

Daria WOTZKA*, Andrzej CICHON*, Piotr MANOWSKI**

ZASTOSOWANIE UCZENIA NADZOROWANEGO DO KLASYFIKACJI DEFEKTÓW PPZ NA PODSTAWIE SYGNAŁÓW EA

Tematyka artykułu dotyczy rozpoznawania defektów podobciążeniowych przełączników zaczepów (PPZ) z wykorzystaniem uczenia nadzorowanego. PPZ to specjalistyczne urządzenie będące częścią transformatora elektroenergetycznego, które pozwala na skokową zmianę przekładni a tym samym napięcia na zaciskach tego transformatora. Jako metodę diagnostyczną zastosowano metodę emisji akustycznej (EA), której zaletą jest możliwość stosowania podczas normalnej pracy transformatora bez konieczności jego wyłączenia. Sygnały EA pozyskane z badań laboratoryjnych, w których symulowano cztery rodzaje defektów - typowych uszkodzeń PPZ, poddano wstępnej analizie z wykorzystaniem filtrów cyfrowych i transformaty Hilberta, a następnie poddano procesowi klasyfikacji. W artykule zawarto przykładowe przebiegi czasowe sygnałów EA oraz wyniki wstępnych badań dotyczących klasyfikacji defektów PPZ z wykorzystaniem siedmiu metod wraz z oceną ich skuteczności.

KEYWORDS: analiza sygnałów EA, podobciążeniowe przełączniki zaczepów, PPZ, klasyfikacja uszkodzeń PPZ, uczenie nadzorowane.

1. WPROWADZENIE

Zapewnienie ciągłości i niezawodności dostaw energii elektrycznej do konsumentów ma niezaprzeczalnie istotną wagę. W tym celu od wielu lat doskonałone są metody pozwalające na diagnozę stanu technicznego poszczególnych elementów systemu energetycznego. Jednym z elementów tego systemu są transformatory elektroenergetyczne i podobciążeniowe przełączniki zaczepów (PPZ), które pozwalają na regulację napięcia pod obciążeniem, poprzez skokową zmianę przekładni transformatora, dzięki czemu równoważone są zmiany napięć w sieci energetycznej, spowodowane zróżnicowanym zapotrzebowaniem na moc w ciągu doby. Istnieje szereg metod umożliwiających diagnozowanie stanu technicznego PPZ, jedną z nich jest nieinwazyjna metoda emisji akustycznej (EA) [1, 2]. Tematyka dotycząca diagnostyki PPZ z wykorzystaniem metody EA

* Politechnika Opolska

** PROMAN Sp. z o.o.

jest obecnie rozpatrywana w szeregu pracach. Przykładowo w [3, 4] przedstawiono wyniki pomiarów sygnałów EA emitowanych przez PPZ pracujący w warunkach laboratoryjnych do oceny ich stanu technicznego. W szczególności stopień zatarzenia określano na podstawie zarejestrowanych sygnałów EA. W pracy [5] przedstawiono zestawienie porównawcze wyników analiz sygnałów EA zarejestrowanych przetwornikami pomiarowymi o różnych parametrach. W artykule [7] przedstawiono wyniki analiz sygnałów EA w dziedzinie czasu i częstotliwości zarejestrowanych na obudowie trójfazowego PPZ typu GIII. Do analiz zastosowano transformaty falkowe i krótkoczasową transformatę Fouriera. W artykule [8] zastosowano dyskretną transformatę falkową do określenia energii składowych częstotliwościowych zawartych w rejestrowanych sygnałach EA emitowanych przez prawidłowo działający PPZ. W artykule [9] przedstawiono metodę klasyfikacji uszkodzeń PPZ z wykorzystaniem neuronowej sieci Kohonena, którą zastosowano do identyfikacji czterech stopni zużycia styków. Spotyka się również inne metody rozpoznawania uszkodzeń PPZ. Przykładowo w artykule [10] do klasyfikacji stopnia uszkodzenia PPZ na podstawie wyników analizy DGA zastosowano regresję logistyczną i sztuczne sieci neuronowe. Natomiast metody klasyfikacji wykorzystujące uczenie maszynowe bazujące na różnego rodzaju deskryptorach charakteryzujących sygnały EA stosowano m.in. w pracach: [11-17].

Nadrzędnym celem prowadzonych badań jest opracowanie zautomatyzowanego klasyfikatora w zastosowaniu do detekcji uszkodzeń PPZ na podstawie sygnałów EA. W niniejszym artykule zawarto wyniki wstępnych prac zmierzających do wyboru jednego lub kilku metod klasyfikujących zamodelowane uszkodzenia w sposób optymalny, tj. relatywnie szybko i skutecznie.


2. METODOLOGIA BADAŃ

Do realizacji zadania klasyfikacji wykorzystano zestaw danych pomiarowych, składający się z 29 próbek dla każdego z typów uszkodzenia PPZ.


Rejestrację sygnałów EA przeprowadzono w warunkach laboratoryjnych z wykorzystaniem modelu PPZ. Badany model PPZ umieszczono w kadzi wypełnionej olejem izolacyjnym. Dodatkowo układ wyposażono w napęd umożliwiający automatyczne przełączanie poszczególnych zaczepów. Zamodelowano cztery klasy defektów PPZ. Pierwsze trzy klasy D1, D2, D3 dotyczą zużycia styków głównych przełącznika mocy. Defekty te zamodelowano poprzez zmianę grubości styków głównych. Regulację grubości wykonywano za pomocą podkładek dopasowanych do kształtu styków w zakresie 1-3 mm. Dodatkowo zamodelowano niejednoczesność działania przełącznika mocy poprzez zmianę grubości styków w poszczególnych fazach, co odpowiada defektowi klasy D4. Klasa BD oznacza prawidłowe działanie urządzenia. Sygnały EA zarejestrowane

zostały z wykorzystaniem szerokopasmowego przetwornika pomiarowego. Szczegółowy opis elementów układu pomiarowego, procedury wykonywania pomiarów oraz charakterystyka uszkodzeń PPZ przedstawiono w pracy [6].

Na rys. 1 i 2 przedstawiono wykorzystane w badaniach przykładowe przebiegi czasowe sygnałów EA zarejestrowanych podczas prawidłowej pracy PPZ (klasa BD) oraz serię pomiarową dla PPZ z zamodelowanym uszkodzeniem klasy D3.



Rys. 1. Przebiegi czasowe sygnałów EA zarejestrowane dla PPZ bez defektu (BD)



Rys. 2. Przebiegi czasowe sygnałów EA zarejestrowane dla PPZ z uszkodzeniem klasy D3


Wstępnie sygnały EA przetworzono z wykorzystaniem filtra dolnoprzepustowego oraz transformaty Hilberta. W rezultacie klasyfikacji poddano sygnał stanowiący górną obwiednię przefiltrowanego sygnału. Do wstępnego przetworzenia danych pomiarowych zastosowano dostępne w środowisku MATLAB funkcje: `resample(dane, 1, 5)` i `envelop`. Tak zdefiniowane sygnały EA emitowane przez PPZ poddano wstępnym badaniom z wykorzystaniem narzędzia '*ClassificationLearner*', dostępnego w środowisku MATLAB, które pozwala na relatywnie wygodną i szybką zautomatyzowaną analizę szeregiem klasyfikatorów. Do dalszej klasyfikacji sygnałów, wybrano metody, które charakteryzowały się najwyższą wartością miary trafności klasyfikacji. W szczególności zastosowano następujące metody: liniowa analiza dyskryminacyjna –

`fitcdiscr(..., 'DiscrimType', 'linear', 'Gamma', 0, 'FillCoeffs', 'off')` (algorytm nr 1), zespół losowych klasyfikatorów analizy dyskryminacyjnej - `fitcensemble(..., 'Method', 'Subspace', 'NumLearningCycles', 30, 'Learners', 'discriminant', 'NPredToSample', max(1, min(7156, width(predictors) - 1)))` (algorytm nr 3) i k-najbliższych sąsiadów - `fitcensemble(..., 'Method', 'Subspace', 'NumLearningCycles', 30, 'Learners', 'knn', 'NPredToSample', max(1, min(7156, width(predictors) - 1)))` (algorytm nr 2), metoda wektorów wspierających z wielomianem rzędu drugiego (algorytm nr 5), trzeciego (algorytm nr 4) - `fitcecoc(...'KernelFunction', 'polynomial',...)` i nieliniowy typu Gaussa - `fitcecoc(...'KernelFunction', gaussian,...)` (algorytm nr 6) oraz metoda k-najbliższych sąsiadów - `fitcknn(..., 'Distance', 'Euclidean', 'Exponent', [], 'NumNeighbors', 1, 'DistanceWeight', 'Equal', 'Standardize', true)` (algorytm nr 7).

Jako kryterium oceny analizowanych metod zastosowano miarę trafności klasyfikacji, macierz pomyłek oraz czas obliczeń. Ponadto metody przebadano dla trzech różnych liczb obserwacji: 10, 19 i 29, przy czym każdorazowo do obliczenia miary trafności i macierzy pomyłek stosowano szacowanie techniką 10-krotnej oceny krzyżowej. Każda z obserwacji składała się z 14311 predyktorów, co wynika bezpośrednio z liczby próbek w przebiegu czasowym przetworzonym jak opisano powyżej. Predyktorami są kolejne próbki pomiarowe przebiegu czasowego sygnału EA.


3. WYNIKI I WNIOSKI Z PRZEPROWADZONYCH BADAŃ

Na rys. 3 zaprezentowano przykładową zależność między wybranymi predyktorami, t. j. próbkami sygnału EA zarejestrowanymi w czasie, zastosowanymi w procesie klasyfikacji dla pięciu rozpatrywanych klas uszkodzeń PPZ. Każdy z kolorów określa inną klasę uszkodzenia PPZ: DB, D1, D2, D3, D4.



Rys. 3. Zależność między dwoma wybranymi predyktorami z uwzględnieniem czterech klas uszkodzeń PPZ


Na rys. 4 przedstawiono zestawienie porównawcze wartości miary trafności klasyfikacji, obliczonej dla trzech zestawów liczb obserwacji: 10, 19 i 29, uzyskane dla poszczególnych metod klasyfikacji. Na podstawie analizy tej miary stwierdzono, że wszystkie modele charakteryzują się wysokimi poziomami wskazań właściwej klasy uszkodzenia na podstawie przetworzonego przebiegu czasowego sygnału EA. Poziomy te w prawie wszystkich przypadkach przekraczają 80%, a jedynie dla liczby obserwacji równej 10 w algorytmie nr 7 trafność wynosi 74%. Liczba obserwacji poprawia jakości klasyfikacji średnio o 7,41% przy jej zwiększeniu z 10 do 19 i o dalsze 3,03% dla 29 obserwacji. Najwyższy poziom trafności uzyskano dla liczby obserwacji równej 29, dla algorytmów nr 1 i nr 2, dla których wynosił on 95%. Natomiast algorytmy nr 3 i nr 4 uzyskały poziom trafności równy 94%.



Rys. 4. Trafność klasyfikowania dla poszczególnych metod klasyfikacji

Na rys. 5 zestawiono czas trwania obliczeń dla poszczególnych klasyfikatorów.

Algorytmy nr 1, nr 2 i nr 3 osiągają najlepszy poziom trafności jednak są bardziej czasochłonne. W większości przypadków zwiększenie liczby obserwacji powoduje również zwiększenie czasu u trwania obliczeń. Czas ten wynosi maksymalnie 42 s, jednak należy uwzględnić fakt, że obliczenia wykonywano na komputerze o dużej mocy obliczeniowej (i7-7700K 4,2 GHz, 32 GB RAM) przy wykorzystaniu obliczeń równoległych.



Rys. 5. Czas obliczeń dla poszczególnych klasyfikatorów

Kolejną zastosowaną metodą analizy rozpatrywanych algorytmów klasyfikacji było określenie macierzy pomyłek. W tablicach 1-7 zestawiono wartości dla liczby obserwacji równej 29. Wiersze macierzy odpowiadają poprawnym klasom decyzyjnym, natomiast kolumny decyzjom predykowanym przez klasyfikator. Na przecięciu wiersza n i kolumny m - zawarta jest liczba obserwacji należąca oryginalnie do klasy n -tej, a zaklasyfikowana do klasy m -tej. W tabelach dla każdej z klas zawarto liczbę klasyfikacji niewłaściwej klasy (FN) i błędnych klasyfikacji właściwej klasy (FP).

Tabela 1. Macierz pomyłek dla algorytmu nr 1.

		Klasy predykowane					FN
		BD	D1	D2	D3	D4	
Klasy właściwe	BD	28	0	0	1	0	1
	D1	0	27	1	1	0	2
	D2	0	1	27	1	0	2
	D3	0	0	1	28	0	1
	D4	1	0	0	0	28	1
FP		1	1	2	3	0	–

Tabela 2. Macierz pomyłek dla algorytmu nr 2.

		Klasy predykowane					FN
		BD	D1	D2	D3	D4	
Klasy właściwe	BD	28	0	0	1	0	1
	D1	0	27	1	1	0	2
	D2	0	1	27	1	0	2
	D3	0	0	1	28	0	1
	D4	1	0	0	0	28	1
FP		1	1	2	3	0	–

Tabela 3. Macierz pomyłek dla algorytmu nr 3.

		Klasy predykowane					FN
		BD	D1	D2	D3	D4	
Klasy właściwe	BD	28	0	0	1	0	1
	D1	0	27	1	1	0	2
	D2	1	1	26	1	0	3
	D3	0	0	1	28	0	1
	D4	1	0	0	0	28	1
FP		2	1	2	3	0	–

Tabela 4. Macierz pomyłek dla algorytmu nr 4.

		Klasy predykowane					FN
		BD	D1	D2	D3	D4	
Klasy właściwe	BD	27	2	0	0	0	2
	D1	1	27	0	1	0	2
	D2	0	1	27	1	0	2
	D3	0	1	0	28	0	1
	D4	1	0	0	0	28	1
FP		2	4	0	2	0	–

Tabela 5. Macierz pomyłek dla algorytmu nr 5.

		Klasy predykowane					FN
		BD	D1	D2	D3	D4	
Klasy właściwe	BD	26	3	0	0	0	3
	D1	1	27	0	1	0	2
	D2	0	0	27	2	0	2
	D3	1	0	0	28	0	1
	D4	1	0	0	0	28	1
FP		3	3	0	3	0	–

Tabela 6. Macierz pomyłek dla algorytmu nr 6.

		Klasy predykowane					FN
		BD	D1	D2	D3	D4	
Klasy właściwe	BD	24	5	0	0	0	5
	D1	1	28	0	0	0	1
	D2	3	0	26	0	0	3
	D3	1	0	0	28	0	1
	D4	1	2	0	0	26	3
FP		6	7	0	0	0	–

Tabela 7. Macierz pomyłek dla algorytmu nr 7.

		Klasy predykowane					FN
		BD	D1	D2	D3	D4	
Klasy właściwe	BD	29	0	0	0	0	0
	D1	7	20	2	0	0	9
	D2	1	0	27	1	0	2
	D3	0	0	2	26	1	3
	D4	0	1	2	0	26	3
FP		8	1	6	1	1	–

Na podstawie macierzy pomyłek można dla każdego z rozpatrywanych algorytmów określić, które klasy uszkodzeń PPZ klasyfikowane były błędnie jako niewłaściwe klasy (FN), które klasy były wskazywane właściwie (wartość na przecięciu wiersza i kolumny) oraz które klasy wskazywane były błędnie jako właściwe (FP). Łącznie dla wszystkich algorytmów klasa D1 była najczęściej błędnie klasyfikowana jako niewłaściwa lub właściwa. Najrzadziej błędnie klasyfikowana jako niewłaściwa była klasa D3, a jako klasa właściwa klasa D4. Najczęściej prawidłowo klasyfikowana była klasa D4 (194 razy), a najrzadziej klasa D1 (183 razy).

4. PODSUMOWANIE

W artykule przedstawiono wyniki prac badawczych zmierzających do określenia optymalnego algorytmu klasyfikacji pięciu klas uszkodzeń PPZ na podstawie wstępnie przetworzonego sygnału EA, zarejestrowanego w warunkach laboratoryjnych. W szczególności przedstawiono wyniki analizy porównawczej poziomu trafności klasyfikacji, czasu obliczeń i macierzy pomyłek dla siedmiu różnych algorytmów nadzorowanego uczenia maszynowego. Na podstawie wykonanych analiz określono, że optymalnymi algorytmami klasyfikacji są algorytmy nr 1 (liniowa analiza dyskryminacyjna) i nr 2 (zespół losowych klasyfikatorów k-najbliższych sąsiadów), które najczęściej, 138 razy, co stanowi 95% przypadków, właściwie przewidywały klasę uszkodzenia. Podczas analiz stwierdzono również, że klasa, która najczęściej była właściwie przewidywana to klasa D3.

LITERATURA

- [1] Erbrink J., Gulski E., Seitz P. P., Leich R., Advanced on-site diagnosis of transformer on-load tap changer, Conference Record of the 2008 IEEE International Symposium on Electrical Insulation, 2008, pp. 252-256.
- [2] Erbrink J. J., Gulski E., Smit J. J., Seitz P. P., Leich R., Experimental model of aging mechanisms of on-load tap changer contacts, International Conference on Condition Monitoring and Diagnosis, Beijing, 2008, pp. 247-250.
- [3] Cichoń A., Borucki S., Boczar T., diagnosis of the non-concurrent operation of the on-load tap changer contacts by the acoustic emission method, Archives of Acoustics, Volume 36, Number 4, ISSN 0137-5075, 2011.
- [4] Cichoń A., Boczar T., Frącz P., Zmarzły D., Detection of defects in on-load tap-changers using acoustic emission method, Conference Record of the 2012 IEEE International Symposium on Electrical Insulation (ISEI), 2012.
- [5] Cichoń A., Borucki S., Diagnostics of technical condition on load tap changers by acoustic emission method using different types of measuring transducers, International Conference on High Voltage Engineering and Application (ICHVE), 2012.
- [6] Cichoń A., Berger P., Borucki S., Analiza porównawcza wyników badań w zakresie oceny stopnia zużycia styków PPZ metodą akustyczną i oscylograficzną, Pomiar Automatyka Kontrola, nr 02, 2013, s. 152-155.
- [7] Majchrzak H., Cichoń A., Borucki S., Application of the acoustic emission method for diagnosis of on-load tap changer, Archives of Acoustics, Volume 42, Number 1, ISSN 2300-262X, 2017.
- [8] Shanker T. B., Nagamani H. N., Punekar G. S., Acoustic emission signal analysis of On-Load Tap Changer (OLTC), IEEE 1st International Conference on Condition Assessment Techniques in Electrical Systems (CATCON), 2013.
- [9] Filho E. F. S., de Almeida F. A. L., Self-organized classification of on-load tap changers acoustic signatures, Conference Proceedings: IEEE Instrumentation and Measurement Technology (IMTC), 2008.

- [10] Wang H., Liu Y., Griffin P., Artificial intelligence in OLTC fault diagnosis using dissolved gas-in-oil information, IEEE Power Engineering Society Summer Meeting, Volume. 4, 2000.
- [11] Ritschel F., Sause M. G. R., Brunner A. J. Niemz P., Acoustic emission (AE) Signal classification from tensile tests on plywood and layered wood, 31st Conference of the European Working Group on Acoustic Emission (EWGAE), 2014.
- [12] Rippengill S., Worden K., Holford K.M., Pullin R., automatic classification of acoustic emission patterns strain, Volume 39, Number 1, 2003.
- [13] Ding P., Li Q., Huang X., Classification of acoustic emission sources produced by carbon/epoxy composite based on support vector machine, IOP Conference Series: Materials Science and Engineering, Global Conference on Polymer and Composite Materials (PCM), Volume 87, 2015.
- [14] Ebenezer S. P., Papandreou-Suppappola A., Suppappola S. B., Classification of acoustic emissions using modified matching pursuit, EURASIP Journal on Advances in Signal Processing, ISSN: 1687-6180, 2004.
- [15] Pomponi E., Vinogradov A., Real-time acoustic emission classification: new evolutionary approach, 30th European Conference on Acoustic Emission Testing & 7th International Conference on Acoustic Emission, 2012.
- [16] Baccar D., Schiffer S., Soffker D., acoustic emission-based identification and classification of frictional wear of metallic surfaces, 7th European Workshop on Structural Health Monitoring (EWSHM), 2014.
- [17] Zhao J., Wang K., Guo Y., Acoustic emission signals classification based on support vector machine, 2nd International Conference on Computer Engineering and Technology (ICCET), 2010.

APPLICATION OF SUPERVISED LEARNING FOR CLASSIFICATION OF OLTC DEFECTS ON THE BASIS OF AE SIGNALS

The subject of the article concerns recognition of defects of on load tap changers (OLTC) with the use of supervised learning. OLTC is a specialized device that is part of a power transformer, which allows for a step change of the gear and thus the voltage at the terminals of this transformer. The acoustic emission (AE) method was applied as diagnostic method. The advantage of this method lies in the possibility of its application during normal operation of the device without having to turn it off. EA signals were obtained from laboratory tests in which four types of defects - typical OLTC damages, were simulated. The gathered signals were pre-analyzed using digital filters and Hilbert transforms, and then subjected to the classification process. The article contains examples of EA signal waveforms and the results of preliminary research on the classification of OLTC defects with the use of seven methods together with an assessment of their effectiveness.

(Received: 04.02.2018, revised: 17.03.2018)