

Metody klasyfikacji obrazów fazowo-rozdzielczych wnz z wykorzystaniem hybrydowych sieci neuronowych

Streszczenie. W artykule autorzy dokonali klasyfikacji czterech typowych defektów generujących wyladowania niezupełne w izolacji rozdzielnic średnich napięć SN za pomocą głębokich sieci neuronowych na podstawie obrazów fazowo-rozdzielczych wyladowań. Zbadano i omówiono efektywność różnych hybrydowo połączonych sieci neuronowych: GoogleNet i SqueezeNet uczonych na skalogramach, SAE z FNN, 2D-CNN z LSTM oraz AE połączone z CNN i LSTM. Najwyższą dokładność klasyfikacji typu wnz uzyskano dla sieci CNN w połączeniu z LSTM.

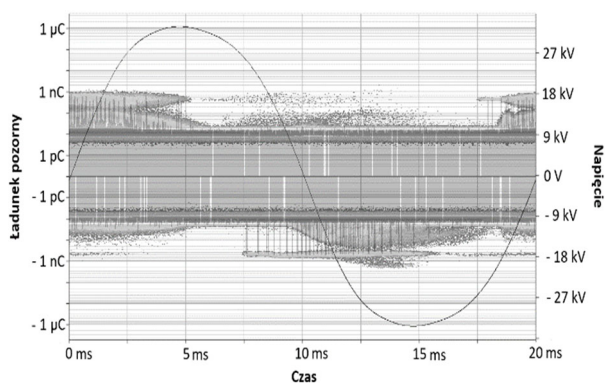
Abstract. In the article, the authors classified four typical defects generating partial discharges in the insulation of medium voltage switchgear using deep neural networks based on phase-resolved images of discharges. The effectiveness of various hybrid connected neural networks was examined and discussed: GoogleNet and SqueezeNet trained on scalograms, SAE with FNN, 2D-CNN with LSTM, and AE combined with CNN and LSTM. The highest PD type classification accuracy was achieved for CNN combined with LSTM. (**Methods for classifying PD phase-resolved images using hybrid neural networks**)

Słowa kluczowe: głębokie sieci neuronowe, diagnostyka izolacji, wyladowania niezupełne, rozdzielnice SN

Keywords: deep neural networks, insulation diagnostics, partial discharges, MV switchgear

Wstęp

Wczesna detekcja wyladowań niezupełnych (wnz) i właściwa ocena zagrożenia dla izolacji wynikającego z ich obecności w rozdzielnicach średniego napięcia (SN) jest kluczowym elementem ich długotrwałego użytkowania. Nowoczesne metody pomiarów cyfrowych pozwalają na dokładną analizę zmierzonych wartości ładunku [1, 2]. Poprawna interpretacja otrzymanych wyników wymaga długoletniego doświadczenia w zakresie pomiarów i analizowania rozkładów wnz. Automatyzacja procesu klasyfikacji typu defektu może pomóc użytkownikowi systemów pomiarowych w interpretacji wyników pomiarowych wnz. Nowoczesne systemy pomiarowe pozwalają na rejestrację i analizę obrazów fazowo-rozdzielczych (PRPD). Przykładowy obraz pokazano na rysunku 1.



Rys.1. Przykładowy histogram PRPD zarejestrowany dla wyladowań ślizgowych w ciągu 60 sekund

Skuteczną metodą służącą do oceny wyników pomiarów jest technika 3PAR, która umożliwia separację obrazów PRPD od różnych defektów i zakłóceń, a także pozwala ustalić przybliżoną lokalizację miejsca wnz [3].

W artykule zbadano różne techniki klasyfikacji czterech typowych rodzajów defektów w izolacji, wykorzystując do tego głębokie sieci neuronowe. Obliczenia wykonano w dwóch etapach. W pierwszym postanowiono zbadać dokładność sieci GoogleNet i SqueezeNet w klasyfikacji rodzajów wnz na podstawie [4-6]. Sprawdzone skuteczność

wspomnianych sieci, tworząc skalogramy przed procesem uczenia. Wykorzystano także hybrydowe kombinacje sieci, takie jak Stacked Autoencoder (SAE) z siecią neuronową typu Feedforward (FNN), konwolucyjną sieć neuronową (CNN) w połączeniu z Autoencoder (AE) oraz rekurencyjną sieć pamięci krótkotrwałej (LSTM) [7–10]. W drugim etapie do klasyfikacji użyto prostej sieci CNN z LSTM.


W pierwszej części artykułu opisano obiekt badany, dwie metody pomiarowe i przedstawiono sposób symulacji defektów rozdzielnic średniego napięcia o izolacji powietrznej. W dalszej części krótko scharakteryzowano rodzaje użytych hybrydowych głębokich sieci neuronowych do klasyfikacji defektów. Opisano hybrydowe kombinacje CNN, LSTM, SAE, AE oraz GoogleNet i SqueezeNet, a także przedstawiono wyniki klasyfikacji. Na zakończenie podsumowano wyniki badań i wskazano plan dalszych badań.

Klasyfikacja przy użyciu głębokich sieci neuronowych

GoogleNet to model konwolucyjnej sieci neuronowej opracowany w 2014 roku. Składa się z 22 warstw sieci neuronowej, w tym warstw spłotowych, warstw redukcji wymiarów, warstw normalizacji wsadowej, warstw aktywacji ReLU i warstw wyjściowych softmax. Cechą wyróżniającą architekturę GoogleNet jest zastosowanie tzw. „modułu Inception”, który umożliwia wykrywanie obiektów o różnych rozmiarach i orientacjach w jednej warstwie sieci [10].

SqueezeNet to model głębokiej sieci neuronowej charakteryzujący się mniejszym rozmiarem niż modele tradycyjne. Główną jej cechą jest użycie warstw spłotowych 1x1 zamiast tradycyjnych 3x3 lub 5x5. Warstwy te wykorzystują mniej parametrów, co prowadzi do mniejszego rozmiaru modelu, a jednocześnie zapewniają podobną wydajność klasyfikacji. SqueezeNet zawiera także tak zwane „moduły ogniowe”, czyli bloki łączące warstwy spłotu 1x1 i 3x3 lub 5x5 [11].


Najpierw dla każdego sygnału utworzono skalogram z następującymi parametrami: Filtr: CWT; Rozmiar obrazu: 224 × 224 × 3; Falka: analityczny Morse (3, 60). Następnie zostały one wykorzystane w procesie uczenia maszynowego przez wymienione wyżej sieci neuronowe.



Rys.2. Przykładowe wygenerowane skalogramy dla klasy 2 i 3

Do uczenia głębokich sieci neuronowych wykorzystano model hybrydowy Stacked Autoenkoder, składający się z dwóch ukrytych warstw, po 100 i 50 neuronów każda. Warstwy szkolono w sposób bez nadzoru w celu wyodrębnienia cech z danych uczących. Testy przeprowadzono w programie MatLab – w aplikacji Deep Learning Toolbox. Parametry sieci: epoki: 100; regularyzacja L2: 0,001; rzadkość regularyzacji: 4; Proporcja rzadkości: 0,1. Sieć FNN uczone przy użyciu algorytmu optymalizacji Adam z następującymi parametrami: szybkość uczenia: 0,001; epoki: 100; wielkość partii: 32.

Do hybrydowej kombinacji CNN i LSTM wykorzystano biblioteki Keras [12] i Tensorflow [13]. Uczenie sieci przeprowadzono na karcie graficznej RTX 3070, wykorzystując głównie warstwy Conv2D z 64 filtrami, BatchNormalization, aktywacją Re-Lu, drop-out, a także warstwę rekursyjną LSTM z 200 jednostkami i opcją powrotu sekwencji. Model sieci został skompilowany przy użyciu optymalizatora Adam przyjmującego następujące parametry: szybkość uczenia: 0,001; Epoki: 50; wielkość partii: 32. Na rysunku 3 zaprezentowano topologię użytej sieci.



Rys.3. Przykładowa topologia użytej sieci 2D CNN + LSTM

Ostatnią badaną kombinacją hybrydową, również wykorzystującą biblioteki Keras i Tensorflow, było połączenie sieci SA, CNN i LSTM. Tym razem wykorzystano Autoenkoder z warstwą ukrytą o rozmiarze 1984. Parametry uczenia: epoki: 150; wielkość partii: 32; podział walidacji: 0,2. Utworzony model sieci CNN i LSTM składał się z warstw Conv1D z 64 filtrami, normalizacją wsadową, MaxPooling i LSTM (odpowiednio 256 i 128) oraz warstwą Drop-out. Wykorzystano optymalizator Adam o parametrach: szybkość uczenia: 0,0005; Epoki: 1200 wielkość partii: 32.

Dane pomiarowe dla pierwszego etapu badań


Skuteczne wykorzystanie głębokich sieci neuronowych wymaga odpowiedniej liczby danych pomiarowych. Ze względu na prostą konstrukcję i łatwość pomiarów w polu autorzy zdecydowali się użyć czujnika pojemnościowego elektromagnetycznego Transient Earth Voltage (TEV) oraz oscyloskopu Tektronix MSO56B do rejestracji sygnałów wnz. Czujnik umieszczono na metalowej obudowie badanej rozdzielnic. Napięcie probiercze doprowadzono do szyny

wysokonapięciowej. Układ pomiarowy przedstawiono na rysunku 4.

Dla pierwszego etapu badań, autorzy postanowili dokonać klasyfikacji sygnałów rejestrowanych dla połowy okresu napięcia probierczego (biegunowości dodatniej i ujemnej). Zarejestrowano łącznie 2000 sygnałów. Jeden sygnał (jedna dana pomiarowa) zawierał 62500 próbek. Dla poprawy efektywności obliczeń, podczas badań zastosowano filtr górno-przepustowy 100 Hz. Przykładowe dane dla wyładowań ślizgowych zaprezentowano na rysunku 5.



Rys.4. Układ pomiarowy podczas pierwszego etapu badań



Rys.5. Uchwycona zależność wnz od fazy doprowadzonego napięcia przy wyładowaniach ślizgowych

Każdy typ defektu (klasę) w rozdzielnic SN zasymulowano w inny sposób, np. poprzez dodanie miedzianego ostrza na szynę wysokiego napięcia, jak na rysunku 6 (klasa 1), od strony uziemionej obudowy (klasa 2) czy poprzez wywołanie w układzie wyładowań ślizgowych (klasa 3). Dla klasy 4 zasymulowano kilka potencjalnych defektów jednocześnie, a dla klasy ostatniej nie ingerowano w działanie badanej rozdzielnic. Liczba zarejestrowanych przebiegów dla każdej klasy każdego typu przedstawiono w tabeli 1.



Rys.6. Symulacja pierwszego defektu – typ 1

Tabela 1. Zastosowane klasy podczas pierwszego etapu klasyfikacji

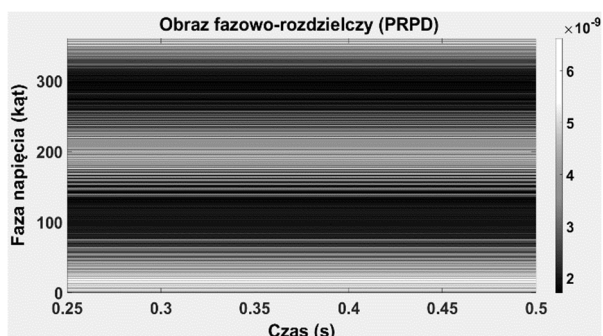
Typ defektu	Opis	Liczba danych
1	Ułot ostrza na szynie WN	360
2	Ułot od ostrza na uziemionej obudowie potencjału ujemnego	480
3	Wyładowania ślizgowe	420
4	Obecność dwóch typów defektów (np. 1 i 3)	600
5	Brak defektu	140

Dane pomiarowe dla drugiego etapu badań

Podczas drugiego etapu również skorzystano z czujnika TEV. Wykorzystano przyrząd pomiarowy firmy Omicron MPD600 wraz z oprogramowaniem rejestrującym obrazy PRPD. Zarejestrowano 65-75 sekundowe obrazy fazowo-rozdzielcze dla każdego typu defektu, a następnie podzielono je na mniejsze - 0,25 sekundowe histogramy dla każdego defektu izolacji. Zarejestrowano łącznie 1371 histogramów – liczbę danych pomiarowych dla każdej klasy przedstawiono w tabeli 2.

Tabela 2. Zastosowane klasy podczas badań drugiego etapu

Typ defektu	Opis	Liczba danych
1	Ułot ostrza na szynie WN	279
2	Ułot od ostrza na uziemionej obudowie potencjału ujemnego	254
3	Ułot od ostrza na szynie na swobodnym potencjale	259
4	Wyładowania ślizgowe	301
5	Brak defektu	276



Rys.7. Przykładowy histogram PDPD podczas 0,25 sekund dla wyładowania ślizgowego

Pomiary wnz zrealizowano za pomocą urządzenia MPD600 firmy OMICRON. Przykładowy histogram pokazano na rysunku 7. Dane zostały zebrane, a następnie przekazane do uczenia maszynowego w programie MatLab. Do klasyfikacji PRPD wykorzystano połączenie sieci konwolucyjnej CNN z siecią LSTM. Kolejne warstwy sieci przedstawiono w tabeli 3.

Tabela 3. Warstwy hybrydowej sieci CNN LSTM

Lp.	Nazwa warstwy
1	Wejściowa
2	Konwolucyjna (16 filtrów)
3	Normalizacji wsadowej
4	Aktywacji ReLU
5	Splaszczająca
6	LSTM 1 (100 jedn.)
7	LSTM 2 (50 jedn.)
8	W pełni połączona
9	Softmax
10	Klasyfikacji (wyjściowa)

Wyniki

Dokładność klasyfikacji typu wyładowania definiuje się jako stosunek prawidłowo sklasyfikowanych próbek do wszystkich próbek w zbiorze testowym i określa w %. Dokładność klasyfikacji ocenia ogólną efektywność modelu klasyfikatora. Im wyższa jej wartość tym skuteczniej model identyfikuje dany typ wyładowania. Dokładności klasyfikacji wszystkich zastosowanych w badaniach sieci zaprezentowano w tabeli 4. Szczegółowe wyniki klasyfikacji dla każdej z klas podczas pierwszego etapu zaprezentowano w tabeli 5, a dla drugiego etapu, na macierzy pomyłek, na rysunku 8.

Tabela 4. Dokładność klasyfikacji

Metoda	Sieć neuronowa	Dokładność
1	GoogleNet	97,3%
1	SqueezeNet	98,4%
1	SAE + FNN	81,1%
1	CNN + LSTM	83,9%
1	AE + CNN + LSM	81,2%
2	CNN + LSTM	99,8%

Tabela 5. Wyniki klasyfikacji dla każdej klasy (typu defektu) w pierwszym etapie badań

Sieć neuronowa	Kl.	Recall	Precision	F1-Score
GoogleNet	1	90,4%	93,9%	92,0%
	2	97,2%	96,4%	98,9%
	3	97,2%	98,8%	98,0%
	4	93,6%	94,5%	95,3%
	5	100%	100%	100%
SqueezeNet	1	94,6%	97,7%	96,1%
	2	99,8%	98,4%	99,5%
	3	98,5%	99,9%	99,0%
	4	99,9%	99,5%	98,2%
	5	100%	100%	100%
SAE + FNN	1	54,7%	48,1%	56,1%
	2	52,0%	49,8%	55,7%
	3	83,8%	83,7%	84,1%
	4	79,1%	83,2%	85,2%
	5	100%	100%	100%
CNN + LSTM	1	68,1%	73,4%	70,7%
	2	83,3%	79,4%	81,4%
	3	55,1%	94,1%	69,6%
	4	97,4%	74,1%	84,2%
	5	100%	100%	100%
AE + CNN + LSM	1	52,7%	56,7%	54,3%
	2	67,4%	65,3%	66,3%
	3	81,3%	90,3%	85,5%
	4	89,5%	89,5%	85,7%
	5	100%	100%	100%

Połączenie sieci SAE+FNN, CNN+LSTM i AE+CNN+LSTM pozwoliło osiągnąć dokładność na poziomie około 82%. Najwyższy wynik pojedynczej klasy osiągnięto dla klasy 5 (brak defektu) równy 100% dla każdej badanej sieci neuronowej pierwszej metody. Należy nadmienić, że najniższy wynik osiągnięto przy wykorzystaniu programów napisanych w środowisku Python dla klas 1 i 2. Ich uczenie trwało kilkadziesiąt minut dla każdej sieci.

Najwyższy wynik dla metody pierwszej uzyskano dla sieci SqueezeNet i GoogleNet – 98,39% i 97,31%. Niestety, tworzenie skalogramów na podstawie przekazanych danych, a także uczenie trwało kilka godzin. Najwyższy wynik podczas wszystkich badań uzyskano dla sieci CNN i LSTM.

Macierz pomyłek

1	279				
2		254			
3			259		1
4				301	
5			1		276
	1	2	3	4	5

Przewidywana klasa

Rys.8. Wynik macierzy pomyłek dla drugiego etapu badań

Wnioski

Uzyskane wyniki potwierdziły słuszność użycia głębokich sieci neuronowych w celu klasyfikacji typu defektów generujących wnz. Najwyższą dokładność podczas pierwszego etapu badań osiągnięto dla klasyfikacji skalogramów przy użyciu sieci neuronowych GoogleNet i SqueezeNet. Niemal równie wysoki wynik uzyskano w przypadku wykorzystania obrazów PRPD zarejestrowanych urządzeniem MPD600 podczas drugiego etapu. Dokładne przygotowanie danych pomiarowych, zależność ilości impulsów od fazy napięcia probierczego, a także niski poziom tła wpłynęły znacząco na pozytywne rezultaty klasyfikacji. Zastosowanie Autoenkodera nie poprawiło znacząco wyników klasyfikacji podczas pierwszego etapu badań. Wysoki wynik klasyfikacji dla klasy 5 (brak defektu) oznacza, że zastosowane sieci dobrze radzą sobie z identyfikacją samego zjawiska wnz oraz jego braku, natomiast odpowiednie sklasyfikowanie typu wnz jest zadaniem bardziej wymagającym.

Autorzy planują dalsze badania nad automatyzacją klasyfikacji rodzajów wnz z zastosowaniem różnych głębokich sieci neuronowych podczas pomiarów metodami elektrycznymi konwencjonalnymi i niekonwencjonalnymi. Badania, gdzie poziom zewnętrznych zakłóceń może być wysoki, np. na polach transformatorowych czy w stacjach elektroenergetycznych, w trakcie ich pracy, mogą znacząco rozszerzyć bazę danych, potrzebną do głębokiego uczenia maszynowego. Rozważane są próby na innych obiektach

elektroenergetycznych (np. osprzęt kablowy) przy użyciu wielu czujników pojemnościowych i indukcyjnych (np. przekładnik prądowy wysokich częstotliwości - HFCT).

Autorzy planują także sprawdzić możliwość stworzenia uniwersalnej głębokiej sieci neuronowej do klasyfikacji wieloetykietowej kilku typów defektów występujących jednocześnie.

Autorzy: mgr inż. Paweł Kluge, Politechnika Warszawska, Instytut Elektrotechniki Teoretycznej i Systemów Informacyjno-Pomiarowych, ul. Koszykowa 75, 00-662 Warszawa, E-mail: pawel.kluge@pw.edu.pl; dr inż. Andrzej Łasica, Politechnika Warszawska, Instytut Elektrotechniki Teoretycznej i Systemów Informacyjno-Pomiarowych, ul. Koszykowa 75, 00-662 Warszawa, E-mail: andrzej.lasica@pw.edu.pl; prof. dr hab. inż. Jacek Starzyński, Politechnika Warszawska, Instytut Elektrotechniki Teoretycznej i Systemów Informacyjno-Pomiarowych, ul. Koszykowa 75, 00-662 Warszawa, E-mail: jacek.starzynski@pw.edu.pl; dr hab. inż. Wojciech Kołtunowicz, OMICRON Energy, Solutions GmbH, Lorenzweg 5, 12099 Berlin, Niemcy, E-mail: wojciech.koltunowicz@omicronenergy.com

LITERATURA

- [1] Pattanadech N., Haller R., Kornhuber S., Muhr M., *Partial Discharges (PD): Detection, Identification, and Localization*, Wiley, 2023
- [2] *CIGRE Technical Brochure 662*, Guidelines for partial discharge detection using conventional (IEC 60270) and unconventional methods, 2016, www.e-cigre.org
- [3] Bednarczyk T., Kołtunowicz W., Krueger M., Ranninger U., Pomiar i lokalizacja wylądowań niepełnych w izolacji transformatorów energetycznych. *Przegląd Elektrotechniczny*, 98 (2022), nr 10
- [4] Uckol H.I., İlhan S., Özdemir A. Workmanship Defect Classification in Medium Voltage Cable Terminations with Convolutional Neural Network. *Electric Power Systems Research* (2021), 194
- [5] Classify Time Series Using Wavelet Analysis and Deep Learning - MATLAB & Simulink Example: <https://www.mathworks.com/help/deeplearning/ug/classify-time-series-using-wavelet-analysis-and-deep-learning.html>
- [6] Thi N.D.T., Do T.D., Jung J.R., Jo H., Kim Y.H., Anomaly Detection for Partial Discharge in Gas-Insulated Switchgears Using Autoencoder. *IEEE Access* 2020, 8, 152248–152257
- [7] Alsumaidae Y.A.M., Yaw C.T., Koh S.P., Tiong S.K., Chen C.P., Ali K., Review of Medium-Voltage Switchgear Fault Detection in a Condition-Based Monitoring System by Using Deep Learning, *Energies (Basel)* 2022, 15 (18), 6762
- [8] Li Z., Qu N., Li X., Zuo J., Yin Y., Partial Discharge Detection of Insulated Conductors Based on CNN-LSTM of Attention Mechanisms. *Journal of Power Electronics* 2021, 21, 1030–1040
- [9] Li G., Wang X., Li X., Yang A., Rong, M., Partial Discharge Recognition with a Multi-Resolution Convolutional Neural Network. *Sensors (Switzerland)* 2018, 18 (10), 3512
- [10] Iandola F.N., Han S., Moskewicz M.W., Ashraf K., Dally W.J., Keutzer K., SqueezeNet: AlexNet-Level Accuracy with 50x Fewer Parameters and <0.5MB Model Size. 2016, <https://arxiv.org/abs/1602.07360>
- [11] Szegedy C., Liu W., Jia Y., Sermanet P., Reed S., Anguelov D.; Erhan D., Vanhoucke V., Rabinovich A., Going Deeper with Convolutions. In Proceedings of the Proceedings of the IEEE Computer Society Conference on Computer Vision and Pattern Recognition. *IEEE Computer Society*, 2015, Vol. 07-12-June-2015, 1–9.
- [12] Keras: Deep Learning for Humans: <https://keras.io/>
- [13] TensorFlow: <https://www.tensorflow.org/>