

Stanisław MIKULSKI*

EKSTRAKCYJA WŁAŚCIWOŚCI Z SYGNAŁÓW EA DLA KLASYFIKATORÓW NEURONOWYCH

W poniższym artykule przedstawiono zastosowanie różnych metod analizy sygnału w celu wydobycia danych uczących sieć neuronową, której celem jest detekcja sygnałów emisji akustycznej (EA) towarzyszących zjawisku drzewienia w żywicach epoksydowych. Badane sygnały poddano m. in. analizie statystycznej poprzez wydobycie takich danych jak: kurtoza, skośność czy wariancja. Oprócz metod statystycznych zastosowano także analizę częstotliwościową oraz metody analizy związane ściśle z metodą akustyczną. Przeprowadzona została analiza każdego z branych pod uwagę parametrów pod kątem jego przydatności podczas detekcji danych.

SŁOWA KLUCZOWE: emisja akustyczna , kurtoza, drzewienie elektryczne

1. WPROWADZENIE

Jednym z gwarantów bezpieczeństwa narodowego jest zapewnić powszechnego i nieprzerwanego dostępu obywateli do energii elektrycznej. Rolą Krajowego Systemu Elektroenergetycznego (KSE) jest produkcja, przesył i rozdział energii elektrycznej. Aby wypełniać swoją rolę KSE musi zapewniać:

- produkcję energii pozwalającą na pokrycie aktualnego zapotrzebowania,
- przesył energii elektrycznej do każdego odbiorcy,
- minimalizację przerw w ciągłości dostaw energii.

W Polsce, jak i w innych cywilizowanych krajach, widoczny jest ciągły wzrost zapotrzebowania na energię elektryczną. Tabela 1.1 przedstawia średnie zapotrzebowanie na energię elektryczną w ciągu roku w latach 2000 – 2016. Wzrost zapotrzebowania na energię powoduje, zwiększenie narażenia urządzeń elektroenergetycznych na uszkodzenia, awarię, a w konsekwencji na możliwość wystąpienia dużych przerw w dostawie oraz tzw. blackoutów. Jednym ze sposobów na zmniejszenie awaryjności w sieciach elektroenergetycznych jest ciągle ulepszanie izolacji urządzeń i linii wysokich napięć. Wszystkie powyższe wymogi dotyczące nowoczesnych sieci powodują, że materiały wykorzystywane do izolacji urządzeń elektroenergetycznych powinny charakteryzować się

* Politechnika Poznańska.

coraz lepszymi właściwościami dielektrycznymi, wytrzymałością termiczną i mechaniczną.

Tabela 1.1. Średnie roczne zapotrzebowanie na moc w Polsce w ostatnich 15 latach – opracowane na podstawie danych KSE [7]

Rok	2000	2005	2010	2011	2012	2013	2014	2015	2016
Moc [MW]	15601	16586	17713	17929	18000	18114	18212	18519	18796


Najczęściej źródłem uszkodzeń w izolacjach jest miejscowe, nierównomierne występowanie natężenia pola elektrycznego wewnątrz dielektryka, związane z mikro-uszkodzeniami powstałymi w fazie: produkcji, instalacji lub w czasie użytkowania urządzenia. W wyniku tego w dielektryku następuje wyładowanie niezupełne (WNZ), które doprowadza do formowania wewnątrz izolacji przewodzących kanalików. W miejscu występowania takiego kanału następuje osłabienie właściwości izolacyjnych (miejscowe zwiększenie natężenia pola elektrycznego), które prowadzi do tworzenia kolejnych kanalików formujących razem tzw. drzewo [2]. Proces takiej degradacji najczęściej jest długotrwały i powoduje powolne pogarszanie jakości izolacji w miejscu występowania drzewa, a w skrajnym przypadku do zwarcia i awarii urządzenia [2, 4].

Badania zaprezentowane w pracy skupiają się na pomiarach dla żywicy epoksydowej. Właściwości takie jak duża wytrzymałość mechaniczna, duża odporność na warunki atmosferyczne oraz dobre właściwości elektroizolacyjne, spowodowały, że żywice epoksydowe znalazły duże zastosowanie jako materiał izolujący w elektroenergetyce (m. in. kable, uzwojenia cewek, obudowy urządzeń elektronicznych) [1].

Celem badań jest znalezienie właściwości pozwalających na detekcję sygnałów EA, a zwłaszcza początkowej fazy formowania fali sprężystej. Algorytm takiej detekcji może pozwolić na lepszą diagnostykę urządzeń elektroenergetycznych zawierających izolację stałą.

2. STANOWISKO POMIAROWE


Standardowe stanowisko do pomiaru EA bez względu na rodzaj badanego obiektu zawiera: sensora EA, układ wzmacniacza i aparaturę pomiarową. Sensor EA przykładany jest najczęściej bezpośrednio do badanego obiektu. Jego rolą jest przetwarzanie zarejestrowanych drgań mechanicznych rozchodzących się wewnątrz objętości obiektu na sygnały elektryczne mierzone przez aparaturę pomiarową. Najczęściej sensorami są materiały piezoelektryczne. W badaniach wykorzystano sensor piezoelektryczny PAC R3 α , którego charakterystyka przenoszenia została przedstawiona na rys. 1.



Rys. 1. Charakterystyka przenoszenia sensora piezoelektrycznego PAC R3a

Sygnały elektryczne na wyjściu sensora piezoelektrycznego są obarczone dużą ilością zakłóceń wynikających z tła akustycznego oraz samych właściwości zjawiska piezoelektrycznego. W związku z tym analiza sygnałów rejestrowanych bezpośrednio z sensora była by bardzo trudna. W celu polepszenia jakości metody EA, pomiar z sensora zostaje najpierw przetworzony za pomocą dedykowanego do tego celu wzmacniacza. Rolą takiego układu jest wzmocnienie sygnałów EA przy jednoczesnej eliminacji (redukcji) sygnałów zakłócających. W naszym przypadku zastosowano układ PAC AE5A kompatybilny z wykorzystywanym w badaniach sensorem EA.

Sygnały EA przetworzone przez piezoelektryk oraz układ wzmacniacza podawane były na kartę pomiarową NI USB-6251, która posiada 16-bitowy przetwornik A/D i pozwala wykonywać pomiary analogowe dla maksymalnie 16 kanałów, przy maksymalnej częstotliwości próbkowania nawet do 1,25 MS/s. Sygnał był próbkowany z częstotliwością 1MS/s. Rysunek 2 przedstawia schemat ideowy stanowiska pomiarowego. Próbkę rejestrowane i zapisywane były, na komputerze wyposażonym w wykonane przez autora oprogramowanie, do plików binarnych.




Rys. 2. Stanowisko do pomiaru sygnałów akustycznych towarzyszących drzewieniu dielektryków stałych

Badania przeprowadzono dla próbek żywic epoksydowych w kształcie kostki o wymiarach 25 mm x 10 mm x 4 mm. Górna i dolna powierzchnia próbki po uprzednim wyszlifowaniu została pokryta lakierem przewodzącym. Ponieważ proces formowania się drzewa elektrycznego może trwać często latami, w badaną próbkę wtopiono elektrodę igłową, tak aby odległość pomiędzy spodem próbki a końcem elektrody wynosiła kilka milimetrów. Dzięki temu zabiegowi uzyskano na tyle duże natężenie pola elektrycznego pomiędzy elektrodą igłową a elektrodą przyłożoną do spodu próbki, że proces formowania się drzewa trwał maksymalnie do kilku godzin. Wraz z pomiarami EA rejestrowany był stan wizualny próbki za pomocą mikroskopu oraz kamery.

3. EKSTRAKCJA WŁAŚCIWOŚCI SYGNAŁU


Poprzez detekcję procesu drzewienia w izolacjach można rozumieć detekcję wyładowań niezupełnych formujących kolejne "gałęzie" drzewa. Wyładowaniom niezupełnym towarzyszy emisja fal elektromagnetycznych (ciepło, światło, fale radiowe) oraz fal dźwiękowych (słyszalnych oraz ultradźwięki). W związku z tym jedną z możliwych do zastosowania metod detekcji WNZ jest metoda emisji akustycznej (EA), która jest szeroko stosowana w diagnostyce obiektów inżynierskich. Należy do metod nie destrukcyjnych. Polega na pomiarze fali sprężystej, rozchodzącej się w obiekcie w wyniku powstawania mikropęknięć. Źródłem mikropęknięć mogą być np.: procesy korozyjne, ulatnianie się gazu przez nie szczelność konstrukcji ciśnieniowej, pęknięcie struny w konstrukcjach sprężonych lub uszkodzenie izolacji wysokonapięciowych urządzeń energetycznych. Na rys. 3 przedstawiono schemat ideowy metody akustycznej.



Rys. 3. Schemat ideowy emisji akustycznej [6]


Klasyczna analiza sygnałów EA rozpoczyna się od zdefiniowaniu empirycznie pewnego progu wyzwolenia, którego przekroczenie określa początek tzw. zdarzenia. Rysunek 4 przedstawia sposób wyznaczania podstawowych parametrów dla sygnału EA. W wyniku wystąpienia zdarzenia (w naszym przypadku

WNZ) sygnał zarejestrowany – jego pierwsza oscylacja – przekracza próg wyzvolenia. Od tego momentu rozpoczyna się interpretacja dalszego sygnału jako sygnału EA. W dalszej części analizy określone są parametry sygnału tzw. deskryptory.



Rys. 4. Parametry sygnału EA określone w trakcie jego obróbki [4]

Na rys. 5 przedstawiono fragment zarejestrowanego sygnału wraz z oznaczonymi przedziałami czasu gdzie występuje WNZ.



Rys. 5. Fragment zarejestrowanego sygnału. Szare obszary oznaczają miejsca przedziały czasu, gdzie występuje WNZ

W celu wyznaczenia parametrów uczących dla sieci neuronowej na sygnał nałożono przesuwane co jedną próbkę okno prostokątne o długości N próbek. Dla każdego N -elementowego bloku sygnału obliczono następujące parametry sygnału:

- wartość średnią:

$$x_{avg}^{(k)} = \frac{1}{N} \sum_{n=1}^N x_n^{(k)} \quad (1)$$

gdzie: $x_n^{(k)}$ – n -ta próbka w k -tym bloku,

– wartość maksymalną:

$$x_{max}^{(k)} = \max(\mathbf{x}^{(k)}) \quad (2)$$

gdzie: $\mathbf{x}^{(k)} = \{x_1^{(k)}, x_2^{(k)}, \dots, x_N^{(k)}\}$,

– energię sygnału:

$$x_E^{(k)} = T_s \sum_{n=1}^N (x_n^{(k)})^2 \quad (3)$$

gdzie: T_s – okres próbkowania,

– moc pasmową sygnału:

$$x_{bp}^{(k)} = \sum_{n=1}^N (X(f_i)^{(k)})^2 \quad \text{dla} \quad f_i = i \frac{f_s}{N} \quad (4)$$

gdzie: $X(f_i)$ – amplituda widma DFT dla częstotliwości f_i ,

– wartość międzyszczytową:

$$x_{pp}^{(k)} = \max(x_n^{(k)}) - \min(x_n^{(k)}) \quad (5)$$

– skośność:

$$x_{skew}^{(k)} = \frac{x_{avg}^{(k)} - med^{(k)}}{\sqrt{\sigma^{(k)}}} \quad (6)$$

gdzie: $med^{(k)}$ – mediana z próbek znajdujących się w k -tym bloku, $\sigma^{(k)}$ – wariancja z próbek znajdujących się w k -tym bloku,

– kurtoza:

$$x_{kurt}^{(k)} = \frac{\mu_r^{(k)}}{\sigma^{(k)4}} - 3 \quad (7)$$


gdzie: μ_4 – czwarty moment centralny, $\sigma^{(k)}$ – wariancja z próbek znajdujących się w k -tym bloku,

– całkę z obszaru pomiędzy obwiednią górną i dolną sygnału

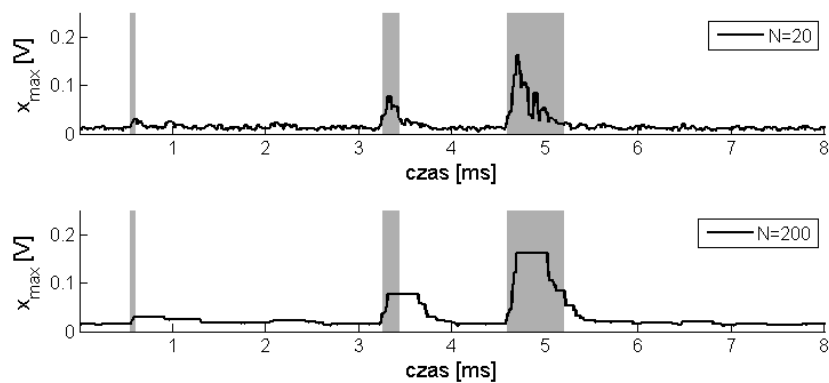
$$x_o^{(k)} = T_s \sum_{n=1}^N O_g(x_n^{(k)}) - O_d(x_n^{(k)}) \quad (8)$$

gdzie: $O_g(x)$ – obwiednia górna, $O_d(x)$ – obwiednia dolna.


Na wstępie przebadany został wpływ długości okna N na wartości poszczególnych detektorów. Analizę przeprowadzono dla dwóch długości okna 20 i 200.






Rys. 6. Porównanie wartości kurtozy dla N równych kolejno 20 oraz 100




Rys. 7. Porównanie wartości maksymalnej dla N równych kolejno 20 oraz 200



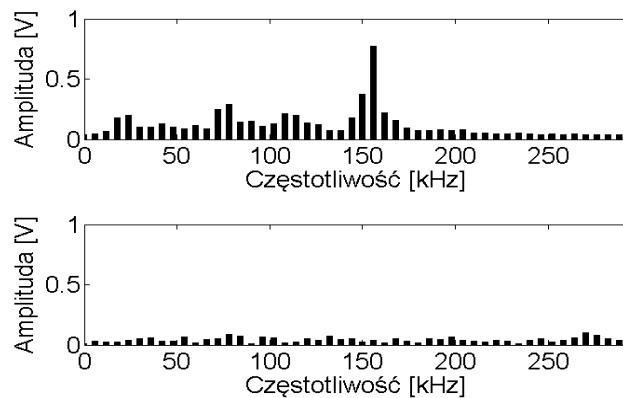
Rys. 8. Porównanie wartości energii sygnału dla N równych kolejno 20 oraz 200

Rys. 9. Porównanie wartości skośności dla N równych kolejno 20 oraz 200Rys. 10. Porównanie wartości średniej sygnału dla N równych kolejno 20 oraz 200Rys. 11. Porównanie wartości międzyszczytowej dla N równych kolejno 20 oraz 100

Rys. 12. Porównanie wartości mocy pasmowej dla N równych kolejno 20 oraz 200

Jak widać na rys. 6 – 12 zbyt krótkie okno powoduje zwiększenie oscylacji wartości poszczególnych parametrów. Większy wpływ na parametry mają zakłócenia sygnału. Natomiast zwiększanie okna powoduje występowanie większej inercji parametrów. Amplituda detektora przesuwa się poza obszar występowania sygnału. Im krótszy jest czas trwania impulsu tym nasila się to zjawisko. W przypadku wartości średniej dla okna sygnału, zwiększanie wartości okna powoduje jednocześnie kompensację szumu białego oraz przemiennego sygnału EA. W dalszej analizie przyjęto długość okna $N = 200$.

Do określenia pasma sygnałów EA wyznaczono uśrednione widmo amplitudowe dla wszystkich zdarzeń i porównano je z widmem amplitudowym szumu zarejestrowanego wraz z sygnałem. Rysunek 13 przedstawia porównanie obu widm. Analizując widmo sygnału EA można zauważyć, że ogranicza się ono do częstotliwości ok. 200 kHz. W związku z tym w dalszych badaniach przyjęto analizę mocy pasmowej sygnału w zakresie od 50 do 200 kHz.




Rys. 13. Widmo sygnału EA (górną) oraz tła akustycznego (dolną)

Wydobycie z wybranych parametrów sygnału danych uczących sieć neuronową polegało na stworzeniu zestawu uczącego składającego się z 600 zestawów uczących x takich, że:

$$x = \{x_{avg}, x_E, x_{bp}, x_{pp}, x_{skew}, x_{kurt}, x_0, x_{max}\} \quad (9)$$

W skład całego zbioru danych uczących wchodziło 300 zestawów uczących dla punktów leżących na początku impulsów EA oraz 300 zestawów leżących w miejscu gdzie występuje tylko tło akustyczne sygnału. Na rys. 14 przedstawiono rzut danych uczących na płaszczyznę wybranych parametrów w odniesieniu do skośności.



Rys. 14. Rozkład danych uczących na poszczególnych płaszczyznach danych uczących w odniesieniu do skośności. Okręgi oznaczają tło akustyczne, natomiast krzyżyki sygnał EA

Analizując rozmieszczenie zestawów przypisanych do tła i EA można stwierdzić, że do poprawnego wykrycia rozpoczęcia sygnałów EA najlepiej nadają się skośność oraz kurtოza. Oba parametry mają widoczne przedziały wartości pomiędzy obiema grupami zestawów. W przypadku parametrów pochodnych po przebiegu czasowym (energia, całka z obwiedni, wartość międzyszczytowa, itd.) można zauważyć, że w tych samych przedziałach wartości występują zarówno zestawy należące do grupy tła akustycznego jak i EA. Jest to spowodowane opóźnieniem pomiędzy rozpoczęciem sygnału EA, a narastaniem poszczególnych parametrów. W przypadku wykrywania początku sygnału EA wartość tych detektorów najczęściej jest zbyt niska.

4. WNIOSKI I PODSUMOWANIE

Przedstawiona w artykule wstępna analiza wartości różnych detektorów sygnału stosowanych w emisji akustycznej, pozwoliła na określenie przydatności poszczególnych parametrów sygnału do wykrywania WNZ w żywicy epoksydowej. Z pośród analizowanych parametrów najlepszymi okazały się kurtoza i skośność. Jednakże należy zwrócić uwagę, że założonym celem badań jest wykrywanie rozpoczęcia formowania fali sprężystej w materiale.

Wykonane badania pozwoliły na ograniczenie rozmiaru danych uczących dla potencjalnego klasyfikatora neuronowego, takiego jak maszyna wektorów nośnych (SVM). Dzięki temu proces nauki sieci może się skrócić nawet kilkakrotnie, a struktura sieci może mieć mniejszą złożoność.

LITERATURA

- [1] Czub P., Bończa: Chemia i technologie żywic epoksydowych, *WNT*, Warszawa 2002.
- [2] Dobrzycki A.: Metoda emisji akustycznej w analizie i badaniu procesu drzewienia elektrycznego dielektryków stałych w silnym polu elektrycznym, *Rozprawa doktorska przedłożona Radzie Wydział Elektrycznego Politechniki Poznańskiej*, Poznań 2008.
- [3] Dobrzycki A., Opydo W. Stanowisko do badania sygnałów emisji akustycznej towarzyszących destrukcji polimetakrylanu metylu w silnym polu elektrycznym, *Zeszyty naukowe Politechniki Poznańskiej seria Elektryka*, nr 50, Poznań 2006, s. 199–208.
- [4] Ranachowski Z.: Emisja akustyczna w diagnostyce obiektów technicznych, *Drogi i Mosty*, nr 2, Poznań 2012, 65–87.
- [5] Simmons, M.: In Ryan, Hugh M. High Voltage Engineering and Testing, 2001, p. 266.
- [6] <http://www.mldt.pl>
- [7] <http://www.pse.pl>
- [8] Datasheet of PAC R3 α

EXTRACTION OF FEATURE FROM AE SIGNALS FOR NEURAL CLASSIFIERS

The following article describes random methods signal analysis used to extract learning features for neural network. Learned neural network should detect AE signals accompanying electrical treeing of epoxy resins. Recorded signals were analyzed with statistical features such as kurtosis and skewness. In addition to the statistical features, signal was analyzed in frequency domain and with well known AE methods.

(Received: 27. 02. 2017, revised: 03. 03. 2017)