emission Techniques, *Int. J. Sci. Technol* (2019), vol 8 issue 12, 3467-3469
- [9] Wotzka D., Cichoń A., Study on the Influence of Measuring AE Sensor Type on the Effectiveness of OLTC Defect Classification. *Sensors* 20 (2020), 3095
- [10] Cichoń A., Nowa metoda diagnostyki stanu technicznego podobciążeniowych przełączników zaczepów, *Oficyna Wydawnicza Politechniki Opolskiej* (2011)