

Politechnika Opolska
Wydział Elektrotechniki Automatyki i Informatyki
Instytut Elektroenergetyki



Rozprawa doktorska

**Zastosowanie algorytmu multikomparacyjnego do
klasyfikacji sygnałów emisji akustycznej generowanych
przez wyladowania niezupełne**

Autor: mgr inż. Paweł Kurtasz

Promotor: prof. dr hab. inż. Tomasz Boczar



KAPITAŁ LUDZKI
NARODOWA STRATEGIA SPÓJNOŚCI

UNIA EUROPEJSKA
EUROPEJSKI
FUNDUSZ SPOŁECZNY



Praca powstała przy współfinansowaniu ze środków Europejskiego Funduszu Społecznego

Opole 2011



Rozprawa doktorska: „Zastosowanie algorytmu multikomparacyjnego do klasyfikacji sygnałów emisji akustycznej generowanych przez wyładowania niezupełne”



Spis Treści:

1. Wstęp	5 -
2. Cel, zakres i teza pracy.....	10 -
3. Charakterystyka wyładowań niezupełnych	13 -
3.1. Klasyfikacja wyładowań niezupełnych	13 -
3.2. Własności fizykochemiczne oleju elektroizolacyjnego.....	15 -
3.3. Elektronowa teoria przebicia	17 -
3.4. Pęcherzykowa teoria przebicia.....	21 -
3.5. Mechanizmy generacji wyładowań niezupełnych powierzchniowych w oleju -	23 -
3.6. Mostkowy mechanizm przebicia izolacji	27 -
4. Charakterystyka metody emisji akustycznej oceny wyładowań niezupełnych ..	32 -
4.1. Zjawisko emisji akustycznej	32 -
4.1.1. Geneza prac nad metodą emisji akustycznej	33 -
4.1.2. Charakterystyka sygnałów generowanych przez wyładowania niezupełne-	33 -
4.1.3. Modele opisujące sygnały emisji akustycznej generowanej przez wyładowania niezupełne	35 -
4.2. Deskryptory wykorzystywane do identyfikacji podstawowych form wyładowań niezupełnych mierzonych metodą emisji akustycznej	38 -
4.2.1. Deskryptory charakteryzujące sygnały emisji akustycznej od wyładowań niezupełnych w dziedzinie czasu	38 -
4.2.2. Deskryptory charakteryzujące sygnały emisji akustycznej od wyładowań niezupełnych w dziedzinie częstotliwości	42 -
4.2.3. Deskryptory charakteryzujące sygnały emisji akustycznej od wyładowań niezupełnych w dziedzinie czasowo-częstotliwościowej	46 -
5. Możliwości identyfikacji podstawowych form wyładowań niezupełnych	51 -
5.1. Sztuczne sieci neuronowe	51 -
5.2. Mechanizmy statystyczne.....	57 -
5.3. Algorytmy neuronowo rozmyte i logika rozmyta.....	60 -
6. Baza sygnałów emisji akustycznej generowanej przez wyładowania niezupełne.....	67 -
6.1. Opis bazy sygnałów emisji akustycznej.....	67 -
6.2. Charakterystyka układów generacji podstawowych form wyładowań niezupełnych.....	67 -




6.3. Metodyka pomiarów sygnałów emisji akustycznej generowanej przez wyładowania niezupełne.....	- 71 -
7. Zastosowanie Klasycznego Algorytmu Multikomparacyjnego do klasyfikacji wyładowań niezupełnych	- 77 -
7.1. Określenie warunków pracy Klasycznego Algorytmu Multikomparacyjnego.....	- 77 -
7.2. Opis mechanizmu działania Klasycznego Algorytmu Multikomparacyjnego.....	- 78 -
7.3. Dobór liczby przebiegów wzorcowych	- 81 -
7.4. Dobór i walidacja klasyfikatorów binarnych	- 89 -
8. Analiza porównawcza skuteczności rozpoznawania Zoptymalizowanego Algorytmu Multikomparacyjnego i Klasycznego Algorytmu Multikomparacyjnego	- 95 -
8.1. Określenie warunków pracy Zoptymalizowanego Algorytmu Multikomparacyjnego.....	- 95 -
8.2. Mechanizm działania Zoptymalizowanego Algorytmu Multikomparacyjnego.....	- 95 -
8.3. Wyznaczenie skuteczności klasyfikacji Zoptymalizowanego Algorytmu Multikomparacyjnego.....	- 97 -
9. Ocena możliwości zastosowania deskryptora czasowo-częstotliwościowego w strukturze Zoptymalizowanego Algorytmu Multikomparacyjnego.....	- 100 -
10. Badanie zmodyfikowanej bazy danych za pomocą Zoptymalizowanego Algorytmu Multikomparacyjnego	- 108 -
11. Wnioski	- 116 -
Bibliografia	- 119 -



1. Wstęp

Większość transformatorów dużych mocy, pracujących obecnie w polskim systemie elektroenergetycznym, to urządzenia o dużym stopniu wyeksploatowania, ich strukturę wiekową przedstawiono w rys. 1.1 [110].

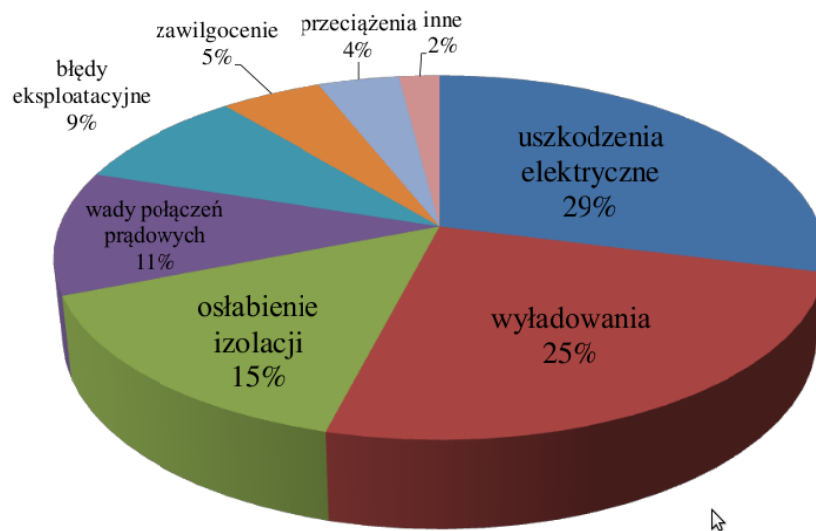


Rys. 1.1. Charakterystyka populacji transformatorów ze względu na wiek [110].

Jak zobrazowano na rys. 1.1 największą grupę stanowią transformatory, których okres eksploatacji zawiera się w przedziale 20 lat – 30 lat. Jednak największe ryzyko wystąpienia awarii związane jest z eksploatacją grupy transformatorów, stanowiącej 46% populacji, których wiek przekroczył 30 lat. W większości, transformatory z tej grupy, charakteryzują się dobrym stanem technicznym, ale mogą występować w nich zaawansowane procesy starzeniowe [110].

Do najczęstszych przyczyn występowania awarii w transformatorach elektroenergetycznych należą: uszkodzenia elektryczne, wyładowania niezupełne (WZN), osłabienie izolacji i wady połączeń prądowych rys 1.2 [110]. Zestawienie to zostało sporządzone w oparciu o dane dotyczące przyczyn

występowania awarii w transformatorach, opracowane przez Polskie Towarzystwo Przesyłu i Rozdziału Energii Elektrycznej, w latach 1999 – 2002 [110].



Rys. 1.2. Przyczyny uszkodzeń transformatora wysokiego napięcia [110].

Z analizy danych zawartych na rys.1.1 i rys. 1.2 wynika, że jednym z najbardziej istotnych elementów, które są niezbędne do zapewnienia bezawaryjnej pracy systemu elektroenergetycznego, jest diagnostyka układów izolacyjnych transformatorów elektroenergetycznych. Może to zapewnić ich długotrwałą i bezpieczną eksploatację, w szczególności dotyczy to metod diagnostycznych stosowanych on-line, bez konieczności odłączania badanego urządzenia od napięcia zasilania.

Aktualnie wykorzystywane podstawowe systemy automatyki zabezpieczeniowej transformatorów elektroenergetycznych, umożliwiają jedynie ich bezpieczne wyłączenie po wystąpieniu awarii, nie dają jednak możliwości jej predykcji. Powstaje więc konieczność uzupełnienia automatyki zabezpieczeniowej transformatorów elektroenergetycznych, o dodatkowe układy pomiarowe, które umożliwiałyby przewidywanie wystąpienia awarii. Obecnie, jako dodatkowe zabezpieczenie jednostek transformatorowych dużej



mocy, takich jak transformatory blokowe lub autotransformatory sprzęgłowe (np. 110 kV na 400 kV), coraz częściej wykorzystuje się, ciągły monitoring oleju izolacyjnego, wykonywanych pod kątem poziomu nasycenia wodorem. Jednakże tego typu rozwiązanie dostarcza jedynie fragmentarycznych informacji, na temat procesów zachodzących w izolacji nadzorowanego urządzenia. Ponadto poziom nasycenia wodorem, wzrasta wraz z czasem użytkowania urządzenia. W praktyce eksploatacyjnej nie ma możliwości, na podstawie tylko tego kryterium, dokonać poprawnej oceny zjawisk, które mogą prowadzić do degradacji i w konsekwencji do uszkodzenia izolacji transformatora.

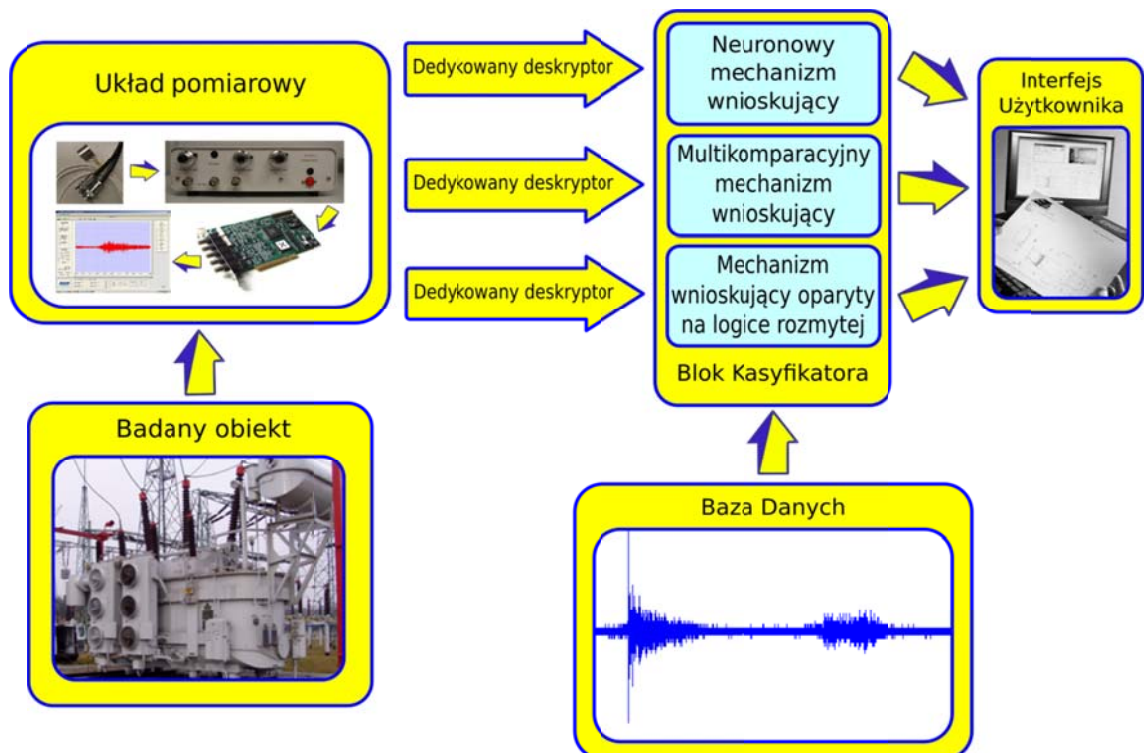
Inną metodą diagnostyczną, jest pomiar emisji akustycznej (EA), generowanej przez WNZ, które mogą występować w badanej izolacji. Metoda EA stanowi obecnie ważne uzupełnienie standardowych metod diagnostycznych jak elektryczna i chromatografii gazowej. Umożliwia wykonanie oceny badanej izolacji podczas normalnej pracy urządzenia elektroenergetycznego, bez konieczności odłączania obciążenia. Obecnie trwają prace zmierzające do zastosowania metody EA do pomiarów realizowanych on-line. Pozwala ona stwierdzić fakt występowania WNZ w badanej izolacji, zmierzyć ich intensywność, w ograniczonym zakresie zlokalizować obszar ich występowania, a także zidentyfikować formę WNZ, która jest ściśle powiązana z określonym rodzajem defektu izolacji, bez konieczności ingerowania w cykl pracy badanego urządzenia.

Celem prowadzonych w Instytucie Elektroenergetyki Politechniki Opolskiej prac, jest opracowanie systemu ekspertowego, do diagnostyki on-line układów izolacyjnych urządzeń elektroenergetycznych, w oparciu o pomiary sygnałów EA generowanej przez WNZ, przy zastosowaniu: elementów sztucznej inteligencji, sztucznych sieci neuronowych i algorytmów statystycznych. Niniejsza rozprawa stanowi kontynuację tych prac. W jej ramach, Autor zaproponował zastosowanie algorytmu multikomparacyjnego, do rozpoznawania podstawowych form WNZ. Można go zaliczyć do grupy algorytmów statystycznych. Wraz z dedykowanymi deskryptorami, może on pełnić funkcję mechanizmu decyzyjnego, w systemie ekspertowym, który

obecnie jest wykonywany w Instytucie. Równorzędny funkcjonalnie mechanizm decyzyjny, oparty o sztuczne sieci neuronowe, został opracowany w ramach rozprawy doktorskiej, dra Sebastiana Boruckiego [38].

Autor niniejszej rozprawy, wykazał konieczność opracowania trzeciego niezależnego mechanizmu decyzyjnego, zbudowanego w oparciu o np. logikę rozmytą, który mógłby zostać równolegle zaimplementowany do systemu ekspertowego. Zdaniem Autora zastosowanie trzech równoległych i równorzędnych klasyfikatorów, zwiększy skuteczność i poprawność procesu klasyfikacji. Na rys. 1.3 przedstawiono, zaproponowaną przez Autora, strukturę systemu ekspertowego. Obejmuje ona: obiekt badany, układ pomiarowy, deskryptory dedykowane poszczególnym mechanizmom wnioskującym wchodzącym w skład bloku klasyfikatora, bazę danych i interfejs użytkownika.

Zakres prac naukowo-badawczych, które zrealizowano w ramach niniejszej rozprawy obejmował, opracowanie multikomparacyjnego mechanizmu wnioskującego i dedykowanego deskryptora. Ponadto, uzupełniono bazę danych podstawowych form WNZ o dodatkową nieskatalogowaną dotychczas formę.





Rozprawa doktorska: „Zastosowanie algorytmu multikomparacyjnego do klasyfikacji sygnałów emisji akustycznej generowanych przez wyładowania niezupełne”

Rys. 1.3. Schemat blokowy systemu ekspertowego, o zmodyfikowanej strukturze, zaproponowanej przez Autora.



2. Cel, zakres i teza pracy

Celem ogólnym niniejszej rozprawy doktorskiej było, określenie możliwości zastosowania klasyfikatora opartego na algorytmie multikomparacyjnym, do analizy sygnałów EA generowanych przez dziewięć podstawowych form WNZ, jakie mogą występować w izolacji papierowo-olejowej transformatorów elektroenergetycznych, które można powiązać z określonym typem defektu izolacji papierowo-olejowej.

Do celów szczegółowych niniejszej pracy można zaliczyć:

- określenie możliwości zastosowania klasyfikatora opartego na Klasycznym Algorytmie Multikomparacyjnym (KAM) do klasyfikacji ośmiu rozpatrywanych Klas WNZ,
- określenie możliwości zastosowania klasyfikatora opartego na Zoptymalizowanym Algorytmie Multikomparacyjnym (ZAM) do klasyfikacji dziewięciu rozpatrywanych Klas WNZ,
- określenie możliwości zastosowania deskryptora częstotliwościowego do klasyfikacji podstawowych form WNZ, z wykorzystaniem klasyfikatora KAM,
- określenie możliwości zastosowania deskryptora częstotliwościowego do klasyfikacji podstawowych form WNZ, z wykorzystaniem klasyfikatora ZAM,
- określenie możliwości zastosowania deskryptora czasowo-częstotliwościowego do klasyfikacji dziewięciu podstawowych form WNZ, z wykorzystaniem klasyfikatora ZAM.

W rozprawie przyjęto następującą tezę:

„Klasyfikator oparty na algorytmie multikomparacyjnym, umożliwia rozpoznawanie jednoźródłowych form wyładowań niezupełnych, rejestrowanych metodą emisji akustycznej, które są generowane w izolacji papierowo-olejowej, dla ściśle określonych warunków metrologicznych”.



W celu udowodnienia założonej w pracy tezy, podjęto następujące zagadnienia:

- scharakteryzowano dziewięć podstawowych form WNZ,
- przedstawiono metodę EA i wskazano możliwości jej zastosowania do pomiarów WNZ,
- scharakteryzowano sygnały EA generowanych przez WNZ,
- przedstawiono modele sygnałów EA generowanych przez WNZ,
- dokonano przeglądu deskryptorów charakteryzujących sygnały EA: czasowych, częstotliwościowych, czasowo-częstotliwościowych i wskaźników statystycznych,
- dokonano przeglądu metod wykorzystywanych do identyfikacji WNZ ze szczególnym uwzględnieniem: sztucznych sieci neuronowych, narzędzi statystycznych, algorytmów neuronowo-rozmytych i logiki rozmytej,
- scharakteryzowano bazę sygnałów EA, reprezentujących podstawowe formy WNZ, którą zastosowano w niniejszej rozprawie,
- przedstawiono sposób generacji, rejestracji i analizy WNZ, których sygnały EA zostały skatalogowane w utworzonej bazie danych,
- opisano metodykę pomiarów EA od WNZ, którą zastosowano podczas badań laboratoryjnych zrealizowanych w ramach niniejszej pracy,
- przeprowadzono badania skuteczności algorytmu KAM w zastosowaniu do rozpoznawania podstawowych form WNZ, a w szczególności:
 - określono warunki pracy,
 - przedstawiono mechanizm działania,
 - przeprowadzono dobór liczby przebiegów wzorcowych,
 - wykonano dobór i walidację klasyfikatorów binarnych zastosowanych w strukturze multikomparacyjnej,
- przeprowadzono badania porównawcze algorytmów KAM i ZAM poprzez:
 - określono warunki pracy algorytmu ZAM,
 - opisano mechanizm działania algorytmu ZAM,
 - wyznaczono skuteczność klasyfikacji algorytmu ZAM,
 - porównano mechanizmy działania i uzyskane wyniki skuteczności klasyfikacji algorytmów KAM i ZAM,



Rozprawa doktorska: „Zastosowanie algorytmu multikomparacyjnego do klasyfikacji sygnałów emisji akustycznej generowanych przez wyładowania niezupełne”

- dokonano oceny możliwości zastosowania deskryptora czasowo-częstotliwościowego w algorytmie ZAM,
- przeprowadzono badania zmodyfikowanej bazy danych, zawierającej dziewięć form WNZ, odpowiadających dziewięciu Klasom defektów izolacji, za pomocą algorytmu ZAM,
- sformułowano wnioski w oparciu o uzyskane wyniki.



3. Charakterystyka wyładowań niezupełnych

3.1. Klasyfikacja wyładowań niezupełnych

WNZ jest wyładowaniem elektrycznym, które może występować w określonym punkcie lub obszarze układu izolacyjnego. Polega ono na lokalnym przepływie prądu elektrycznego przez izolację, którego natężenie nie jest wystarczające do spowodowania natychmiastowej i bezpośredniej utraty jej własności izolacyjnych. Jednakże długotrwałe oddziaływanie WNZ powoduje stopniową degradację układu izolacyjnego i w skrajnym przypadku może doprowadzić do powstania wyładowań zupełnych, a w konsekwencji do przebicia izolacji [1, 2, 3, 29, 79].

Istnieje kilka metod klasyfikacji WNZ. Można je podzielić ze względu na intensywność występowania na: stabilne i niestabilne w czasie oraz zanikające [4, 5]. Kolejny podział WNZ na: samodzielne i niesamodzielne, zaproponowano w pracach [6, 7]. Trzeci sposób klasyfikacji WNZ zakłada ich podział na formy, które są powiązane z określonymi typami defektów izolacji. Był on szeroko opisywany w pracach [8 – 12] prowadzonych w Instytucie Elektroenergetyki Politechniki Opolskiej i został przyjęty za bazowy w niniejszej rozprawie. Zaproponowano zdefiniowanie dziewięciu następujących klas defektów izolacji olejowej i papierowo – olejowej [8, 13, 14, 15]:

- Klasa 1 – wyładowania w układzie ostrze-ostrze, które można powiązać z WNZ powstałymi na skutek uszkodzenia izolacji dwóch sąsiadujących zwojów uzwojenia transformatora,
- Klasa 2 – wyładowania w układzie ostrze-ostrze ze swobodnie przemieszczającymi się pęcherzykami gazowymi, które mogą odzwierciedlać WNZ w oleju zagazowanym i spowodowane są uszkodzeniem izolacji dwóch sąsiadujących uzwojeń transformatora,
- Klasa 3 – wyładowania w układzie ostrze-płyta, które mogą modelować WNZ występujące między uszkodzoną częścią izolacji uzwojenia transformatora a uziemionymi częściami płaskimi (elementy kadzi),



- Klasa 4 – wyładowania w układzie dwóch elektrod płytowych, między którymi znajduje się izolacja papierowa, jest to najczęstsza forma WNZ występująca w tzw. punkcie potrójnym, w którym powierzchnia elektrody styka się z dielektrykiem stałym i ciekłym,
- Klasa 5 – wyładowania w układzie z jedną elektrodą wielostrzową a drugą płytową, między którymi znajduje się izolacja papierowa, inny rozkład natężenia pola elektrycznego w porównaniu z wyładowaniami w układzie powierzchniowym z dwoma elektrodami płaskimi,
- Klasa 6 – wyładowania w układzie wielostrze-płyta w oleju, które mogą modelować WNZ występujące między wielopunktowym uszkodzeniem izolacji uzwojenia transformatora a uziemionymi częściami płaskimi (elementy kadzi),
- Klasa 7 – wyładowania w układzie wielostrze-płyta w oleju, ze swobodnie przemieszczającymi się pęcherzykami gazowymi, które mogą być powiązane z WNZ występującymi między wielopunktowym uszkodzeniem izolacji uzwojenia transformatora a uziemionymi częściami płaskimi (elementy kadzi), w zagazowanym oleju,
- Klasa 8 – wyładowania w układzie wielostrze-płyta ze swobodnie przemieszczającymi się cząstkami stałymi o nieokreślonym potencjale, które mogą modelować WNZ występujące w oleju zawierającym cząsteczki włókien celulozowych powstałych w procesie stopniowej degradacji izolacji papierowo-olejowej spowodowanej procesami starzeniowymi,
- Klasa 9 – wyładowania w układzie ostrze-płyta ze swobodnie przemieszczającymi się pęcherzykami gazowymi, mogą one modelować WNZ występujące między uszkodzoną częścią izolacji uzwojenia transformatora a uziemionymi częściami płaskimi (elementy kadzi), w zagazowanym oleju.

Zaproponowane klasy podstawowych form WNZ można podzielić na cztery podstawowe grupy. Do pierwszej z nich można zaliczyć wyładowania, do które



występują w izolacji olejowej, bez udziału papieru i pęcherzyków gazowych. Należą do niej następujące klasy WNZ:

- Klasa 1 – wyładowania w układzie ostrze-ostrze w oleju,
- Klasa 3 – wyładowania w układzie ostrze-płyta w oleju,
- Klasa 6 – wyładowania w układzie wieloostre-płyta w oleju.

Do drugiej grupy można zaliczyć wyładowania, do których dochodzi w izolacji olejowej, z udziałem pęcherzyków gazowych, bez udziału papieru. W grupie tej można wyróżnić:

- Klasa 2 – wyładowania w układzie ostrze-ostrze w oleju ze swobodnie przemieszczającymi się pęcherzykami gazowymi,
- Klasa 7 – wyładowania w układzie wieloostre-płyta w oleju, ze swobodnie przemieszczającymi się pęcherzykami gazowymi,
- Klasa 9 – wyładowania w układzie ostrze-płyta w oleju, ze swobodnie przemieszczającymi się pęcherzykami gazowymi.

Trzecią grupę podstawowych form WNZ stanowią wyładowania, które generowane są w izolacji papierowo-olejowej. Do grupy tej można zaliczyć następujące klasy WNZ:

- Klasa 4 – wyładowania w układzie dwóch elektrod płytowych, między którymi znajduje się izolacja papierowa,
- Klasa 5 – wyładowania w układzie z jedną elektrodą wieloostrową a drugą płytową, między którymi znajduje się izolacja papierowa.

Do czwartej grupy defektów izolacji można zaliczyć wyładowania, do których dochodzi w skutek obecności w oleju elektroizolacyjnym cząstek o nieokreślonym potencjale. Grupa ta jest reprezentowana przez, jedną klasę:

- Klasa 8 – wyładowania w układzie wieloostre-płyta ze swobodnie przemieszczającymi się cząstkami stałymi o nieokreślonym potencjale.

3.2. Własności fizykochemiczne oleju elektroizolacyjnego

Obecnie najczęściej wykorzystywane są w technice izolacyjnej oleje mineralne, które powstają w procesie rafinacji ropy naftowej. Stosuje się je min.



jako: samodzielny materiał izolacyjny, czynnik chłodzący, syciwo do izolacji stałej np. w kondensatorach. Produkowane oleje mineralne mają, w zależności od przeznaczenia, zróżnicowany skład chemiczny, który decyduje o wartościach takich parametrów jak: gęstość, lepkość, przenikalność elektryczna i rezystywności [2, 6, 7].

Oleje transformatorowe posiadają wysoką wytrzymałość elektryczną, małe straty dielektryczne i niską lepkość, z uwagi na pełnioną funkcję izolująco-chłodzącą. Ponadto powinny cechować się stabilnością parametrów fizykochemicznych w czasie i być obojętne chemicznie w stosunku do innych materiałów izolacyjnych oraz konstrukcyjnych transformatora [2, 6, 7].

Oleje stosowane jako syciwa kablowe mają zbliżone właściwości fizykochemiczne do olejów transformatorowych, z tą tylko różnicą, że posiadają większą lepkość. Jest nieznacznie większa w przypadku kabli najwyższych napięć i znacząco większa nawet do 30% w dla kabli średnich napięć. Dodatkową cechą olejów izolacyjnych stosowanych w kablach najwyższych napięć jest wysoka rezystywność, która w połączeniu z niskim współczynnikiem strat dielektrycznych powoduje ograniczenie procesu nagrzewania. Obecnie ze względu na obostrzenia środowiskowe odchodzi się od stosowania kabli olejowych. Jednakże z technicznego punktu widzenia są one korzystne w zastosowaniu z względu na niską awaryjność i długi okres eksploatacji [2, 6, 7].

Oleje stosowane jako syciwa kondensatorowe posiadają podobne właściwości do olejów kablowych o niskiej lepkości. Dodatkowo cechują się zdolnością do pochłaniania produktów gazowych powstałych w wyniku ich rozkładu, wywołanego polem elektrycznym.

Pomimo zróżnicowania parametrów fizykochemicznych olejów elektroizolacyjnych, wynikających z ich przeznaczenia, procesy fizyczne poprzedzające ich przebicie mają podobny przebieg [2, 3, 6, 16].

Rozwój WNZ generowanych w dielektrykach ciekłych, ze względu na ich niejednorodną strukturę i złożony charakter oddziaływań międzycząsteczkowych, jest procesem niezwykle skomplikowanym. Dlatego proces ten jest mniej poznany od zjawisk towarzyszących generacji i rozwojowi WNZ w gazach.



Dodatkowo powodem takiego stanu rzeczy, jest zdolność cząsteczek cieczy do wykonywania nakładających się na siebie ruchów drgających, rotacyjnych i przemieszczeń translacyjnych wywołanych polem elektrycznym. Istotny jest również wpływ nie do końca poznanych jeszcze czynników takich jak: zanieczyszczenia w postaci cząstek stałych, obecność wtrącin gazowych, zawartość wody, degradacja elektrod, proces starzeniowy oleju wywołany WNZ i czynnikami środowiskowymi, ponadto od czasu, kształtu i biegunowości przyłożonego napięcia, a także temperatury, ciśnienia i stopnia zjonizowania cieczy wynikającego z jej przepływu [3, 7, 16, 17].

Ze względu na dużą złożoność zjawisk poprzedzających przebicie oleju izolacyjnego, nie możliwe jest wskazanie tylko jednego mechanizmu powodującego przebicie. W publikacjach dotyczących dielektryków ciekłych można wyróżnić trzy podstawowe teorie opisujące proces przebicia olejów elektroizolacyjnych [6, 7, 16, 17]:

- elektronowa teoria przebicia dotycząca olejów o dużym stopniu czystości, pomija się w niej wpływ zanieczyszczeń i ciśnienia,
- pęcherzykowa teoria charakteryzująca proces przebicia olejów pozbawionych zanieczyszczeń stałych, ale zawierających pęcherzyki gazowe, którym przypisuje się główną rolę w inicjacji WNZ,
- mostkowa teoria przebicia, oleje silnie zanieczyszczone, przypisuje ona główną rolę w inicjacji procesu przebicia zanieczyszczeniom w postaci cząstek stałych, przemieszczających się w oleju izolacyjnym.

Przedstawione wyżej teorie opisujące mechanizmy przebicia olejów elektroizolacyjnych można powiązać z Klasami WNZ, scharakteryzowanymi w rozdz. 3.1 niniejszej rozprawy i podzielić na cztery grupy.

3.3. Elektronowa teoria przebicia

Do pierwszej grupy defektów izolacji można zaliczyć WNZ generowane w iskiernikach: ostrze-ostrze, ostrze-płyta, wieloostrze-płyta, bez zawartości w oleju izolacyjnym zanieczyszczeń stałych i pęcherzyków gazowych. Można z



nią powiązać elektronową teorię przebicia. Dotyczy ona wyłącznie cieczy o bardzo wysokim stopniu czystości. Uwzględnia ona wyłącznie elektryczne aspekty mechanizmu przebicia i dotyczy dwóch przypadków: pierwszy zakłada istnienie małej przerwy iskiernikowej w zakresie od dziesiątych części milimetra do milimetra, drugi zakłada warstwy o większych grubościach rzędu kilku milimetrów [6, 16].

Pierwszy wariant swoistego mechanizmu przebicia dotyczy cienkich warstw olejowych, jest zbliżony do mechanizmu iskry krótkiej, który występuje w gazach i został opisany przez Towsenda. Mechanizm ten zakłada, że elektrony początkujące wyładowanie w cieczy powstają w skutek autoemisji z katody, a proces ten nasila się w miejscach nierówności jej powierzchni. Elektrony te wywołują jonizację zderzeniową, która jest głównym zjawiskiem w mechanizmie przebicia cienkich warstw oleju. Dużą rolę odgrywa więc współczynnik jonizacji zderzeniowej α , jego wartość jest na poziomie 10^4 cm^{-1} i wraz z odległością zmniejsza się. Fakt spadku wartości współczynnika tłumaczy się przyklepaniem elektronów do cząstek oleju, co powoduje powstawanie jonów ujemnych. Zjawisko to występuje wówczas gdy odstęp między elektrodami jest większy od długości lawiny elektronowej, a pole elektryczne wywoływane przez elektrody jest silnie niejednostajne. W przypadku uwzględnienia większych odległości między elektrodami określa się efektywny współczynnik jonizacji, który można wyznaczyć zależnością:

$$(3.1)$$

gdzie: α – współczynnik jonizacji zderzeniowej, α_{eff} – współczynnik jonizacji zderzeniowej nieuwzględniający zjawiska przyłączania się elektronów, β – współczynnik uwzględniający przyczepianie elektronów [6, 16].

Przy odległościach rzędu tysięcznych części milimetra współczynnik α , stąd równanie 3.1 upraszcza się i przyjmuje postać:

$$(3.2)$$



Kluczową rolę w mechanizmie jonizacji odgrywa powstawanie dodatniego ładunku przestrzennego co objawia się przez powstanie znacznego spadku napięcia przy katodzie i jednoczesnym wzroście gęstości emisji elektronowej. Skutkiem tego dochodzi do powstawania, przy powierzchni elektrody ujemnej, lokalnych pól elektrycznych o natężeniach powyżej 10^6 V/cm. W powstałym w konsekwencji strumieniu elektronów dochodzi do szeregu zderzeń z cząsteczkami oleju, o charakterze jonizacyjnym. Dodatkowo pod wpływem energii zderzeń występuje zwiększenie drgań w ramach wiązań międzycząsteczkowych. Jest ono powodem lokalnego wzrostu temperatury i może być przyczyną rozgrzania i odparowywania oleju. To z kolei prowadzi do powstawania mikropęcherzyków gazowych, których wytrzymałość elektryczna jest wielokrotnie mniejsza niż wytrzymałość elektryczna oleju izolacyjnego. Powoduje to dalszy rozwój zjawiska, według mechanizmu wyładowań w dielektrykach gazowych [3, 18].

Drugi wariant swoistego mechanizmu przebicia dotyczy co najmniej kilkumilimetrowej warstwy oleju i jest zbliżony do kanałowego mechanizmu przeskoku w gazie o nierównomiernym polu. Zgodnie z teorią, pierwotnym źródłem swobodnych elektronów jest autoemisja katodowa, natomiast wtórnym fotojonizacja warstwy cieczy przylegającej do kanału tworzącego się strimera [6, 16, 17]. Powstaje on z lawin elektronowych, przesuniętych względem siebie w czasie i przestrzeni. Kanał strimera jest stosunkowo słabo przewodzący, co skutkuje spadkiem wartości napięcia wzdłuż kanału. Czoło rozwijającego się strimera jest ekranowane przez ładunek przestrzenny tego samego znaku co elektroda, od której strimer się rozwija, jego rozwój ma charakter skokowy, a w trakcie jego trwania następują schodkowe zahamowania jego długości. Podczas gdy długość strimera nie przyrasta, następuje intensyfikacja zderzeń przemieszczających się w kanale elektronów z cząstkami dielektryka ciekłego. Prowadzi to do podwyższenia temperatury w kanale, a w szczególności jego czołowej części, gdzie występuje największa liczba zderzeń. Jeżeli temperatura kanału osiągnie temperaturę wrzenia, zostanie on wypełniony oparami oleju, a te podlegają procesowi intensywnej jonizacji. Skutkiem czego, w miejscu kanału strimera, zostanie utworzony wysoko przewodzący kanał plazmowy. Z czoła



nowopowstałego kanału plazmowego, dojdzie do dalszego skokowego rozwój strimera [18]. Przyrost długości kanału wyładowczego następuje z prędkością (10^6 - 10^7) cm/s, w czasie (0,02-0,1) μ s. Wpływ ładunku przestrzennego pochodzącego od strimera poprzedzającego, może powodować odchylenie kierunku rozwoju kolejnego kanału, w stosunku do kierunku pierwotnego. Cykliczny proces generacji kolejnych strimerów, podtrzymuje wysoką temperaturę kanału wyładowczego i ostatecznie może doprowadzić do przebicia dielektryka [18].

Teoria swoistego mechanizmu przebicia tłumaczy w sposób zadowalający zależność wytrzymałości elektrycznej oleju w funkcji grubości jego warstwy, uwzględnia ponadto wzajemny odstęp elektrod, a także właściwości materiału, z którego są wykonane. Nie wyjaśnia ona jednak innych zjawisk takich jak np.: zwiększanie wytrzymałości elektrycznej cieczy wraz ze wzrostem jej ciśnienia. Uwzględniając fakt, że ciecze zalicza się do ciał nisko ściśliwych, wzrost ciśnienia nie może być przyczyną dostatecznego zmniejszania dróg swobodnych elektronów, a więc zgodnie z teorią, nie może on wpływać na swoisty mechanizm generacji wyładowań.

Teorią, która bardziej trafnie odwzorowuje rzeczywistość jest nieswoisty mechanizm powstawania wyładowań, w izolacji ciekłej. Uwzględnia on istnienie zanieczyszczeń w oleju elektroizolacyjnym, pod wpływem których dochodzi do istotnych modyfikacji pierwotnych właściwości fizykochemicznych czystego oleju [3, 19]. Należy również wspomnieć o dwóch innych teoriach a mianowicie o konwekcyjno-zaburzeniowym mechanizmie przebicia i o jonowym mechanizmie przebicia.

Mechanizm konwekcyjno-zaburzeniowy dotyczy warunków w których istnieje silne pole elektryczne, a olej izolacyjny jest w wysokim stopniu czysty. Zakłada ponadto, że nośniki ładunku przestrzennego pochodzą bezpośrednio z powierzchni elektrod. Warunkiem przebicia jest współdziałanie ładunku z polem elektrycznym bliskim wartości krytycznej.

Natomiast mechanizm jonowy dotyczy olejów słabo i umiarkowanie zanieczyszczonych, czynnikiem warunkującym przebicie w tym mechanizmie jest losowe przemieszczanie się zanieczyszczeń w objętości oleju i



występowanie przewodnictwa jonowego. Mechanizmy przebicia występujące w rzeczywistości można postrzegać jako superpozycje istniejących teorii i w tym zastosowaniu przytoczone teorie są niezwykle przydatne. [3, 6, 7, 16].

3.4. Pęcherzykowa teoria przebicia

Do drugiej, wyszczególnionej przez Autora grupy WNZ, można zaliczyć: wyładowania powstające w izolacji olejowej z udziałem pęcherzyków gazowych, bez udziału przegród papierowych i cząstek o nieokreślonym potencjale, zamodelowane przy użyciu iskierników: ostrze-ostrze, wieloostrze-płyta i ostrze-płyta.

Podczas produkcji olej elektroizolacyjny jest poddawany procesowi odgazowania, jednakże dzięki zdolnościom do rozpuszczania gazów (szczególnie węglowodorów i wodoru) pewna ich ilość może pozostawać w jego objętości. Ilość gazów jaką jest w stanie zabsorbować olej jest ograniczona i zależna od takich parametrów jak: ciśnienie i temperatura. W skutek gwałtownej zmiany jednego, bądź obu wymienionych czynników jednocześnie, może dojść do wydzielenia się gazu w postaci pęcherzyka. Jest to proces niezwykle niebezpieczny ponieważ pojawienie się wtrącin gazowych w oleju powoduje radykalne pogorszenie wytrzymałości elektrycznej układu izolacyjnego [7]. Pęcherzyki gazowe mogą również występować w oleju w skutek ich migracji z niepoprawnie wysuszonej izolacji stałej lub pod wpływem zbyt gwałtownego wypełniania kadzi transformatora cieczą. Przyczyną generacji pęcherzyków gazowych mogą być także WNZ, które początkowo rozwinęły się w czystym oleju. W wyniku ich oddziaływania dochodzi do degradacji oleju z możliwością wydzielenia się nie tylko gazów ale i ciał stałych np. sadzy. Może również następować lokalne parowanie cieczy izolacyjnej wokół mikroostrzy, co jest spowodowane krytycznym zaburzeniem rozkładu pola elektrycznego w tym miejscu [21, 22]. Jego wartość można wyznaczyć za pomocą kryterium sformułowanego przez A. H. Sharbaugha i P. K. Watsona w postaci zależności (3.3) [7].



(3.3)

gdzie: σ – krytyczne naprężenie pola elektrycznego, i – odpowiednio ciepło właściwe i ciepło parowania cieczy, ΔT – przyrost temperatury oleju, m – masa oleju podlegającego procesowi przegrzania, w skutek którego dochodzi do wrzenia oleju, t – czas oddziaływania impulsu napięciowego, będący jednocześnie czasem procesu przegrzania, ϵ_0 – stałe.

Powodem lokalnego parowania oleju mogą być również nierówności powierzchni elektrod. W miejscach ich występowania dochodzi do bombardowania ciekłego dielektryka elektronami. Średnia gęstość prądu towarzysząca temu zjawisku jest niewielka i wynosi kilka $\mu\text{A}/\text{cm}^2$, a cały płynący przez elektrodę prąd przepływa tylko w miejscach występowania nierówności. To sprawia, że lokalna gęstość prądu może być znacznie większa [21].

Wyniki przedstawione w najnowszych pracach wskazują również, że obecność wtrącin gazowych może być spowodowana procesem kawitacji, do którego dochodzi w skutek turbulentnego przetłaczania oleju lub pod wpływem drgań rdzenia transformatora [20].

Głównym założeniem pęcherzykowej teorii przebicia jest to, że do zapoczątkowania wyładowania dochodzi wewnątrz istniejącej już wtrąciny gazowej. Jest ono spowodowane istnieniem lokalnego natężenia pola elektrycznego o wartości określonej równaniem (3.4) [7].

$$E = \frac{U}{d} \quad (3.4)$$

gdzie: E – natężenie pola w przestrzeni międzyelektrodowej przy założeniu, że dielektryk jest jednorodny (bez wtrącin gazowych), ϵ – przenikalność elektryczna względna oleju, E_c – natężenie krytyczne pola w pęcherzyku gazowym [7].

Zjonizowane pęcherzyki dążą do zminimalizowania swojej energii potencjalnej poprzez wyrównywanie rozkładów ciśnienia powierzchniowego i elektrostatycznego. Powoduje to zmianę ich kształtu geometrycznego poprzez



wydłużenie ich kształtu w kierunku linii sił pola elektrycznego. Opracowano kilka modeli deformacji kulistego pęcherzyka gazu w polu elektrycznym. Model Stiepańczuka – Tiniakowa zakłada, że niezjonizowany pęcherzyk gazu przyjmuje w polu elektrycznym kształt elipsoidy obrotowej spłaszczonej w kierunku linii pola. Natomiast modele Kao i Gartona-Krasuckiego przewidują, że kształt niezjonizowanego pęcherzyka jest elipsoidalny i wydłużony w kierunku linii pola. [23, 24, 25].

W skutek zaistniałych procesów może dojść do wyładowania głównego w oleju, które będzie miało postać gazowego kanału plazmowego. Według K. C. Kao objętość pęcherzyków, w skutek procesu wydłużania, nie ulegnie zmianie. Natomiast przeskok może wystąpić wtedy, gdy spadek napięcia osiąga wartość minimalną na krzywej Paschena odpowiadającej rodzajowi gazu wypełniającego pęcherzyki. Wzór zaproponowany dla omawianego przypadku przez K. C. Kao ma postać (3.5) [7,18].

Wzór (3.5) opisuje zależność między ciśnieniem oleju a naprężeniem krytycznym pola elektrycznego. Jeżeli ciśnienie oleju wrasta, to początkowy promień pęcherzyka gazowego maleje, tym samym wartość naprężenia krytycznego pola w dielektryku jest tym większa im większe jest ciśnienie.

$$E_{cr} = \frac{U_0}{r} \left(1 - \frac{U_0}{U_0 + U_0} \right) \quad (3.5)$$

gdzie: E_{cr} – naprężenie krytyczne pola elektrycznego, ϵ – przenikalność elektryczna odpowiednio cieczy i gazu w pęcherzyku, U_0 – napięcie powierzchniowe cieczy, U – spadek napięcia w pęcherzyku, r – promień początkowy pęcherzyka [7, 18].

3.5. Mechanizmy generacji wyładowań niezupełnych powierzchniowych w oleju

Do trzeciej grupy WNZ według Autora można zaliczyć wyładowania, które występują w izolacji papierowo-olejowej, bez udziału pęcherzyków gazowych i




cząstek o nieokreślonym potencjale, w następujących typach iskierników: dwóch elektrod płytowych, między którymi znajduje się izolacja papierowa oraz z jedną elektrodą wieloostrzową a drugą płytową, między którymi znajduje się izolacja papierowa.

Są to WNZ powierzchniowe i stanowią najczęściej występującą formę wyładowań w układach izolacyjnych urządzeń elektroenergetycznych. Jest to spowodowane warstwową budową układów izolacyjnych, stosowaną powszechnie w tego typu izolacjach. Polega ona na występowaniu szeregowych uwarstwień dielektryka ciekłego i stałego [18, 26].

Najczęściej WNZ powierzchniowe generowane są w obszarze styku elektrody z powierzchnią dielektryka stałego i dielektrykiem ciekłym. Obszar ten nazywany jest punktem potrójnym. Warunki, jakie są konieczne do zapoczątkowania WNZ w punkcie potrójnym to przekroczenie krytycznego natężenia pola, obecność w tym obszarze elektronów swobodnych i powstanie wystarczającej liczby elektronów pierwotnych [26, 27].

Istotną rolę w mechanizmie generacji WNZ powierzchniowych odgrywa gromadzący się w pobliżu elektrod ładunek przestrzenny. Powstaje on na skutek jonizacji towarzyszącej tym wyładowaniom i wytwarza własne pole, które nakłada się na pole wywołane napięciem przyłożonym do układu [3, 6, 7].


Mechanizm generacji WNZ powierzchniowych i towarzyszącego im ładunku przestrzennego można przybliżyć w za pomocą uproszczonego schematu zastępczego przedstawionego na rys. 3.1 [3, 18].



Rys. 3.1. Schemat zastępczy dielektryka dla WNZ powierzchniowego, gdzie: R_p – rezystancje szeregowo, C – rozłożone pojemności skośne, C_1 - rozłożone pojemności powierzchniowe, C_3 - pojemność pozostałej części układu [3, 18].

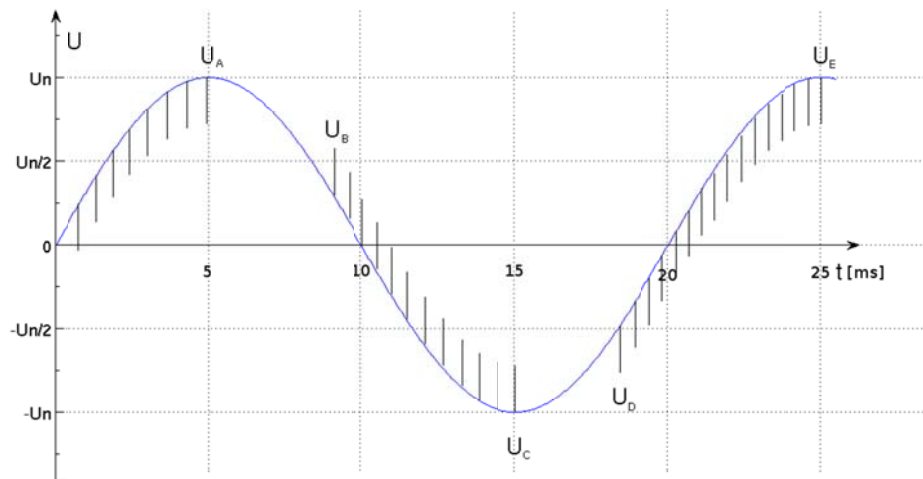
W opisywanym przypadku wartość napięcia przyłożonego do rozpatrywanego układu wzrasta znacznie szybciej niż napięcie, do którego ładowane są pojemności C . Wynika to z faktu, że pojemności C ładowane są przez rezystancje R_p , a pojemności C_1 są wielokrotnie mniejsze od pojemności C . W takiej sytuacji, na rezystancji R_p występują spadki napięcia wystarczające do wywołania jonizacji powierzchniowej. Pod jej wpływem dochodzi do wyładowań wzdłuż powierzchni dielektryka. Stąd wynika, że przebieg wyładowań uwarunkowany jest również wielkością rezystywności powierzchniowej dielektryka [18, 3].

W konsekwencji zasilania takiego układu napięciem sinusoidalnie zmiennym, następuje generowanie WNZ powierzchniowych zarówno podczas narastania napięcia zasilającego, jak i podczas jego spadku, a także przy jego przejściu przez zero (rys. 3.3). Pole elektryczne przy elektrodzie, gdzie rozpoczynają się wyładowania, jest wypadkową pól wywołanych przyłożonym napięciem i ładunkiem przestrzennym (rys. 3.2) [3, 18].



Rys. 3.2. Struktura ładunku przestrzennego podczas inicjacji WNZ powierzchniowych, gdzie: 1 - dodatni ładunek powierzchniowy, 2 - elektrody, 3 - dielektryk stały, 4 - ujemny ładunek [3, 18]

Struktura ładunku przestrzennego zobrażowana na rys. 3.2 ulega zmianie pod wpływem przyłożonego napięcia. Ładunki dodatnie gromadzą się podczas wyładowań w przedziale zmian napięcia od 0 do U_A (Rys. 3.3), w kolejnym przedziale tj. od U_A do U_B nie mogą przepłynąć z powrotem do elektrody, ponieważ ma ona potencjał wyższy lub niewystarczająco niższy od potencjału ładunku przestrzennego. Gdy wartość potencjału elektrody spadnie do wartości U_B , to natężenie pola wywołane przez ładunek przestrzenny jest dostatecznie duże, do ponownej inicjacji wyładowań co prowadzi do całkowitej neutralizacji ładunku zgromadzonego w pobliżu elektrody. Następnie rozpoczyna się proces ponownego gromadzenia ładunku przestrzennego, ale o przeciwnym znaku. Zjawiska te zachodzą w przedziale od U_B do U_C . Tak, więc ładunek przestrzenny powstały w jednym półokresie, podtrzymuje wyładowanie w drugim półokresie. Ten rodzaj wyładowań nazywany jest wyładowaniami podtrzymywanymi. Wynika stąd, że WNZ powierzchniowe generowane przy napięciu sinusoidalnym o częstotliwości 50 Hz mogą być wyładowaniami podtrzymywanymi [3, 18].



Rys. 3.3 Przebieg generacji WNZ powierzchniowych w zależności do fazy przyłożonego napięcia zasilającego [3, 18].



Wyładowania podtrzymywane nie zachodzą przy okresowych napięciach impulsowych, jeżeli czas między dwoma kolejnymi cyklami przyłożonego napięcia jest odpowiednio długi. W takim przypadku istnieją warunki do tego aby ładunek przestrzenny mógł rozpląnąć się wzdłuż powierzchni dielektryka. Ten rodzaj wyładowań nazywany jest wyładowaniami przejściowymi [3].

3.6. Mostkowy mechanizm przebicia izolacji

Do czwartej grupy defektów izolacji zalicza się wyładowania wywołane obecnością w oleju elektroizolacyjnym cząstek o nieokreślonym potencjale. Ta grupa WNZ jest reprezentowana przez iskiernik wieloostre-płyta ze swobodnie przemieszczającymi się cząstkami stałymi w oleju izolacyjnym.

Obecność cząstek o nieokreślonym potencjale w oleju elektroizolacyjnym ma zasadniczy wpływ na jego wytrzymałość elektryczną. Cząstkami tymi mogą być fragmenty włókien celulozy, opiłki metalu, krople wody, drobiny tlenku żelaza, a także inne cząstki stałe.

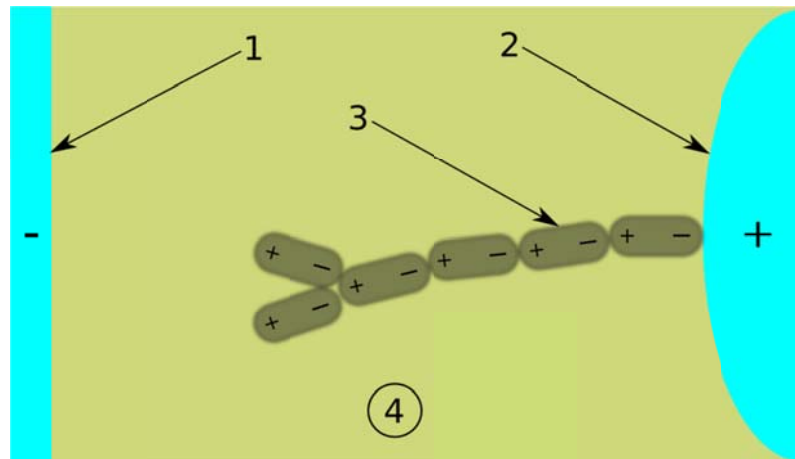
Oleje dostarczane z rafinerii posiadają bardzo wysoki stopień czystości, są pozbawione cząstek stałych, zawiesin i wilgoci [6, 28, 104]. Ponadto zakłady, w których produkuje się i naprawia urządzenia elektroenergetyczne, są zobowiązane do kontroli jakości oleju i w razie konieczności przeprowadzają jego uzdatnianie. W zależności od rodzaju i stopnia zanieczyszczenia, może ono polegać na odwirowaniu, filtracji lub suszeniu [6, 7]. Jednakże w oleju izolacyjnym urządzeń elektroenergetycznych, znajdujących się w eksploatacji, mogą występować zanieczyszczenia, powstałe w wyniku procesu degradacji.

Obecność cząstek zanieczyszczeń może wpływać na rozkład natężenie pola elektrycznego, jaki występuje w pobliżu elementów, do których przyłożone jest napięcie. Tego typu zaburzenie może okazać się wystarczające do zapoczątkowania wyładowań elektrycznych w oleju. Jest to uzależnione od wymiarów, kształtu, koncentracji, konduktywności i przenikalności elektrycznej tych cząstek. Kształt elementów, do których przyłożone jest napięcie i odległość między nimi, determinują gęstość ładunków swobodnych, osadzających się na



ich powierzchniach. Cząstki zanieczyszczeń znajdujące się w ich sąsiedztwie, ładują się poprzez kontakt z tymi elementami lub przez absorpcję jonów bezpośrednio z oleju. Powstałe w ten sposób cząstki, które nie są elektrycznie obojętne, przemieszczają się zgodnie z kierunkiem pola elektrycznego [3, 7, 11].

Cząstki elektrycznie obojętne wykonują bardziej skomplikowany ruch, posiadają one naturalną skłonność do łączenia się w grupy, co prowadzi do powstawania zawiesin. Cząstki zawiesin o przenikalności elektrycznej większej niż przenikalność oleju przemieszczają się do obszarów o największym natężeniu pola, natomiast cząstki o mniejszej przenikalności, w tym pęcherzyki gazowe, są z nich wypierane. Prawidłowość tą nazywa się zjawiskiem dielektroforezy. Koncentrowanie się obcych wtrącin w przestrzeni międzyelektrodowej i tworzenie łańcuchów cząstek naładowanych lub spolaryzowanych, uwzględnia mostkowa teoria przebicia. Zakłada ona, że w silnie zanieczyszczonych olejach istnieje możliwość tworzenia się mostków zanieczyszczeń, w strefach o największym natężeniu pola elektrycznego (Rys. 4.3). Mostkowy mechanizm przebicia w oleju występuje jedynie gdy zachodzą łącznie następujące warunki: odstęp między elektrodami jest niewielki oraz napięcie przyłożone do elektrod jest napięciem wolnozmiennym lub stałym. W tym rozumieniu napięcie o częstotliwości 50 Hz można zaliczyć do wolnozmiennych. Do koncentracji cząstek i utworzenia mostków nie dochodzi przy krótkotrwałym oddziaływaniu pola elektrycznego. Wzrost przenikalności elektrycznej i przewodności zanieczyszczeń sprzyja rozwojowi mostków. Mechanizm ten jest najczęściej spowodowany wzrostem zawilgocenia oleju [7].



Rys. 3.4. Mostkowy mechanizm przebicia, gdzie: 1 – elektroda ujemna np. ściana kadzi urządzenia, 2 - elektroda dodatnia, 3 – spolaryzowane cząsteczki, 4 – olej elektroizolacyjny.

Pomimo tego że mostek jest zbudowany z cząstek o niskiej przewodności to i tak posiadają one niższą impedancję niż olej je otaczający. W konsekwencji dochodzi do przepływu prądu elektrycznego przez mostek, co prowadzi do jego nagrzania. Źródłem ciepła mostka może być również oddziaływanie pola elektrycznego o dużej wartości, jakie występuje przed czołem mostka [18].

Kryterium przebicia dielektryka ciekłego w mechanizmie mostkowym, zakłada że występuje siła, z którą pole elektryczne oddziałuje na cząstkę zanieczyszczeń i jest ona większa od siły przeciwdziałającej przemieszczaniu się tej cząstki, powodowanej oporem i dyfuzją cieczy. W takich warunkach, zapewniony jest wzrost koncentracji cząsteczek, w miejscu występowania największych naprężeń pola elektrycznego. Naprężenie krytyczne pola elektrycznego, dla spolaryzowanych cząstek kulistych, można wyrazić wzorem (3.6) [7].

$$E_{kr} = \frac{2\sigma}{3r} \quad (3.6)$$

gdzie: E_{kr} - naprężenie krytyczne pola elektrycznego, dla spolaryzowanej cząstki kulistej, r - promień cząstek, σ - przenikalność elektryczna cząstek, ϵ_0 -



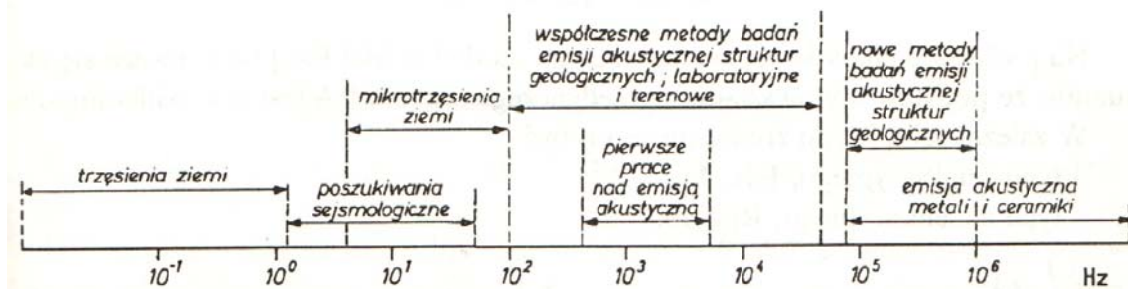
elektrodą, które z kolei może zapoczątkować przebicie ciekłego dielektryka [3, 18].

Należy również zauważyć, że opiłki żelaza są ferromagnetykami. Może więc zaistnieć sytuacja, w której prąd przepływający w uzwojeniach urządzenia elektroenergetycznego, wywoła pole magnetyczne zdolne do przyciągnięcia do tych uzwojeń opiłków żelaza. To z kolei może zapoczątkować tworzenie się mostka zanieczyszczeń [3, 18].

4. Charakterystyka metody emisji akustycznej oceny wyładowań niezupełnych

4.1. Zjawisko emisji akustycznej

Wielu zjawiskom fizycznym towarzyszy generacja fal akustycznych. Badanie zjawiska fizycznego przez analizę towarzyszącej mu EA, należy do badań pośrednich, ponieważ nie obserwuje się bezpośrednio samego zjawiska, natomiast analizuje się skutki wywołane jego przebiegiem. Taka metodyka prowadzenia badań jest jedną z najstarszych i najbardziej intuicyjnych form obserwowania rzeczywistości. W ogólnym ujęciu pojęcie EA jest bardzo szerokie i obejmuje wszystkie zjawiska akustyczne związane np. z trzęsieniem ziemi, czy z działaniem ruchomych części mechanicznych maszyn i urządzeń. Zakresy częstotliwości EA towarzyszącej procesom fizycznym został przedstawiony na rys. 4.1 [35].



Rys. 4.1 Zakres częstotliwości badań EA [35].

W zależności od przebiegu procesu zachodzącego w źródle sygnału, EA może mieć charakter ciągły lub dyskretny. EA ciągła to taka, w której czas trwania sygnału, jest większy od odstępu czasu między impulsami. Natomiast EA dyskretna to taka, w której czas odstępu między impulsami jest większy lub równy czasowi ich trwania. Według Autorów publikacji [35] EA wywołana defektami sieci krystalicznej, WNZ, przebudową mikrostruktury ciała stałego ma charakter ciągły a powstanie i rozprzestrzenianie się mikropęknięć i makropęknięć daje EA dyskretną [35].



4.1.1. Geneza prac nad metodą emisji akustycznej


Prace dotyczące zastosowania metody EA do oceny stanu izolacji papierowo-olejowej urządzeń elektroenergetycznych, były prowadzone od połowy lat siedemdziesiątych [2]. Ich genezę stanowiły trudności metrologiczne, jakie związane są z pomiarami WNZ wykonywanymi metodą elektryczną, w warunkach przemysłowych podczas normalnej pracy urządzeń elektroenergetycznych. Podstawowym problemem są zakłócenia pochodzące od silnych pól elektromagnetycznych emitowanych przez badane obiekty elektroenergetyczne. W chwili obecnej, ze względu na rozwój techniki, dokonywanie pomiarów metodą elektryczną, na obiektach pracujących w energetyce zawodowej, jest możliwe, ale nadal stanowi złożone zagadnienie metrologiczne [29].

Informacja o występowaniu i intensywności WNZ ma kluczowe znaczenie przy ocenie stanu izolacji badanych urządzeń elektroenergetycznych, a w konsekwencji decyduje o prognozie ich dalszej pracy. Metoda EA może być stosowana do detekcji, określenia poziomu intensywności i lokalizacji obszarów generacji WNZ, podczas normalnej eksploatacji mierzonej izolacji [1, 2, 29].

4.1.2. Charakterystyka sygnałów generowanych przez wyładowania niezupełne


W przypadku, gdy WNZ są generowane w ośrodku jednorodnym, a odległość obserwacji zjawiska jest wielokrotnie większa od wymiarów jego źródła i długość emitowanej fali EA jest podwielokrotnością odległości obserwacji, to WNZ można traktować jako punktowe źródło zaburzeń. Wówczas emitowana przez WNZ EA rozchodzi się w ośrodku w postaci fali sferycznej. W konsekwencji zmienne stanu w równaniu falowym opisującym to zjawisko są funkcjami czasu i odległości od punktu wystąpienia WNZ. Natomiast amplituda jest odwrotnie proporcjonalna do odległości od źródła, tym samym natężenie fali EA jest odwrotnie proporcjonalne do kwadratu tej odległości [2].

W przypadku obiektów rzeczywistych idealizacja zjawiska generacji EA do pojedynczego WNZ, rozpatrywanego jako wyładowanie punktowe, nie jest uzasadniona (Rys. 4.2). Znacznie częściej występują WNZ wielokrotnie i wieloźródłowe, wtedy zjawisko to nie dotyczy tylko jednego punktu lecz pewnego obszaru dielektryka.



Rys. 4.2. Schemat generacji impulsu EA przez pojedyncze WNZ, gdzie: i – prąd WNZ, p – ciśnienie generowanej fali akustycznej, WN – wysokie napięcie. Opracowanie własne na podstawie [2, 33].

W konsekwencji zamiast dyskretnej emisji pojedynczych impulsów EA, następuje grupowa emisja impulsów EA lub wprost ciągła, gdzie poszczególne sygnały EA nakładają się na siebie wzajemnie. Natomiast sygnał akustyczny, jaki propaguje w rozpatrywanej izolacji, jest ich superpozycją. Poglądowy przebieg takiego procesu został przedstawiony na rys. 4.3 [2, 3, 79].



Rys. 4.3. Poglądowe przedstawienie generacji EA przez wielopunktowe WNZ, i – prąd pojedynczego WNZ, p – wypadkowe ciśnienie generowanej fali akustycznej [2, 3].

Przedstawione na rys. 4.2 i rys. 4.3 mechanizmy generacji dyskretnej i ciągłej, odnoszą się odpowiednio do punktowego oraz wieloźródłowego występowania WNZ. Parametry sygnału EA pochodzącego od tych źródeł mogą być zróżnicowane, w zależności od przestrzeni propagacji i usytuowania punktu pomiarowego EA.

4.1.3. Modele opisujące sygnały emisji akustycznej generowanej przez wyładowania niezupełne

W chwili wystąpienia WNZ dochodzi do impulsowej przemiany energii elektrycznej w inne jej postacie, następuje: emisja fali elektromagnetycznej, lokalny wzrost temperatury i związane z nim chemiczne przemiany izolacji, emisja promieniowania świetlnego oraz udarowe odkształcenie sprężyste wraz z towarzyszącą mu generacją fal akustycznych. Trudno jest dokładnie określić, jaka ilość energii elektrycznej ulega przekształceniu na energię mechaniczną, ale można ją oszacować na poziomie od 1% do 5%. Nie istnieje możliwość zdefiniowania funkcji, która w sposób jednoznaczny opisywałaby przemianę



jednej postaci energii w inną. Parametry tej przemiany zależą od czynników takich jak: prędkość przemiany energii elektrycznej w mechaniczną, wielkość i typ WNZ, a także rodzaj dielektryka. W zależności od tych parametrów wygenerowane impulsy EA mają różną amplitudę i czas trwania. Teoretyczny opis zjawiska generacji sygnałów EA od WNZ jest niemożliwy ze względu na bardzo dużą złożoność tego procesu i jego stochastyczny charakter [3]. W związku z tym podjęto próby opracowania modeli opisujących procesy generacji EA [19, 30, 31, 37]. Model podany przez Pollack-a jest najprostszym z zaproponowanych, przybliża on WNZ do układu drgających sprężyn. Frederick i Felbeck zaproponowali model oparty na pobudzeniu dyslokacji. Engel opracował model pobudzenia do drgań sieci krystalicznej, przez grupę dyslokacji. Modele te odnoszą się głównie do generacji EA w ośrodkach kruchych lub półkruchych, jak na przykład żywica epoksydowa. Tymczasem techniczne układy izolacyjne są najczęściej układami złożonymi np. izolacja papierowo-olejowa lub gazowa [1, 2, 3].

Dr Daria Wotzka zaproponowała dwa modele matematyczne, które odwzorowują obwiednie sygnałów EA, generowanych przez wybrane formy WNZ, a także jeden model matematyczny opisujący źródło sygnału EA. Pierwszy z zaproponowanych modeli obwiedni to funkcja regresji typu hiperboliczno-wykładniczego (TH), którą można opisać wzorem (4.1) [37].

$$\text{---} \tag{4.1}$$

!

gdzie: - aproksymata funkcji regresji typu TH, - czas, i - estymaty parametrów strukturalnych – amplituda, - estymaty parametrów strukturalnych – skala, - estymaty parametrów strukturalnych – lokalizacja.

Kolejny z zaproponowanych modeli obwiedni, to model funkcji regresji typu sigmoidalno-wykładniczego (SW), który jest opisany wzorem (4.2) [37].

$$\text{---} \tag{4.2}$$



gdzie: \hat{y}_i - aproksymata funkcji regresji typu SW, t - czas, \hat{a}_i - estymaty parametrów strukturalnych – amplituda, \hat{b}_i - estymata parametru strukturalnego – narastanie, \hat{c}_i - estymaty parametrów strukturalnych – skala, \hat{d}_i - estymaty parametrów strukturalnych – lokalizacja.

Jako model matematyczny fali EA generowanej przez pojedyncze WNZ została zaproponowana kombinacja krzywej sigmoidalnej opisującej kształt czoła fali EA, krzywej wykładniczej opisującej tłumienie i krzywej cosinusoidalnej, która określa częstotliwość (4.3) [37].

$$\hat{y}_i = \hat{a}_i \left[\frac{1}{1 + \exp(-\hat{b}_i(t - \hat{d}_i))} \right] \exp(-\hat{c}_i(t - \hat{d}_i)) \cos(2\pi \hat{d}_i(t - \hat{d}_i)) \quad (4.3)$$

gdzie: \hat{a}_i – amplituda, \hat{b}_i – współczynnik narastania krzywej sigmoidalnej, \hat{c}_i – współczynnik skali krzywej sigmoidalnej, \hat{d}_i – współczynnik skali krzywej wykładniczej, \hat{d}_i – częstotliwość \hat{d}_i - współczynniki lokalizacji.

Opracowując model matematyczny źródła sygnału EA dr Daria Wotzka przyjęła, że sygnał EA od WNZ składa się z pojedynczych impulsów zdefiniowanych za pomocą równania (4.3), przy czym każdy z nich posiada różne wartości podstawowych parametrów takich jak: częstotliwość, przesunięcie w czasie i amplitudę. Można zatem wykorzystać zasadę superpozycji i zsumować poszczególne impulsy w jeden sygnał, co zapisano za pomocą wyrażenia (4.4) [37].

$$\hat{y}_i = \sum_{k=1}^N \hat{a}_{ik} \left[\frac{1}{1 + \exp(-\hat{b}_{ik}(t - \hat{d}_{ik}))} \right] \exp(-\hat{c}_{ik}(t - \hat{d}_{ik})) \cos(2\pi \hat{d}_{ik}(t - \hat{d}_{ik})) \quad (4.4)$$

gdzie: N – liczba pojedynczych impulsów, które składają się na sygnał EA, \hat{a}_{ik} – amplituda składowej sigmoidalnej, \hat{a}_{ik} – amplituda składowej cosinusoidalnej, \hat{b}_{ik} – współczynnik narastania składowej sigmoidalnej, \hat{c}_{ik} – współczynnik skali składowej sigmoidalnej, \hat{c}_{ik} – współczynnik skali składowej wykładniczej, \hat{d}_{ik} – częstotliwość składowej cosinusoidalnej \hat{d}_{ik} – współczynniki lokalizacji.



Bazując na wynikach analizy porównawczej Autorka pozycji [37] stwierdza że, na podstawie wyznaczonych wartości współczynników determinacji, model typu sigmoidalno-wykładniczego (SW) osiąga średnio najwyższy wskaźnik dopasowania wartości estymowanych do wartości empirycznych, a ponadto, że, możliwe jest zdefiniowanie modelu matematycznego źródła fal EA generowanej przez wybrane klasy WNZ i określenie jego parametrów w taki sposób, aby odpowiadał on rzeczywistym sygnałom EA od WNZ rejestrowanym podczas pomiarów laboratoryjnych.

4.2. Deskrytory wykorzystywane do identyfikacji podstawowych form wyładowań niezupełnych mierzonych metodą emisji akustycznej

Istnieje wiele różnych deskryptorów, które mogą być wykorzystane do opisu sygnałów EA generowanej przez WNZ, jednakże metrologiczny sens posiada jedynie około dwudziestu z nich [11, 34, 35, 36]. Ponadto dokonując doboru deskryptorów charakteryzujących sygnały EA od WNZ należy brać pod uwagę nie tylko możliwości formalne, ale również sens fizyczny danego deskryptora i jego możliwy związek ze stopniem degradacji badanej izolacji, a także możliwości metrologiczne. Z doniesień literaturowych wynika, że do deskryptorów w oparciu, o które można dokonywać identyfikacji i klasyfikacji podstawowych form WNZ, należą deskryptory określone w dziedzinie częstotliwości lub w dziedzinie czasowo-częstotliwościowej, a także wskaźniki statystyk opisowych i wyniki analizy falkowej [9, 10, 11, 12, 34].

4.2.1. Deskrytory charakteryzujące sygnały emisji akustycznej od wyładowań niezupełnych w dziedzinie czasu


Do podstawowych deskryptorów charakteryzujących intensywność występowania WNZ w dziedzinie czasu należą:

- **Maksymalna amplituda sygnału**

Maksymalna amplituda sygnału jest rozumiana jako największa amplituda pojedynczego sygnału w danym cyklu pomiarowym, lub jako maksymalna amplituda ciągu sygnałów przypadających na dany cykl pomiarowy [2, 79].

- **Suma EA**


Suma EA (ΣEA) określa liczbę kolejnych amplitud EA, które przekroczyły zadany próg dyskryminacji (PD), w określonym przedziale czasowym [2, 3, 79]. Sposób jego wyznaczania przedstawiono poglądowo rys. 4.4.



Rys. 4.4. Poglądowe przedstawienie sposobu zliczania sumy amplitud EA generowanej przez WNZ, gdzie: t - czas, A – amplituda sygnału EA, PD – próg dyskryminacji, ΣEA – suma amplitud EA [2, 79].

- **Tempo EA**

Tempo EA ($EA/\Delta t$) jest liczbą amplitud EA, które przekroczyły zadany próg dyskryminacji, w danej jednostce czasu. Na rys. 4.5 przedstawiono poglądowo sposób określania tempa EA.






Rys. 4.5. Poglądowe przedstawienie sposobu określania tempa EA, generowanej przez WNZ, gdzie: t - czas, A - amplituda sygnału EA, PD – próg dyskryminacji, $EA/\Delta t$ – tempo EA [2, 79].

- **Suma zdarzeń akustycznych**


Suma zdarzeń akustycznych (ΣN) określa liczbę kolejnych obwiedni sygnałów akustycznych, które w określonym przedziale czasowym, przekroczyły zadany próg dyskryminacji (PD). Sposób określania sumy zdarzeń akustycznych przedstawiono poglądowo na rys. 4.6.



Rys. 4.6. Poglądowe przedstawienie sposobu zliczania sumy zdarzeń akustycznych, generowanych przez WNZ, gdzie: t – czas, A – amplituda sygnału EA, PD – próg dyskryminacji, ΣN – suma zdarzeń akustycznych [2, 79].

- **Tempo zdarzeń akustycznych**

Tempo zdarzeń akustycznych ($N/\Delta t$), jest liczbą obwiedni sygnałów akustycznych, które przekroczyły zadany próg dyskryminacji, w danej jednostce czasu. Sposób wyznaczania tego deskryptora przedstawiono poglądowo na rys. 4.7.



Rys. 4.7. Poglądowe przedstawienie sposobu określania tempa zdarzeń akustycznych, generowanych przez WNZ, gdzie: t – czas, A – amplituda sygnału EA, PD – próg dyskryminacji, $N/\Delta t$ – tempo zdarzeń akustycznych [2, 79].

- **Wartość skuteczna sygnału elektrycznego**

Wartość skuteczna sygnału elektrycznego, mierzonego na wyjściu przetwornika mechoelektrycznego A_{RMS} , jest definiowana jako pierwiastek ze średniej kwadratów chwilowej wartości sygnału elektrycznego, uzyskanego w skutek przetworzenia przez przetwornik mechoelektryczny sygnału EA, generowanego przez WNZ (4.5) [2].

(4.5)

gdzie: – wartość skuteczna sygnału elektrycznego na wyjściu przetwornika mechoelektrycznego, – przebieg czasowy sygnału napięciowego na wyjściu z przetwornika mechoelektrycznego przetworzonego z sygnału akustycznego, – rozpatrywany przedział czasowy [2].

Wartość skuteczna, A_{RMS} stanowi jakościowy miernik sygnałów EA i można go traktować jako uzewnętrznienie aktywności akustycznej badanego procesu generacji WNZ. Dzieje się tak ponieważ jego wartość nie zależy od szumów wprowadzonych przez wykorzystywaną aparaturę pomiarową, możliwe jest całkowite ich wyeliminowanie z rozważanego wskaźnika. Jest to realizowane przez ustalenie zerowego poziomu parametru A_{RMS} , dla średniego poziomu



szumów własnych stosowanej aparatury, a następnie odjęcie go od uzyskanych wyników pomiarów [2].

Zaprezentowane deskryptory stanowią podstawę w ocenie intensywności WNZ mierzonych metodą EA, natomiast nie są wykorzystywane do identyfikacji ich form.

4.2.2. Deskryptory charakteryzujące sygnały emisji akustycznej od wyładowań niezupełnych w dziedzinie częstotliwości

Szybka transformata Fouriera (ang. *Fast Fourier Transform* FFT) umożliwia przekształcenie sygnałów zarejestrowanych w dziedzinie czasu do dziedziny częstotliwości. FFT ma zastosowanie do danych w formie dyskretnej i pochodzi od przekształcenia Fouriera (ang. *Fourier Transform* FT) odnoszącego się do sygnału występującego w formie ciągłej, który można oznaczyć jako $x(t)$, wówczas transformata Fouriera ma postać (4.6).

(4.6)

gdzie: $X(f)$ – transformata Fouriera, $x(t)$ – sygnał określony w dziedzinie czasu, f – pulsacja, t – czas [38, 41, 107].

W celu wyznaczenia wartości $X(f)$ sygnał nieokresowy jest traktowany jako szczególny przypadek sygnału okresowego o okresie nieskończonym to znaczy $T \rightarrow \infty$. Nieskończony przedział całkowania, przyjęty podczas wyznaczania wartości $X(f)$ skutkuje wyznaczeniem widma ciągłego. Warunkiem koniecznym, wystarczającym i potwierdzającym prawdziwość wzoru 4.6 jest ograniczona wartość energii przenoszona przez sygnał $x(t)$ dla skończonego przedziału czasowego, co wyraża się przez całkowalność sygnału podniesionego do kwadratu (4.7) [38, 41, 107].

(4.7)



Rozprawa doktorska: „Zastosowanie algorytmu multikomparacyjnego do klasyfikacji sygnałów emisji akustycznej generowanych przez wyładowania niezupełne”

Transformata nazywana jest również widmem amplitudowo-fazowym lub widmem zespolonym. Nazwy te mają swoje odzwierciedlenia w przypadku przedstawienia FT jako funkcji wykładniczej za pomocą wyrażenia (4.8) [41, 43].

(4.8)



Biegun rzeczywisty funkcji widmowej nazywa się, widmem gęstości amplitudy (4.9), natomiast biegun urojony nosi miano widma fazowego (4.10).

(4.9)

(4.10)

Widmo gęstości amplitudy, nazywane także widmem amplitudowym, reprezentuje zależność modułu od pulsacji, a widmo fazowe opisuje zmienność kąta fazowego kolejnych harmonicznych w funkcji pulsacji [39, 40, 41]. Do celów analizy sygnałów EA generowanych przez WNZ wykorzystuje się obecnie widmo amplitudowe, ponieważ zawiera informacje umożliwiające jednoznaczne zidentyfikowanie sygnałów EA od podstawowych form WNZ [3, 38]. Widmo fazowe jest natomiast jedną z wielkości opisujących, szeroko stosowanych w teorii sygnałów, jednakże dotychczas nie znalazło ono zastosowania w identyfikacji i klasyfikacji WNZ mierzonych metodą EA [39, 40, 41].

Istotne informacje na temat sygnałów EA generowanej przez WNZ można uzyskać na podstawie widma gęstości energii. Energia sygnału jest równa kwadratowi modułu jego transformaty i wynosi:

(4.11)

gdzie: – energia sygnału EA, - transformata Fouriera [41, 43].

Przekształcenie (4.11) przyporządkowuje poszczególnym zakresom częstotliwości wielkości energii przez nieprzenoszone. Po uwzględnieniu czasu trwania sygnału można więc je traktować jako rozkład mocy sygnału wzdłuż osi pulsacji.



Obecnie stosowane układy pomiarowe determinują zastosowanie przekształceń dyskretnych, ponieważ sygnały EA są rejestrowane w postaci cyfrowej, co oznacza że sygnał analogowy jest próbkowany a następnie kwantowany, skutkiem czego zostaje zastąpiony funkcją parametru dyskretnego . Do przeprowadzania analizy widmowej sygnałów dyskretnych stosuje się dyskretną transformatę Fouriera (ang. *Discrete Fourier Transform* DFT) (4.12) [3, 11, 41, 43].

$$(4.12)$$

gdzie: n – indeks kolejnej próbki sygnału, czyli czas dyskretny, f_s - częstotliwość próbkowania, T - czas próbkowania, k - indeks kolejnego prążka widma, czyli dyskretna częstotliwość, N – całkowita liczba próbek zbioru, jaki stanowi sygnał [3, 11, 38, 41, 43].

W wyniku procesu dyskretyzacji sygnały, które mu podlegają, zostają ograniczone czasowo. Można więc traktować je jako ciągi danych o skończonej długości złożone z N elementów (4.13) [3, 11, 41, 43].

$$(4.13)$$

Właściwość ta została wykorzystana w przekształceniu DFT, które traktuje sygnał dyskretny jako okresowy, tym samym wartości dyskretnego widma wyznaczone są szeregami o skończonej liczbie składników (4.14) [3, 11, 41, 43].

$$(4.14)$$



W konsekwencji ciąg próbek — składa się z wartości rzeczywistych, natomiast ciąg transformat — przyjmuje wartości zespolone. Uzyskane w ten sposób widmo DFT ma charakter prążków, między którymi znajdują się odstępy. Wartość tych odstępów można wyznaczyć z zależności (4.14) [3, 38, 42, 43] :

$$\text{---} \quad \text{---}$$

(4.14)

DFT posiada wiele aplikacji w postaci kompleksowych procedur numerycznych. Jedną z nich, jest widmo gęstości mocy (ang. *Power Spectrum Density* PSD), które jest między innymi standardowo zaimplementowane w programie Matlab. PSD pozwala na wyznaczenie widma gęstości mocy, dla poszczególnych pasm częstotliwości badanego sygnału, za pomocą DFT, przy zastosowaniu techniki okienkowania, która eliminuje nieciągłości sygnału na granicach jego przedziału rejestracji. W niniejszej pracy, jako jeden z deskryptorów, wykorzystano odpowiednio sparametryzowane przekształcenie PSD.

4.2.3. Deskryptory charakteryzujące sygnały emisji akustycznej od wyładowań niezupełnych w dziedzinie czasowo-częstotliwościowej

Analiza sygnałów EA jedynie w dziedzinie częstotliwości powoduje utratę części informacji przenoszonych przez sygnały. Podczas gdy z punktu widzenia klasyfikacji sygnałów EA generowanych przez WNZ, niezwykle istotne jest określenie, czy EA generowana jest w obu półokresach napięcia zasilającego, czy tylko w jednym. Informację taką można uzyskać poprzez zastosowanie przekształcenia czasowo-częstotliwościowego. Realizacja tego przekształcenia może polegać na zastosowaniu analizy widmowej, nie do całego przedziału czasu, lecz do wybranego jego fragmentu, który jest ograniczony za pomocą okna przemieszczanego w dziedzinie czasu. Zmiana szerokości okna,



powoduje zmianę rozdzielczości przekształcenia w dziedzinie czasu i jednocześnie skutkuje odwrotną co do wartości zmianą rozdzielczości w dziedzinie częstotliwości. Dzieje się tak ponieważ, zgodnie z zasadą nieoznaczoności Heisenberga, istnieje pewna graniczna dokładność, z którą możliwa jest lokalizacja czasowo-częstotliwościowa. Prostokąty zlokalizowane na płaszczyźnie czas-częstotliwość posiadają pewną minimalną powierzchnię, która nie może ulec zmianie w funkcji modyfikacji szerokości okna. Zatem po osiągnięciu przez prostokąty czasowo-częstotliwościowe, powierzchni minimalnej, dalsze zwiększanie rozdzielczości np. w dziedzinie czasu, spowoduje automatycznie zmniejszenie jej w dziedzinie częstotliwości. Przesuwając okno w dziedzinie czasu i częstotliwości uzyskuje się tak zwaną szachownicę dekompozycji [11, 38, 108].

Przekształcenie działające zgodnie z wyżej opisanym algorytmem nazywa się krótkoczasową transformatą Fouriera (ang. *Short Time Fourier Transform* STFT). Cechą STFT, którą należy uznać za wadę, jest jednakowa rozdzielczość dla całego zakresu częstotliwości w ramach badanego przebiegu. Wynika ona z braku możliwości zmiany szerokości okna obserwacyjnego, w odniesieniu do pasma analizowanych częstotliwości. Taka sytuacja jest niekorzystna ponieważ, z punktu widzenia informacji przenoszonej przez sygnał, nie ma potrzeby analizowania z tą samą rozdzielczością składowych częstotliwościowych odpowiadających wysokim harmonicznym i pierwszej harmonicznym. Wada ta stała się przyczyną rozwoju prac związanych z transformatą falkową [44, 45, 46]. Krótkoczasową transformatę Fouriera, w postaci ciągłej, można zapisać za pomocą zależności (4.15).

$$(4.15)$$

gdzie: - krótkoczasowa transformata Fouriera, - funkcja okna analizującego, - przesunięcie czasowe w obszarze okna analizującego, - analizowany sygnał, - częstotliwość, - sprzężenie funkcji zespolonej [44, 46].



STFT w dziedzinie czasu polega na wykonaniu przekształcenia Fouriera na kolejnych fragmentach sygnału, wyznaczonych za pomocą okna . Natomiast, w dziedzinie częstotliwości, STFT jest realizowana jako przekształcenie odwrotne do przekształcenia Fouriera, na fragmentach widma częstotliwościowego, wyznaczonych za pomocą przesuwającego się w tej dziedzinie widma okna analizującego [44, 47]. Wyniki uzyskane przy zastosowaniu STFT w dużym stopniu zależą od rodzaju funkcji okna analizującego Dla sygnałów szybkozmiennych, do jakich można zaliczyć sygnały EA generowane przez WNZ najczęściej stosuje się okno Hamminga, które można opisać za pomocą zależności (4.16) [38, 44]. W niniejszej pracy do celów klasyfikacji podstawowych form WNZ zastosowano okno Hamminga.

-

$$(4.16)$$

Kształt zastosowanego okna musi być dopasowany do analizowanego sygnału. W najprostszej wersji okno może być określone przez funkcję prostokątną lub trójkątną. Istotne jest aby funkcje opisujące okna analizujące nie powodowały znaczącego rozmycia widma, co realizowane jest przez zaokrąglenie ich krańców. Typ zastosowanego okna ma również wpływ na rozdzielczość STFT [44, 47].

Często stosowanym deskryptorem czasowo-częstotliwościowym, zbudowanym w oparciu o STFT jest spektrogram . Wyznacza się go jako kwadrat modułu STFT i dla sygnału zmiennego w funkcji czasu, przyjmuje on postać równania (4.17) [40, 42, 108].



(4.17)

gdzie: $S(f, t)$ – spektrogram, $X(f)$ - krótkoczasowa transformata Fouriera, $w(t)$ - funkcja okna analizującego, τ – przesunięcie czasowe w obszarze okna analizującego, $x(t)$ - analizowany sygnał, f – częstotliwość, Δf – sprzężenie funkcji zespolonej [40, 42, 108].

Spektrogram wykorzystuje się w celu wyznaczenia zmiany gęstości widmowej mocy sygnału w funkcji czasu. Przekształcenie to znalazło szerokie zastosowanie do interpretacji wyników analizy czasowo-częstotliwościowej. Jeżeli badany sygnał występuje w postaci dyskretnej to konieczne jest wyznaczenie spektrogramu w postaci dyskretnej, za pomocą wyrażenia (4.18) [40, 42, 44, 108].

$$S(f, t) = \sum_{k=-\infty}^{\infty} X_k(f) w_k(t) \quad (4.18)$$

gdzie: $X_k(f)$ – dyskretna postać krótkoczasowego przekształcenia Fouriera, t_k – dyskretna wartość czasu, f_k – dyskretna wartość częstotliwości, L – długość sekwencji danych związana z częstotliwością, Δt – fragment sygnału wyznaczony z przebiegu przez okno, Δf – szerokość pasma [40, 42, 44, 108].

Możliwe jest również wyznaczenie spektrogramu amplitudy, oznaczanego jako $A(f, t)$ dla sygnałów w postaci ciągłej i $A_k(f, t_k)$ dla sygnałów w postaci cyfrowej. Jego przebieg charakteryzuje zmiany amplitudy poszczególnych pasm częstotliwości sygnału, w funkcji czasu. Spektrogram amplitudy wyznacza się za pomocą STFT, dla sygnałów zmiennych w funkcji czasu na podstawie zależności (4.19) i sygnałów w postaci cyfrowej na podstawie zależności (4.20) [40, 42, 44, 108].



(4.19)

(4.20)

Dzięki zastosowaniu w przekształceniu STFT okna analizującego przesuwanego w dziedzinie czasu, możliwy jest podział badanego sygnału na odcinki czasowe, które mogą na siebie zachodzić lub być względem siebie rozłączne. Następnie dla poszczególnych odcinków wyznaczana jest transformata Fouriera, a na jej podstawie widmo amplitudowe lub gęstości mocy. Każdemu z odcinków odpowiada moment czasowy lub t i jest on środkiem danego odcinka czasu. W konsekwencji uzyskuje się trójwymiarowy obraz przestrzeni czas-częstotliwość-amplituda lub czas-częstotliwość-gęstość mocy. Obraz ten jest graficznym przedstawieniem widma analizowanego sygnału [38, 44, 47].



5. Możliwości identyfikacji podstawowych form wyładowań niezupełnych

Istnieje szereg algorytmów, które mogą być wykorzystywane do klasyfikacji i identyfikacji podstawowych form WNZ, występujących w izolacji transformatorów elektroenergetycznych. W niniejszym rozdziale zamieszczono przegląd literaturowy publikacji związanych tematycznie z praktycznym zastosowaniem różnego typu algorytmów, do rozpoznawania podstawowych form WNZ i powiązanych z nimi defekami układów izolacyjnych. Algorytmy klasyfikacji można podzielić na kilka grup, w zależności od zastosowanej topologii. Do najczęściej wykorzystywanych, w diagnostyce izolacji urządzeń elektroenergetycznych, można zaliczyć:

- sztuczne sieci neuronowe (SSN),
- metody statystyczne,
- algorytmy neuronowo rozmyte i logikę rozmytą.

5.1. Sztuczne sieci neuronowe

SSN są obecnie jednym z najbardziej popularnych narzędzi wykorzystywanych do klasyfikacji WNZ, niezależnie od zastosowanych metod pomiarowych. Aktualne możliwości zastosowań SSN do klasyfikacji WNZ zostały przedstawione między innymi w publikacjach [90-93].

Publikacja [48] ma charakter przeglądowny, w której przedstawiono sposób wykorzystania SSN, o kilku różnych architekturach, do rozpoznawania WNZ generowanych w układach izolacyjnych i zarejestrowanych metodą elektryczną. Zaproponowane architektury SSN to jednokierunkowe sieci wielowarstwowe lub sieci samoorganizujące się typu Kohonena. Zdaniem Autorów, zaproponowane rozwiązania posiadają dużą skuteczność rozpoznawania WNZ, jednakże ich stochastyczny charakter i mała powtarzalność, mogą prowadzić do obniżenia skuteczności identyfikacji. W artykule dokonano oceny wpływu takich czynników jak: poziom napięcia generacji i wieloźródłowość WNZ na efektywność ich identyfikacji.



Szereg publikacji poświęconych jest problematyce optymalizacji struktury wielowarstwowych sieci perceptronowych [49-56], wykorzystywanych w celu rozpoznawania poszczególnych rodzajów defektów układów izolacyjnych, które powstały w wyniku generacji WNZ, przy zastosowaniu pomiarów wykonywanych metodami elektrycznymi. Badania dotyczyły jedynie jednoźródłowych i jednokrotnych form WNZ. Autorzy wymienionych prac wykazali dużą przydatność SSN do celów klasyfikacji i identyfikacji uszkodzeń powstałych w wyniku generacji WNZ. Dzięki zaproponowanym architekturom uzyskano bardzo wysokie wyniki skuteczności klasyfikacji zamodelowanych defektów izolacji, w niektórych przypadkach nawet stuprocentowe. Jako nierozstrzygnięty pozostaje parametr liczby warstw ukrytych i związania z nimi liczb umieszczonych w nich neuronów.

Ciekawą koncepcją identyfikacji trzech typów defektów układu izolacyjnego wywołanych przez WNZ przedstawiono w publikacji [57]. Rozpoznawanie przeprowadzono przy wykorzystaniu wielowarstwowej SSN, natomiast pomiary wykonywane były metodą elektryczną. WNZ generowane były za pomocą iskierników modelujących wyładowania powierzchniowe w następujących warunkach: w polu jednorodnym w powietrzu, w polu silnie niejednorodnym w powietrzu i w dielektryku stałym z wtrąciną gazową. Autorzy zastosowali współczynniki i rozkładu Weibull'a, współczynnik kurtozy, skrośności oraz wybrane parametry histogramów wyznaczonych przy pomocy analizy fraktalnej, jako parametry charakteryzujące sygnały reprezentujące podstawowe formy WNZ, w celu przeprowadzenia procesu uczenia SSN. Uzyskana średnia wartość skuteczności klasyfikacji wyniosła 95%. Autorzy zaproponowali również optymalizację struktury zastosowanej SSN. Na podstawie przeprowadzonych badań stwierdzono, że najbardziej skuteczna jest struktura zakładająca w poszczególnych warstwach, następującą liczbę neuronów: 6-5-5-4.

Wielowarstwowe jednokierunkowe SSN i sieci o radialnych funkcjach bazowych, wykorzystano do identyfikacji WNZ powierzchniowych, występujących w izolacji papierowo-olejowej [32, 58, 59]. Badano wpływ następujących parametrów: poziom napięcia zasilającego, kształt elektrod zastosowanych w iskiernikach modelujących, na uzyskiwane czynniki



rozpoznawania. Podczas pomiarów zastosowano metodę elektryczną i deskryptory czasowo-częstotliwościowe. Wartości skuteczności identyfikacji WNZ powierzchniowych, w funkcji zmiany parametrów napięcia zasilającego i kształtu elektrod, wynosiła blisko 100%. Potwierdza to wysoką efektywność zastosowanej architektury.


W publikacji [60] autorzy rozpatrywali aspekt korelacji między wzorcami charakteryzującymi Klasy WNZ i rodzajami defektów izolacji, które są nimi powodowane. Celem prowadzonych badań była poprawa skuteczności oceny stanu badanej izolacji. Aby osiągnąć zamierzony cel wykorzystano probabilistyczne sieci neuronowe (PSN)(ang. *Probabilistic Neural Network*). System wnioskujący został opracowany i zbudowany za pomocą dwóch wersji PSN. Uzyskane wnioski sformułowano na podstawie nowatorskiego pomysłu, polegającego na ocenie czternastu unikalnych cech wektora wejściowego. Umożliwiało to podejmowanie dokładnych i wiarygodnych decyzji podczas klasyfikacji stochastycznych i złożonych sygnałów generowanych przez WNZ. Wyeliminowano w ten sposób konieczność wykonywania pomiarów WNZ przez wysoko wykwalifikowanych specjalistów. Oryginalna wersja PSN została zaprojektowana przez Spechta i Romsdahla w 1994. Parametrem tej sieci jest gęstość prawdopodobieństwa. Jest to model oparty na konkurencji uczenia się zgodnie z zasadą „zwycięzca bierze wszystko”. Rozwój PSN opiera się na koncepcji wielowymiarowej oceny prawdopodobieństwa. Klasyfikator oparty na PSN łączy w sobie strategię: Baye zastosowaną w celu podejmowania decyzji i nieparametrycznych estymatorów zastosowanych w celu uzyskania funkcji gęstości prawdopodobieństwa. PSN składają się z warstwy wejściowej, dwóch warstw ukrytych i warstwy wyjściowej. Zastosowanie zaproponowanej metody pozwoliło na uzyskaniu ponad 90% skuteczności klasyfikacji i co istotne, poprawienie skuteczności klasyfikacji względem konwencjonalnych SSN. Autorzy zaproponowali rozszerzenie zastosowania opracowanej przez siebie metody do celów klasyfikacji procesów, w których występuje duża liczba różnorodnych danych wejściowych, a procedura podejmowania decyzji jest złożona [60].



Kompleksowa wiedza na temat możliwości zastosowania SSN do celów identyfikacji i klasyfikacji sygnałów EA generowanej przez WNZ, zawarto w publikacjach pracowników Instytutu Elektroenergetyki Politechniki Opolskiej [12, 13, 14, 61, 62, 63, 64, 65] i rozprawie doktorskiej Sebastiana Boruckiego [38]. Ich Autorzy wykazali, że skuteczna identyfikacja podstawowych form WNZ, oparta na bezpośredniej analizie przebiegów czasowych zarejestrowanych sygnałów EA jest praktycznie niemożliwa. Z tego względu w procesie uczenia i testowania SSN wykorzystane zostały widma częstotliwościowe i spektrogramy. Przy wyznaczeniu widma gęstości mocy, zastosowano okno Hanninga. Autorzy poddali analizie deskryptory charakteryzujące się zróżnicowaną dokładnością wyznaczenia PSD. Była ona zależna od zadanej liczby punktów uśredniających i w cytowanych publikacjach, zawierała się w zakresie od 16 do 1024 punktów. Wyznaczone w ten sposób wektory, były wykorzystywane jako ciągi uczące i ciągi testowe odpowiednio w procesie uczenia i testowania zaproponowanej architektury SSN służącej do identyfikacji podstawowych form WNZ.

Do wyznaczenia spektrogramów wykorzystywano procedurę numeryczną *specgram* w programie Matlab. Pozwala ona na wyznaczanie trójwymiarowych map widmowej gęstości mocy. Autorzy ograniczyli ilość otrzymywanych danych, uzyskiwanych w wyniku zastosowania przekształcenia STFT, poprzez opracowanie wstępnego algorytmu przetwarzania plików pomiarowych. Jego istota polegała na wyodrębnieniu z zarejestrowanego przebiegu czasowego sygnału EA, interwału czasowego obejmującego zdarzenie akustyczne, to jest czas występowania WNZ. Wyznaczony przedział czasowy miał swój początek w miejscu występowania maksymalnej wartości amplitudy EA, a jego długość oznaczona jako dT , wynosiła od 0,05 ms do 2 ms, w zależności od rozważanego przypadku. Wyselekcjonowany w ten sposób przebieg czasowy poddawano przekształceniu STFT, co umożliwiło wyznaczenie trójwymiarowych macierzy. Następnie przekształcano je do jednokolumnowego wektora. Wektory te były wykorzystywane jako ciągi uczące i ciągi testowe w procesie uczenia i testowania zaproponowanej architektury SSN. Autorzy omawianych publikacji, na podstawie przeprowadzonych badań literaturowych, zaproponowali

zastosowanie do rozpoznawania WNZ sieć jednokierunkową wielowarstwową. Przy jej użyciu uzyskano wysokie wartości skuteczności rozpoznawania podstawowych form WNZ, jakie mogą występować w izolacji papierowo-olejowej. Obliczone skuteczności były większe niż w przypadku zastosowania tej struktury do wyników otrzymywanych metodami elektryczną i DGA. Zaproponowana struktura to sieć typu F - F BP (ang. *Feed – Forward Backpropagation Network*), która posiadała trzy warstwy neuronów, a każdy z neuronów miał sigmoidalną funkcję aktywacji (Rys. 5.1).



Rys. 5.1. Struktura wielowarstwowej sieci neuronowej [38].

Zastosowano nadzorowany proces uczenia badanej SSN, tym samym część z plików pomiarowych zarejestrowanych sygnałów EA traktowano jako ciąg uczący, natomiast pozostałą część jako ciąg testowy. Każda forma WNZ była reprezentowana przez 100 plików pomiarowych, z których losowo wybierano pliki wchodzące w skład ciągu uczącego, natomiast pozostałe pliki stanowiły ciąg testowy.

W kolejnym kroku dokonano wyboru algorytmu uczącego, w oparciu o: stabilność i zbieżność procesu uczącego, uzyskiwane skuteczności rozpoznawania sygnałów EA generowanej przez przyjęte formy WNZ oraz długość czasu procesu uczącego. Po przeanalizowaniu sześciu algorytmów uczących, Autorzy zaproponowali algorytm RPROP (ang. *Resilient Backpropagation*).

Przy zastosowaniu: deskryptora częstotliwościowego z 128-ma punktami uśredniającymi PSD, liczby neuronów warstwy ukrytej na poziomie 45 i



rozmiaru ciągu uczącego na poziomie 30 przebiegów. Wartość skuteczności rozpoznawania przez SSN badanych form WNZ wyniosła 92,8%. Najwyższą wartość skuteczności uzyskano przy zastosowaniu rozmiaru ciągu uczącego na poziomie 90 przebiegów, która była równa 97,2%. Całkowity czas potrzeby do sklasyfikowania pojedynczego przebiegu EA, był zależny od liczby neuronów w warstwie ukrytej i wynosił 3 s.

Przy zastosowaniu deskryptora czasowo-częstotliwościowego tj. spektrogramu z szerokością okna czasowego dT równą 0,4 ms, liczby neuronów warstwy ukrytej na poziomie 45 i rozmiaru ciągu uczącego na poziomie 30 przebiegów, wartości skuteczności rozpoznawania przez SSN badanych form WNZ wyniosła 95,3%. Najwyższa wartość omawianej skuteczność została osiągnięta przy zastosowaniu rozmiaru ciągu uczącego na poziomie 80 przebiegów i wyniosła 98,6%. Podobnie jak w poprzednim przypadku, całkowity czas wymagany do sklasyfikowania pojedynczego przebiegu EA, był zależny od liczby neuronów w warstwie ukrytej i wynosił 9 s.


Autorzy cytowanych publikacji wykazali, że zaproponowana przez nich architektura SSN pozwala uzyskać zadowalające skuteczności rozpoznawania sygnałów EA, generowanej przez podstawowe formy WNZ mierzone metodą EA. Rekomendują oni do celu klasyfikacji EA zastosowanie podczas pomiarów diagnostycznych SSN z deskrytorem częstotliwościowym, z uwagi na wymagany relatywnie krótki czas rozpoznawania uszkodzeń układu izolacyjnego. Jednakże wiąże się to ze zmniejszeniem procentowej skuteczności klasyfikacji, w odniesieniu do deskryptora czasowo-częstotliwościowego. Dlatego w przypadku, w którym bardziej istotna jest wysoka wartość otrzymywanej skuteczności, a czas niezbędny do przetworzenia przez SSN wprowadzonych danych ma niższy priorytet, Autorzy proponują zastosowanie deskryptora czasowo-częstotliwościowego tj. spektrogramu o parametrze dT równym 0,4 ms.



5.2. Mechanizmy statystyczne

Coraz częściej stosowanym rozwiązaniem w dziedzinie klasyfikacji sygnałów generowanych przez WNZ są narzędzia statystyczne [91, 100-104]. Ich niewątpliwą zaletą jest duża szybkość działania, w porównaniu do SSN czy struktur neuronowo-rozmytych.

W publikacji [66] przedstawiono możliwości zastosowania analizy regresji, do celów klasyfikacji WNZ, zarejestrowanych metodą elektryczną. Do badanych sygnałów zastosowano opis $fi - q - n$, gdzie: fi – oznacza kąt fazowy impulsu WNZ względem przyłożonego napięcia, n – oznacza liczbę zarejestrowanych impulsów, natomiast q – oznacza ich wysokość. Klasyfikacji podlegały WNZ, generowane w czterech modelowych układach wyładowczych. Miały one odzwierciedlać cztery formy WNZ, mogące występować w izolacji urządzeń elektroenergetycznych. Tym samym zdefiniowano cztery rozpoznawalne Klasy wzorców, które zostały następująco opisane: WNZ koronowe w powietrzu po stronie wysokiego napięcia, WNZ koronowe w powietrzu po stronie niskiego napięcia, WNZ powierzchniowe w powietrzu i WNZ generowane wewnątrz izolacji. Procedura obliczeniowa polegała na przyporządkowaniu badanego sygnału do jednej z czterech rozpoznawalnych Klas wzorców, na podstawie dziewięciu niezależnych zmiennych, zdefiniowanych przez Autorów. Do najważniejszych z nich zaliczono: skośność, kurtozę, asymetrię, korelację wzajemną parametrów $fi - q - n$ wzorców WNZ. Dane wejściowe zostały podzielone na dwie grupy: pierwsza służąca trenowaniu modelu regresji i drugą wykorzystywaną do testowania tego modelu. Zaproponowany przez Autorów algorytm umożliwiał wskazanie, które z badanych niezależnych zmiennych, stanowią optymalne parametry do stworzenia modelu regresji (Rys. 5.2).





Rys. 5.2. Schemat blokowy wielow wejściowego modelu regresji liniowej, gdzie X – czynniki mapujące grupę predyktora, Y – zmienna odpowiedzi [66].

Efektom przeprowadzonych prac było wyselekcjonowanie grupy pięciu parametrów wejściowych, na podstawie których przeprowadzono klasyfikację WNZ, za pomocą modelu regresji, ze skutecznością bliską 100%.

W publikacjach [67, 70, 71] opisano zastosowanie Maszyny Wektorów Nośnych (ang. *Support Vector Machine SVM*), do celów klasyfikacji WNZ, rejestrowanych metodą elektryczną. Do pomiarów sygnałów elektrycznych wykorzystano przetwornik prądu o częstotliwości radiowej (ang. *Radio Frequency Current Transducer RFCT*), którego użyteczne pasmo jest w zakresie 0-200 MHz. Algorytm SVM został zaproponowany przez V.N. Vapnika w 1995 roku i jest mechanizmem opartym na statystycznej teorii uczenia. Nazwa metody związana jest z danymi treningowymi, które nazywane są wektorem wsparcia (ang. *Support Vector*). W ostatnich latach jest on coraz częściej wykorzystywany z powodu szerokiej możliwości implementacji i wysokiej wydajności, w porównaniu do SSN, co potwierdzono empirycznie w publikacji [68]. SVM jest metodą pozwalającą na stworzeniu funkcji w oparciu o zestaw danych treningowych. Powstała w ten sposób funkcja może być zastosowana do klasyfikacji lub do modelu regresji [69]. W omawianym przypadku jako jądro przekształcenia SVM zastosowano gaussowskie radialne funkcje bazowe. Zdefiniowano, a następnie zamodelowano pięć Klas WNZ, w celu przeprowadzenia ich klasyfikacji. Badania dotyczyły następujących form WNZ: koronowych w powietrzu, koronowych w oleju, powierzchniowych w powietrzu, generowanych wewnątrz izolacji olejowej i generowanych wewnątrz izolacji papierowo-olejowej. Zastosowano dwa deskryptory, celem porównania uzyskanych wyników skuteczności klasyfikacji. Przeprowadzone testy dotyczyły deskryptora fazowego bazującego na metodzie $fi - q - n$, deskryptora czasowo-częstotliwościowego, obliczonego przy zastosowaniu dyskretnej transformaty falkowej. Najwyższa skuteczność klasyfikacji, jaką uzyskano dla algorytmu SVM odpowiednio dla deskryptora fazowego wyniosła 99,2%, natomiast dla czasowo-częstotliwościowego była równa 97,6%.



W artykule [72] przedstawiono wyniki analizy porównawczej dwóch metod klasyfikacji, które zastosowano do celu identyfikacji podstawowych form WNZ. Pomiary WNZ wykonano za pomocą metody elektrycznej. Jako urządzenie pomiarowe zastosowano transformator prądu o wysokiej częstotliwości, działający jako czujnik, do monitorowania prądu przepływającego między tuleją metalową umieszczoną na rzeczywistym izolatorze przepustowym, a uziemieniem. Przez izolator przepustowy przepływały impulsy prądowe wywołane WNZ, generowanymi w układzie, który został szerzej opisany w pracy [73]. Autorzy zdefiniowali i zamodelowali cztery następujące Klasy WNZ: powierzchniowe w powietrzu, koronowe w powietrzu, swobodne w oleju oraz wyładowania wewnątrz izolacji olejowej. Klasyfikacji dokonano za pomocą dwóch technik uczenia maszynowego, czyli Maszyny Wektorów Nośnych (ang. *Support Vector Machine* SVM) i probabilistycznych sieci neuronowych (ang. *Probabilistic Neural Network* PNN). Deskryptor obejmował przeprowadzenie analizy falkowej, zarejestrowanych przebiegów czasowych, zawierających sygnały generowane przez zamodelowane formy WNZ. Przy czym długość tego przebiegu, była równa jednemu cyklowi przyłożonego napięcia zasilającego. Następnie, w celu zmniejszenia ilości przetwarzanych danych, w oparciu o uzyskane wyniki, wyznaczono cztery pierwsze momenty funkcji gęstości prawdopodobieństwa to jest: średnią, odchylenie standardowe, skróśność i kurtozę. Uzyskane przez Autorów rezultaty klasyfikacji zestawiono w tabeli 5.1. Dla obu zastosowanych klasyfikatorów, uzyskano bardzo wysokie skuteczności rozpoznawania.

Tab. 5.1. Wyniki skuteczności klasyfikacji [72]

Typ WNZ	Skuteczność Klasyfikacji w %	
	klasyfikator PNN	klasyfikator SVM
Swobodne	91,9	98,6
Koronowe	97,49	100
Wewnętrzne	100	100
Powierzchniowe	99,80	99,39



Razem	97,30	99,5
-------	-------	------

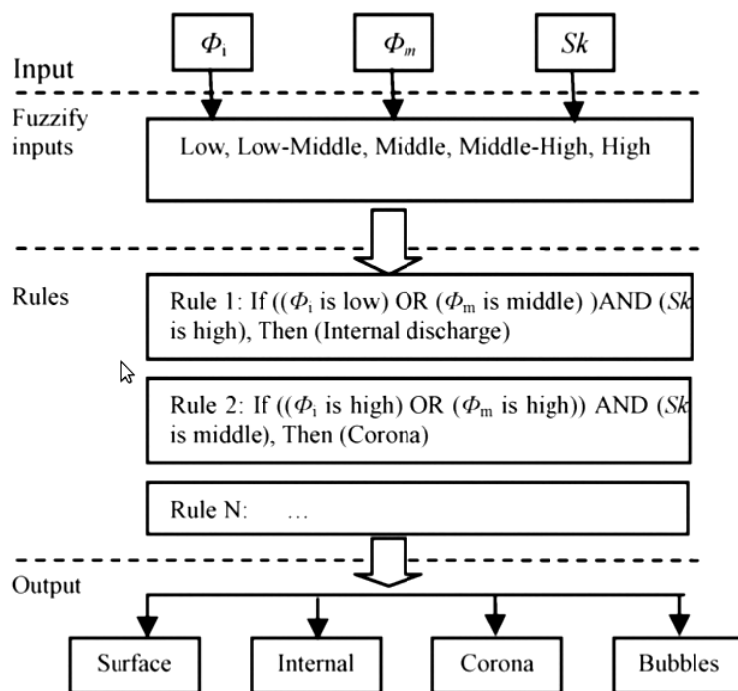
5.3. Algorytmy neuronowo rozmyte i logika rozmyta

Struktury neuronowo-rozmyte, są obecnie bardzo często wykorzystywanym narzędziem do klasyfikacji WNZ [94 - 99]. Dynamiczny rozwój implementacji tych metod do celów rozważanego zagadnienia, jest częściowo związany z udostępnieniem przez firmę MathWorks biblioteki ANFIS, którą wykorzystują w swoich badaniach Autorzy publikacji scharakteryzowanych w tym rozdziale.

W publikacji [74] zaprezentowano wyniki zastosowania logiki rozmytej i statystycznych metod opisu sygnałów, w celu klasyfikacji WNZ występujących w izolacji papierowo-olejowej, które zostały zmierzone metodą elektryczną. Zdefiniowano i zamodelowano w warunkach laboratoryjnych cztery następujące formy WNZ: wyładowania generowane wewnątrz izolacji papierowej, WNZ występujące na powierzchni izolacji papierowej, WNZ koronowe w oleju, WNZ generowane w bąbelkach gazowych przemieszczających się w oleju. Przeprowadzone badania miały na celu stworzenie koncepcji systemu automatycznej identyfikacji wad i defektów izolacji papierowo-olejowej transformatora elektroenergetycznego. W tym celu wykonano statystyczną analizę sygnałów reprezentujących zdefiniowane formy WNZ, które zgromadzono w bazie referencyjnej, dzięki czemu opracowano markery identyfikacji. Autorzy sprawdzili możliwość zastosowania w roli markerów identyfikacji, operatorów statystycznych odnosząc się do kształtu fazy badanych sygnałów. Autorzy przeanalizowali możliwość zastosowania: skrośności, kortuzy i rozkładu Weibulla, natomiast jako operatory fazowe wykorzystano: wskaźnik fazy początkowej (tzn. czy faza początkowa wzorca rozpoczęła się w dodatnim czy ujemnym półokresie) oraz wskaźnik fazy średniej wyładowania. W wyniku przeprowadzonych badań, zastosowano trzy markery, to jest: wskaźnik fazy początkowej, wskaźnik fazy średniej i skrośność.

Na rys. 5.3 przedstawiono zastosowany przez Autorów artykułu [74] system identyfikacji, oparty na logice rozmytej. Na wejściu do systemu podawane są wartości trzech zastosowanych markerów. Następnie przeprowadzono proces

rozmywania, poprzez oszacowanie wartości danego markera w pięciostopniowej skali. W wyniku procesu rozmywania każdemu z markerów zostaje przypisana jedna z wartości: niska, umiarkowanie niska, umiarkowana, umiarkowanie wysoka lub wysoka.



Rys. 5.3. Strukturalny diagram systemu identyfikacji opartego na logice rozmytej [74].

Następnie przeprowadzany jest właściwy proces klasyfikacji, zgodnie z zaimplementowanymi regułami. Dla przykładu dla reguły numer 2 jeżeli: wskaźnik fazy początkowej jest „wysoki” lub wskaźnik fazy średniej jest „umiarkowany” (dwa pierwsze warunki rozpatrywane są łącznie) i skrośność jest „umiarkowana” to badany przebieg zaliczany jest do WNZ typu koronowego.

W opisywanym artykule zaprezentowano również dwie implementacje dla przedstawionego systemu automatycznej identyfikacji WNZ. Pierwszą z nich było zastosowanie systemu do rozpoznawania WNZ generowanych w transformatorze 132 kV / 34,5 kV podczas jego normalnej pracy, w trakcie eksploatacji. Sygnały pochodzące od WNZ były mierzone na izolatorze przepustowym, za pomocą transformatora prądowego wysokiej częstotliwości. Drugą implementacją było zastosowanie systemu do identyfikacji WNZ




generowanych w kablu z izolacją papierowo-olejową, pracującym pod napięciem 220 kV. Do pomiarów WNZ zastosowano transformatory prądowe wysokiej częstotliwości, które umieszczono na głowicach kablowych i cewki Rogowskiego, wykorzystane w celu synchronizacji napięcia sieciowego z sygnałem pochodzącym od WNZ, mierzonym przez transformatory prądowe wysokiej częstotliwości.

Obie przedstawione wyżej implementacje Autorzy zakwalifikowali do bardzo udanych. Wykazali oni, że prezentowany przez nich system pozwala na poprawne rozpoznawanie czterech zdefiniowanych przez nich form WNZ, w warunkach przemysłowych, w środowisku silnych zakłóceń zewnętrznych. Jako kierunek dalszych prac Autorzy wskazują minimalizację błędnych klasyfikacji.

W artykule [75] przedstawiono możliwości zastosowania adaptacyjnego neuronowo-rozmytego systemu wnioskującego (ang. *Adaptive Neuro-Fuzzy Inference System* ANFIS) do klasyfikacji sygnałów elektrycznych generowanych przez WNZ. Proponowany klasyfikator został zastosowany w celu rozpoznawania trzech zamodelowanych w warunkach laboratoryjnych defektów izolacji. Do ich zamodelowania wykorzystano iskierniki, składające się z układu dwóch elektrod płaskich, między którymi umieszczono izolator wykonany w formie płytki. Wewnątrz płytki izolacyjnej znajdowała się pusta przestrzeń, której rozmiar i kształt determinował rodzaj badanego defektu izolacji. WNZ generowane przez poszczególne defekty izolacji mierzone były za pomocą metody elektrycznej. Na podstawie uzyskanych sygnałów wyznaczane były opisujące je parametry statystyczne. W pierwszym etapie badań zastosowano piętnaście parametrów statystycznych charakteryzujących rejestrowane sygnały. Zdeterminowało to strukturę ANFIS, powodując zastosowanie na jej wejściu piętnastu neuronów. W drugiej warstwie Autorzy zaproponowali zastosowanie dziewiętnastu neuronów, dla każdego z neuronów wejściowych. Każdy z zestawu dziewiętnastu neuronów drugiej warstwy reprezentuje jedną z dziewiętnastu funkcji przynależności Gaussa, określonych osobno dla każdego parametru wejściowego. Tym samym liczba neuronów drugiej warstwy wynosiła 285. Trzecia warstwa zawierała dziewiętnaście neuronów

równowartość dziewiętnastu rozmytych reguł typu „jeżeli-to”. W czwartej warstwie umieszczono dziewiętnaście liniowych funkcji przynależności. Piąta warstwa zawierała jeden neuron i stanowiła warstwę wyjściową. Opisywaną strukturę zobrazowano na rys. 5.4.




Rys. 5.4. Strukturalny klasyfikatora ANFIS z 15 neuronami wejściowymi [75].

Opisywana struktura ANFIS pozwoliła uzyskać skuteczność klasyfikacji na poziomie 91,7%. Kolejnym krokiem zaproponowanym przez Autorów była optymalizacja liczby markerów wejściowych, celem zmniejszenia rozmiarów struktury decyzyjnej. Zaproponowano sześć markerów wejściowych, co w zasadniczy sposób zmieniło strukturę decyzyjną. Zmniejszono także liczbę neuronów warstwy drugiej z piętnastu do trzech neuronów dla każdego z wejść. Tym samym liczba wszystkich neuronów warstwy drugiej była równa osiemnaście. Warstwy trzecia i czwarta zachowały swoje funkcjonalności, ale liczba elementów każdej z warstw zmniejszyła się do trzech. Zmodyfikowaną strukturę klasyfikatora AMFIS przedstawiono na rys. 5.5.

Zmodyfikowana struktura ANFIS pozwoliła uzyskać skuteczność klasyfikacji na poziomie 95,8%. Jest to większa wartość niż w przypadku zastosowania piętnastu markerów wejściowych. W podsumowaniu Autorzy stwierdzili, że ANFIS, wraz ze statystycznymi markerami wykorzystanymi do opisu sygnałów,



mogą być z powodzeniem wykorzystywane do klasyfikacji, zdefiniowanych przez nich defektów izolacji.



Rys. 5.5. Strukturalny klasyfikatora ANFIS z 6 neuronami wejściowymi [75].

W artykule [76] przedstawiono wyniki analizy porównanej skuteczności klasyfikacji, sygnałów generowanych przez WNZ, które uzyskano za pomocą trzech metod klasyfikacji tj.: sieci neuronowych uczonych za pomocą algorytmu wstecznej propagacji (ang. *Back Propagation BP*), adaptacyjnego neuronowo-rozmytego systemu wnioskującego (ANFIS) i analizy głównych składowych z liniową dyskryminacją (ang. *Principal Component Analysis–Linear Discriminant Analysis PCA–LDA*). Autorzy zdefiniowali, a następnie zamodelowali pięć defektów izolacji: wyładowania w powietrzu, wyładowania wewnątrz wtrąciny powietrznej w dielektryku, drzewienie elektryczne, drzewienie elektryczne w obecności wtrąciny powietrznej i drzewienie elektryczne w obecności wtrąciny metalowej. Zastosowano standardową elektryczną metodę pomiarową (IEC 270), a na podstawie uzyskanych wyników obliczono rozkłady statystyczne. Następnie zostały one zastosowane jako dane wejściowe do testowanych algorytmów klasyfikacji, w celu wskazania optymalnego algorytmu, który mógłby zostać zastosowany w systemie diagnostycznym działającym on-line. Proces klasyfikacji przeprowadzony dla trzech pierwszy Klas defektów izolacji, niezależnie od zastosowanego



Rozprawa doktorska: „Zastosowanie algorytmu multikomparacyjnego do klasyfikacji sygnałów emisji akustycznej generowanych przez wyładowania niezupełne”

algorytmu, przebiegał bezbłędnie ze 100% skutecznością. Dopiero wprowadzenie dodatkowych dwóch Klas defektów, spowodowało zróżnicowanie otrzymanych wyników klasyfikacji co przedstawiono w tab. 5.2.



Tab. 5.2. Porównanie algorytmów klasyfikacji [76].

Items	Classification scheme		
	BP	ANFIS	PCA-LDA
Base system	Neural network	Fuzzy (FCM) + neural network	Feature extraction and Euclidean distance
Recognition rate (%)	92 %	99 %	96 %
Learning cycles (times)	very long (>1,00times)	just several times	not needed
Parameter number	many	few	few
Simplicity	complex	simple	simplest

Klasyfikatory ANFIS i PCA-LDA wykazują znacząco wyższą skuteczność klasyfikacji od sieci neuronowych. Jednak nadmierna rozbudowa liczby wejść systemu wnioskującego ANFIS, powoduje obniżenie jego skuteczności. Sieci neuronowe charakteryzują się lepszymi możliwościami w procesie uczenia się, ze wszystkich rozważanych systemów, natomiast ich podstawową wadą jest duża liczba parametrów wejściowych i cykli kształcenia. Ponadto wykazują najniższą skuteczność klasyfikacji. Podstawową zaletą klasyfikatora PCA-LDA jest mała liczba parametrów wejściowych. Autorzy stwierdzili, że wybór optymalnego systemu wnioskującego, do celów klasyfikacji WNZ, powinien być podyktowany ilością danych wejściowych oraz rodzajem źródła WNZ.

Podsumowując, SSN są jednym z najlepiej zbadanych narzędzi stosowanych do identyfikacji i klasyfikacji WNZ. Wyniki uzyskiwane przy ich zastosowaniu są w większości przypadków zadowalające. Podobnie struktury neuronowo-rozmyte, cechują się wysoką skutecznością klasyfikacji w odniesieniu do rozważanego zagadnienia. Zastosowanie tych struktur jest uzasadnione wtedy, gdy badane zjawisko można opisać przy użyciu małej liczby markerów wejściowych. Gdy warunek ten jest nie spełniony, znacząco wzrośnie czas niezbędny do przeprowadzenia procesu klasyfikacji.



6. Baza sygnałów emisji akustycznej generowanej przez wyładowania niezupełne

6.1. Opis bazy sygnałów emisji akustycznej

Baza sygnałów EA (zwana dalej bazą danych) generowanej przez WNZ, zawiera dziewięćset przebiegów czasowych. Zarejestrowane sygnały EA, usystematyzowano w dziewięć Klas, z których każda zawiera po sto przebiegów. Sygnały zostały wygenerowane w układach modelujących podstawowe formy WNZ. Szczegółowo scharakteryzowane m.in. w pracach [8, 13, 14, 15, 38]. Baza danych wykorzystana do badań, w oparciu o które powstała niniejsza rozprawa, w ponad 88% została opracowana przez dra Sebastiana Boruckiego i dra Andrzeja Cichonia. Natomiast pozostałe dane stanowią wyniki uzyskane dla WNZ typu ostrze-płyta ze swobodnie przemieszczającymi się pęcherzykami gazowymi, na podstawie pomiarów laboratoryjnych wykonanych przez Autora. Bazę danych wykorzystano podczas symulacji realizowanych w ramach niniejszej rozprawy za zgodą wszystkich Autorów.


W bazie danych zdefiniowano dziewięć form WNZ, które scharakteryzowano w rozdz. 3. Przy czym Klasa 9 została dodatkowo zaproponowana przez Autora i stanowi efekt prowadzonych prac naukowo-badawczych realizowanych w ramach niniejszej rozprawy. Dlatego też pierwszy etap badań, opisanych w niniejszej rozprawie, obejmuje pierwsze osiem Klas.

6.2. Charakterystyka układów generacji podstawowych form wyładowań niezupełnych

Przebiegi czasowe sygnałów EA, które zgromadzono w bazie danych zostały zarejestrowane w układach modelujących podstawowe formy WNZ, jakie mogą występować w izolacji papierowo-olejowej urządzeń elektroenergetycznych. Szczegółowy opis zastosowanych iskierników, które



umożliwiły generację WNZ Klas 1-8, został przedstawiony m.in. w pracach [8, 13, 14, 15, 38]. Sygnały EA zgromadzone w bazie danych zostały wygenerowane za pomocą iskierników modelujących dziewięć zdefiniowanych Klas WNZ, zgodnie z informacjami zawartymi w rozdz. 3.1. Klasa 9 zaproponowana przez Autora niniejszej rozprawy, została usystematyzowana zgodnie z założeniami przyjętymi przez dra Sebastiana Boruckiego w jego rozprawie doktorskiej. Umożliwiło to zapewnienie spójności utworzenia bazy danych. Na rys. 6.1 przedstawiono zdjęcie iskiernika, który został zastosowany do generacji WNZ odpowiadających Klasie 9.



Rys. 6.1. Układ do generacji WNZ ostrze- płyta, ze swobodnie przemieszczającymi się pęcherzykami gazowymi.

Zastosowany układ elektrod to ostrze-płyta gdzie: płyta wykonana została w kształcie walca o średnicy podstawy równej 38 mm i wysokości równej 9 mm. Ostrze posiadało długość 30 mm i średnicę końca równą 0,6 mm. Obie elektrody wykonane zostały z mosiądzu. Odległość między elektrodami, zastosowana podczas generacji WNZ, wyniosła 10 mm. Elektroda płytowa została uziemiona, natomiast do elektrody ostrzowej przyłożono wysokie napięcie. Poniżej iskiernika umieszczono aerator, którego zadaniem była



generacja pęcherzyków gazowych. Gazem dostarczanym do aeratora było powietrze tłoczone za pomocą kompresora, który przedstawiono na rys. 6.2.



Rys. 6.2. Widok kompresora zastosowanego do zasilania aeratora.

Układ wyładowczy został umieszczony w modelu kadzi transformatorowej o wymiarach podstawy 605 mm na 800 mm i wysokości równej 500 mm, którą wypełniono olejem mineralnym. Umieszczenie zaproponowanego iskiernika wewnątrz kadzi zapewniało swobodny przepływ strumienia bąbelków gazu w przestrzeni między elektrodowej. Podczas generacji WNZ olej mineralny miał temperaturę 20°C, był klarowny, a jego średnia wartość skuteczna napięcia przebicia wynosiła około 20 kV na centymetr. Rys. 6.3 przedstawia zastosowany model kadzi wypełnionej olejem elektroizolacyjnym, z zanurzonym w niej układem wyładowczym i transformator probierczy.

Jako źródło wysokiego napięcia zastosowano jednofazowy transformator probierczy typu TP60. Jego przekładnia znamionowa jest zależna od konfiguracji i wynosi 220 V / 60 kV lub 220 V / 30 kV. Podczas przeprowadzonych badań zastosowano konfigurację 220 V / 60 kV. Transformator został połączony z iskiernikiem modelującym WNZ za pomocą opornika wodnego. Sterowanie napięciem probierczym odbywało się za pośrednictwem pulpitu sterowniczego, którego widok został przedstawiony na



rys. 6.4. Umożliwiał on płynną regulację napięcia od zera do napięcia zasilania. Był wyposażony w autotransformator sterowany silnikiem elektrycznym, posiadał zabezpieczenie nadprądowe i cyfrowy pomiar prądu oraz napięcia doprowadzonego do badanego układu. Pomiar prądu wykonywany był z dokładnością do 10 mA, natomiast pomiar napięcia z dokładnością 100 mV.



Rys. 6.3. Widok zastosowanego układu pomiarowego, gdzie: 1-kadź pomiarowa, 2-transformator probierczy, 3-opornik wodny, 4-układ mocujący iskiernik modelujący WNZ.



Rys. 6.4. Pulpit sterowniczy do regulacji i pomiaru napięcia zasilającego.

Napięcie generacji WNZ, których sygnały EA zostały zarejestrowane w bazie danych dla Klasy 9, wynosiło 46,7 V po stronie pierwotnej transformatora probierczego, co po uwzględnieniu przekładni daje potencjał 12,74 kV po stronie wtórnej i stanowi 0,8 wartości napięcia przebicia (Rys. 6.4). W analogiczny sposób zostały zarejestrowane sygnały EA generowanej w iskiernikach modelujących Klasy od 1 do 8 [38].

6.3. Metodyka pomiarów sygnałów emisji akustycznej generowanej przez wyładowania niezupełne

Podobnie jak w przypadku iskiernika do generacji WNZ, tak i układ służący do pomiarów sygnałów EA, zastosowany w ramach niniejszej rozprawy, jest funkcjonalnie tożsamy z układem zastosowanym do pomiaru sygnałów EA, przy użyciu którego, dokonano skatalogowania uzyskanych przebiegów w bazie danych, dla Klas od 1 do 8. Zastosowany układ pomiarowy składał się z przetwornika piezoelektrycznego, wzmacniacza różnicowego, karty pomiarowej i komputera przemysłowego.



Wykorzystany do rejestracji sygnałów EA od WNZ szerokopasmowy, piezoelektryczny przetworniki stykowy typu WDAH17 (Rys. 6.5) firmy Physical Acoustics Corporation, posiada:

- wysoką czułość: $55 \text{ dB} \pm 1,5 \text{ dB}$ na V/ms^{-1} ,
- szerokie pasmo przenoszenia (Rys. 6.6) w zakresie od 100 kHz do 1 MHz, przy zachowaniu kryterium spadku amplitudy o $\pm 10 \text{ dB}$,
- różnicowy układ pomiaru, który częściowo eliminuje wpływ zakłóceń elektromagnetycznych na przetwornik i przewody pomiarowe.




Rys. 6.5. Przetwornik piezoelektryczny stykowy WDAH17 firmy PAC z wtykami przyłączeniowymi.



AE SENSOR CALIBRATION CERTIFICATE

Sensor Name: WD **Test Date:** 2/15/07 **Max. Value (dB):** -60.56
Sensor S/N: FJ18 **Tested By:** L.C. **Peak Freq.(kHz):** 531.25
Comment: 1 METER CABLE




Rys. 6.6. Charakterystyka przenoszenia przetwornika piezoelektrycznego WDAH17 firmy PAC [111].

Kolejnym elementem układu pomiarowego był wzmacniacz sygnału AE SIGNAL CONDITIONER, zaprojektowany i wykonany przez firmę EA System (Rys. 6.7). Jest to układ wzmacniająco-filtrujący o wzmacnieniu: 40 dB dla różnicowego układu połączeń i 34 dB dla pracy z jednym wejściem zwartym do masy. Szerokość pasma przenoszenia wzmacniacza jest w zakresie od 0 Hz do 1,5 MHz, ale zastosowany filtr pasmowo-przepustowy ósmego rzędu, ogranicza ten przedział do zakresu od 16 kHz do 700 kHz [77]. Zastosowane pasmo filtracji, jest wystarczające do poprawnego odwzorowania struktury częstotliwościowej sygnałów EA generowanej przez WNZ, co wykazano m.in. w pracach [10, 11, 13].



Rys. 6.7. Widok układu wzmacniająco – filtrujący AE SIGNAL CONDITIONER.

Po wzmacnieniu sygnały EA były rejestrowane za pomocą czterokanałowej karty pomiarowej CH 3160 (Rys. 6.8) firmy Acquitek. Karta ma możliwość próbkowania czterech kanałów jednocześnie z wydajnością 10 MS/s na kanał, może również pracować z obsługą: dwóch kanałów – 20 MS/s na kanał lub jednego kanału – 40 MS/s, co zapewnia możliwość rejestracji sygnałów z częstotliwością 70 MHz. Impedancja wejściowa ma dwie wybieralne wartości: 50 Ω i 1 M Ω . Zastosowany w karcie przetwornik analogowo cyfrowy posiada rozdzielczość 12 bitów, dodatkowo karta wyposażona jest w 16 MB pamięci wewnętrznej [106].

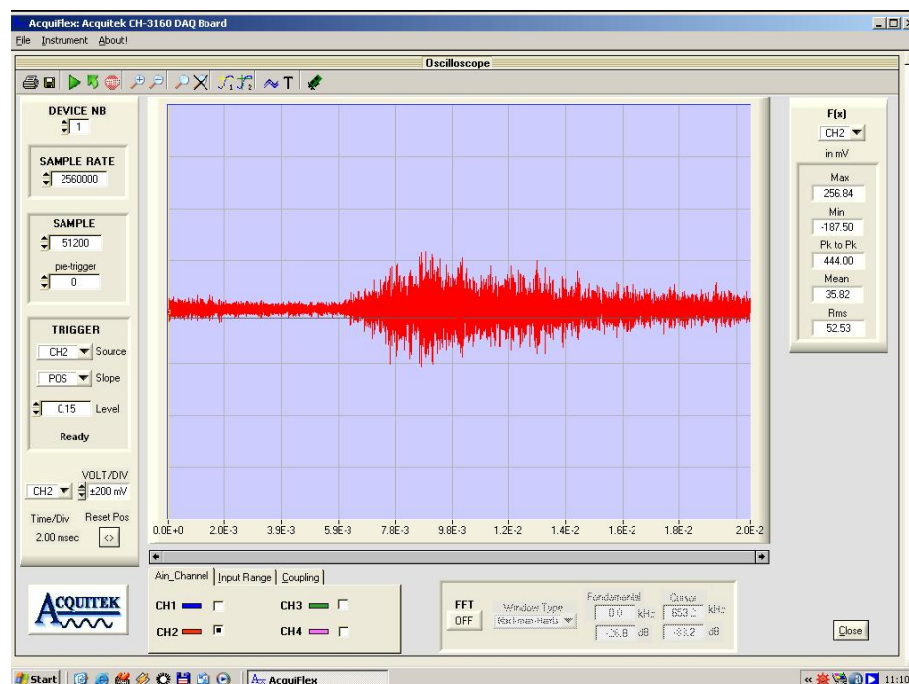


Rys. 6.8. Karta pomiarowa CH 3160 firmy Acquitek [106].


W trakcie wykonywania pomiarów, zastosowano częstotliwość próbkowania na poziomie 2,56 MHz, co zgodnie z twierdzeniem Kotelnikowa-Shannona pozwala rejestrować sygnały o częstotliwości granicznej 1,28 MHz [41]. Pojedyncza rejestracja zawierała 51200 próbek, co po uwzględnieniu częstotliwości próbkowania powodowało, że zarejestrowany sygnał posiadał długość 20 ms. Zaproponowana długość rejestracji odpowiada czasowi trwania



jednego okresu napięcia o częstotliwości technicznej. Podczas rejestracji sygnałów EA, została wykorzystana aplikacja, która umożliwiała automatyczną regulację parametrów karty, podgląd przebiegów czasowych i widm częstotliwościowych oraz ich zapisywanie, dostarczona przez producenta karty pomiarowej (Rys. 6.9). Oprogramowanie posiadało funkcję trigger, która zapewniała samoczynne wyzwalanie rejestracji sygnału, od nastawionej wartości progowej w nim zawartej, a także opcję pre-trigger, umożliwiającą zarejestrowanie określonej liczby próbek poprzedzających trigger. Dzięki ich wykorzystaniu istniała możliwość standaryzacji sposobu rejestracji wszystkich sygnałów EA, które zgromadzono w bazie danych. Wykonywano to poprzez ustawienie funkcji pre-trigger o stałej wartości, niezależnej od rejestrowanej Klasy, równej 5000 próbek.



Rys. 6.9. Rzut ekranu głównego interfejsu użytkownika karty pomiarowej CH 3160 firmy Acqutek.



Rys. 6.10. Widok toru pomiarowego wykorzystanego do pomiarów sygnałów EA generowanej przez podstawowe formy WNZ.

Sposób połączenia poszczególnych elementów tworzących tor pomiarowy EA, który został zastosowany w niniejszej rozprawie, przedstawiony na rys. 6.10. Karta pomiarowa, wraz z niezbędnym oprogramowaniem, została zainstalowana na komputerze klasy PC, wyposażonym w dodatkową ochronę przeciwprzepięciową w postaci dławików. Ponadto zapewniono odrębne uziemienia dla iskiernika modelującego WNZ i układu pomiarowego.



7. Zastosowanie Klasycznego Algorytmu Multikomparacyjnego do klasyfikacji wyładowań niezupełnych

Statystyczne metody klasyfikacji znajdują obecnie bardzo szerokie możliwości praktycznych implementacji. Ich zasadniczą zaletą jest brak procesu uczenia i krótki czas odpowiedzi. To powoduje, że możliwe jest zastosowanie w ich strukturze złożonych metod opisu sygnału i dodatkowo dużej liczby rozpoznawalnych Klas jednocześnie. Zdefiniowanie dziewięciu rozpoznawalnych Klas WNZ z jednoczesnym zastosowaniem deskryptora czasowo-częstotliwościowego, może spełnić w/w warunki. Dlatego w niniejszej pracy zaproponowano zastosowanie autorskiej metody klasyfikacji WNZ, którą można zaliczyć do metod statycznych.

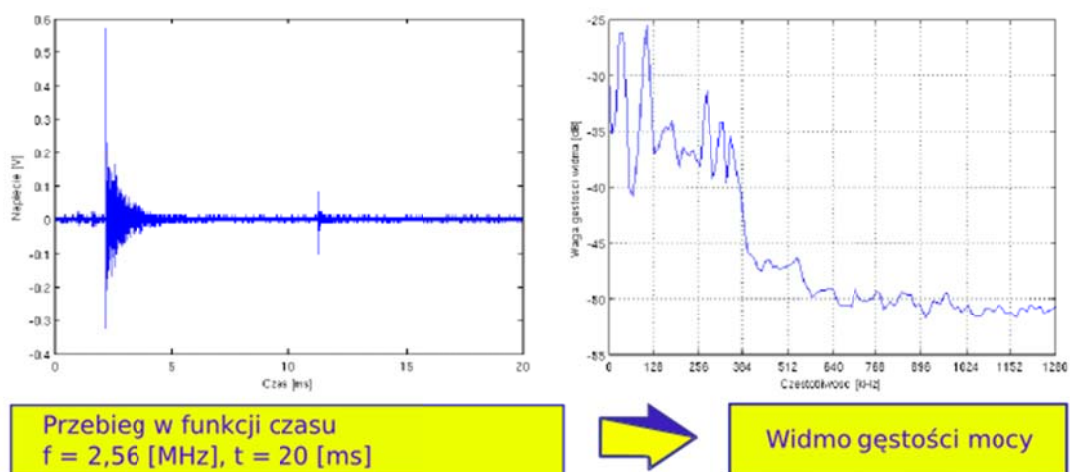
W niniejszym rozdziale opisano badania własne Autora dotyczące Klasycznego Algorytmu Multikomparacyjnego (KAM), w celu sprawdzenia jego przydatności, do klasyfikacji sygnałów EA generowanych przez WNZ. Przeprowadzono również dobór parametrów algorytmu, w celu maksymalizacji jego skuteczności.

7.1. Określenie warunków pracy Klasycznego Algorytmu Multikomparacyjnego

W początkowej fazie analizy wykorzystywano pierwotną bazę danych zawierającą przebiegi czasowe EA generowanej przez osiem Klas WNZ, które zdefiniowano w rozdz. 3.1. niniejszej rozprawy. Każda z Klas defektów jest skatalogowana za pomocą 100 zarejestrowanych sygnałów EA.

Jako deskryptor charakteryzujący zarejestrowane sygnały EA od WNZ zastosowano widmo gęstości mocy, których przebiegi wyznaczono oddzielnie dla każdego ze skatalogowanych w bazie przebiegów czasowych. Opis tego deskryptora zamieszczono w rozdz. 4.2.2. niniejszej rozprawy. W oparciu o wyniki badań zamieszczone w pracy [38], przyjęto 130 punktów uśredniających dla przekształcenia PSD (Rys. 7.1).

Ponadto na podstawie przeglądu doniesień literaturowych [3, 11, 38] i badań własnych Autora, można stwierdzić, że pasmo dominujących częstotliwości dla sygnałów EA generowanej przez podstawowe formy WNZ, jakie mogą występować w izolacji papierowo-olejowej transformatorów elektroenergetycznych, znajduje się w przedziale od 0 do 700 kHz. Dlatego, w dalszych pracach, ograniczono górny zakres analizowanych częstotliwości do 700 kHz. Należy jednocześnie zaznaczyć, że z uwagi na możliwość występowania zakłóceń o charakterze akustycznym i zastosowany układ pomiarowy, nie brano pod uwagę zakresu częstotliwości w paśmie od 0 do 65 kHz. Jego pominięcie nie wpływa na skuteczność klasyfikacji, ponieważ kluczowe informacje, umożliwiające poprawną identyfikację form WNZ, są zawarte w wyższych pasmach częstotliwościowych [41, 80, 81, 82].




Rys. 7.1. Poglądowe przedstawienie zastosowanego do rozpoznawania Klas WNZ deskryptora częstotliwościowego.

7.2. Opis mechanizmu działania Klasycznego Algorytmu Multikomparacyjnego

Algorytm KAM w procesie rozpoznawania wykorzystuje wysoką skuteczność klasyfikatorów binarnych, które wykonują klasyfikacje cząstkowe, w układzie wielokrotnych porównań. Liczba iteracji przeprowadzanych przez

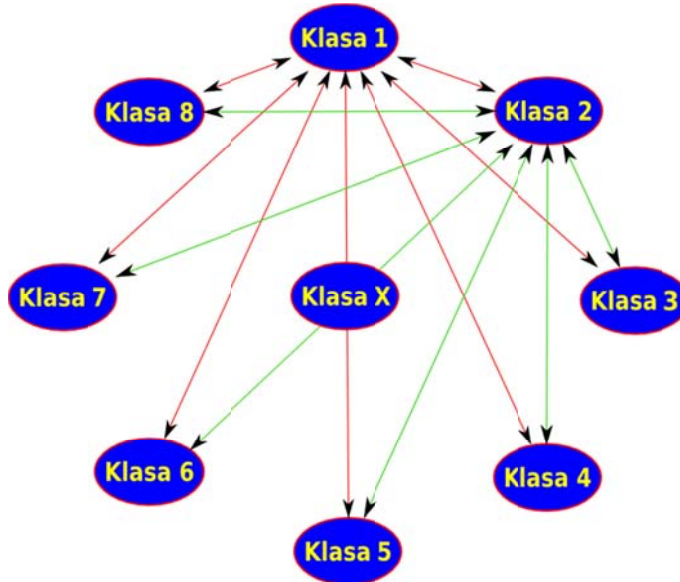
algorytm, w celu rozpoznania jednego badanego przebiegu, jest równa dwuelementowej kombinacji zbioru n – elementowego i można ją wyznaczyć przy użyciu dwumianu Newtona, gdzie wartość n jest równa liczbie rozpoznawanych Klas. W przeprowadzonych badaniach wynosiła ona 8, ponieważ analizę wykonywano w oparciu o dane zgromadzone w bazie danych w jej pierwotnym kształcie (bez uwzględnienia Klasy 9). Tym samym liczba iteracji wykonywanych przez algorytm była równa 28. Za poprawnie zidentyfikowaną Klasę uważa się taką, która zostanie wskazana przez wszystkie 7 (n minus jeden) klasyfikacji cząstkowych w iteracjach jej dotyczących (Rys. 7.2). Porównania cząstkowe są wykonane przez klasyfikatory binarne [14, 15].



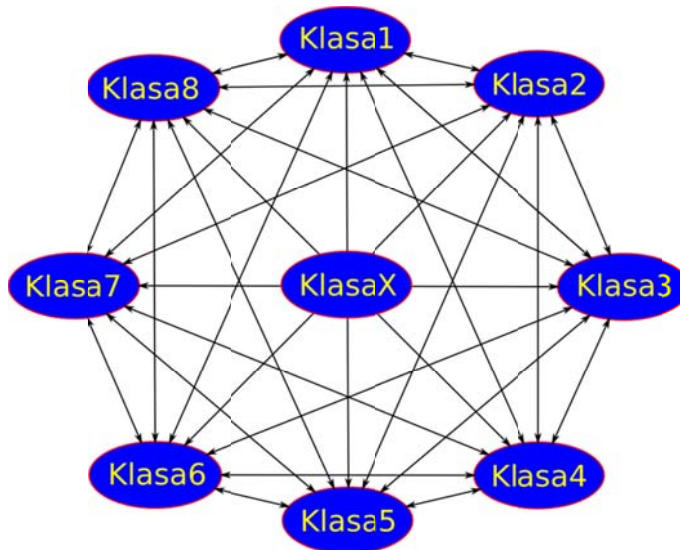
Rys. 7.2. Poglądowe przedstawienie procesu klasyfikacji w zakresie iteracji dotyczących WNZ Klasy 1.

Na rys. 7.2 przedstawiono strukturę porównań wykonywanych przez algorytm KAM, dla iteracji dotyczących Klasy 1 [83, 84]. Elipsy o nazwach: Klasa 1 do Klasa 8 reprezentują poszczególne Klasy WNZ, za wyjątkiem elipsy o nazwie Klasa X, która jest przebiegiem badanym, podlegającym procesowi klasyfikacji. Natomiast strzałki symbolizują kolejne iteracje algorytmu. Tym

samym ich liczbą jest równa liczbie iteracji. Natomiast na rys. 7.3 ujęto dodatkowo iteracje dotyczące Klasy 2, które zaznaczono kolorem zielonym.



Rys. 7.3. Poglądowe przedstawienie procesu klasyfikacji w zakresie iteracji dotyczących Klasy 1 i Klasy 2.

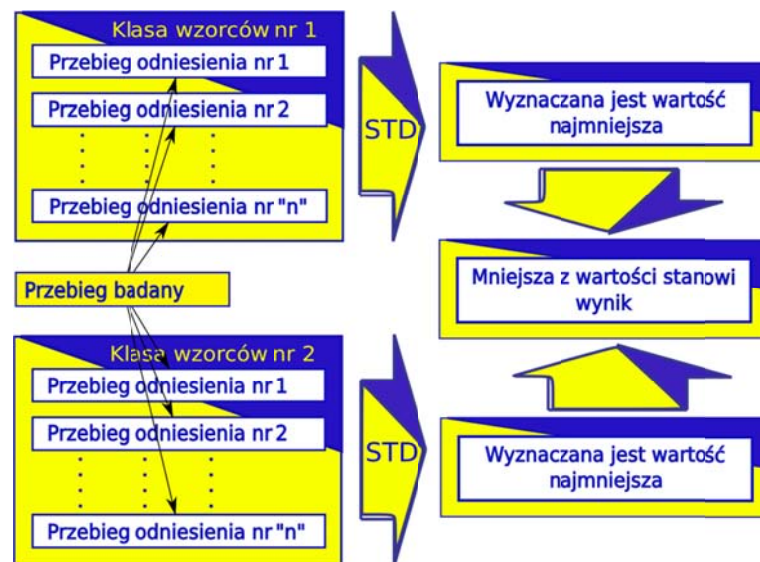


Rys. 7.4. Poglądowe przedstawienie procesu klasyfikacji przeprowadzonego dla pojedynczego przebiegu z bazy danych.

Istotną cechą algorytmu KAM jest fakt nie powtarzania wykonywanych już iteracji. Oznacza to, że jeżeli Klasa X była porównywana z parą Klas: Klasa 1-Klasa 2, w odniesieniu do iteracji dotyczących Klasy 1, to operacja ta nie jest wykonywana ponownie w odniesieniu do iteracji dotyczących Klasy 2. Strukturę wszystkich iteracji wykonywanych przez algorytm KAM, w ramach procesu klasyfikacji przeprowadzonego dla pojedynczego przebiegu z bazy danych, zobrazowano na rys. 7.4.

7.3. Dobór liczby przebiegów wzorcowych

Pojedyncza iteracja algorytmu multikomparacyjnego, zawsze dotyczy tylko dwóch Klas, jest więc sklasyfikowaniem binarnym. W pierwszym etapie badań jako klasyfikator binarny zastosowano algorytm najbliższy sąsiad (*ang. Nearest Neighbor NN*). Jako kryterium oceny przyjęto wartość odchylenia standardowego (STD). Pojedyncza iteracja klasyfikatora binarnego NN, przy użyciu kryterium STD, ma strukturę przedstawioną na rys. 7.5.



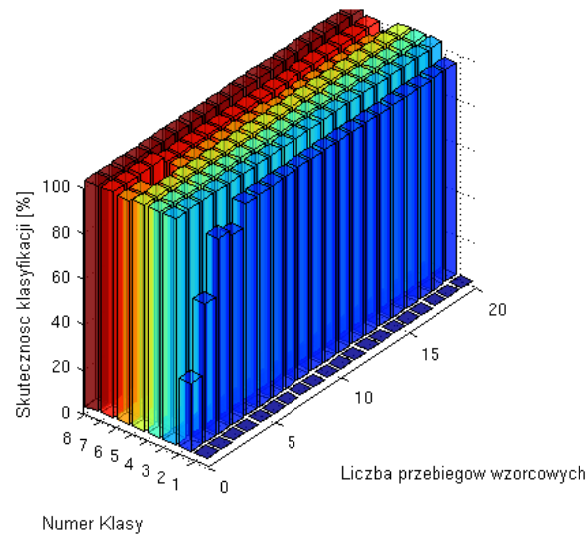
Rys. 7.5. Poglądowe przedstawienie pojedynczej iteracji klasyfikatora binarnego NN, z wykorzystaniem kryterium STD.



W pierwszym kroku badany przebieg jest odejmowany od każdego z przebiegów wzorcowych, uszeregowanych w danej Klasie wzorców. Następnie dla każdego z uzyskanych wyników wyznacza się wartość STD. Otrzymane w ten sposób wartości są porównywane w ramach swojej Klasy wzorców w celu wskazania najmniejszej z nich. W ostatnim kroku następuje analiza porównawcza wyników uzyskanych w ramach Klas wzorców i w konsekwencji przypisanie badanego przebiegu do jednej z rozpatrywanych Klas. Procesowi klasyfikacji podlegają przebiegi przetworzone za pomocą, aktualnie wykorzystywanego deskryptora.


Celem optymalizacji liczby przebiegów wzorcowych, zaimplementowanych w ramach danej Klasy wzorców, przeprowadzono analizy, polegające na obliczeniu skuteczności klasyfikacji algorytmu KAM, w funkcji liczby przebiegów wzorcowych. W ramach przeprowadzonych symulacji liczba przebiegów wzorcowych była zmieniana w zakresie od 1 do 20, dla każdej z Klas. Z populacji 100 przebiegów czasowych EA reprezentujących każdą z Klas WNZ, typowano na drodze losowej 20, które przyjmowano jako przebiegi wzorcowe. Pozostałe 80 przebiegów podlegało pojedynczo procesowi klasyfikacji. Oznacza to, że nie mogła zaistnieć sytuacja, w której rozpoznawany przebieg był jednocześnie wzorcowym.

Operację klasyfikacji wykonywano kolejno dla każdej z ośmiu analizowanych Klas, w 20 konfiguracjach algorytmu KAM. Tym samym proces rozpoznawania przeprowadzono oddzielnie dla każdego z 640 przebiegów z uwzględnieniem 20 wariantów konfiguracji algorytmu KAM. Każdy z przedstawionych na rys. 7.6 - 7.14 wykresów reprezentuje wyniki skuteczności klasyfikacji uzyskane dla danej Klasy, wyznaczone względem pozostałych Klas, w zależności od liczby przebiegów wzorcowych. Klasa charakteryzowana na danym wykresie występuje w postaci słupków o amplitudzie zerowej [85]. Rys. 7.6 reprezentuje wyniki skuteczności klasyfikacji dla Klasy 1.

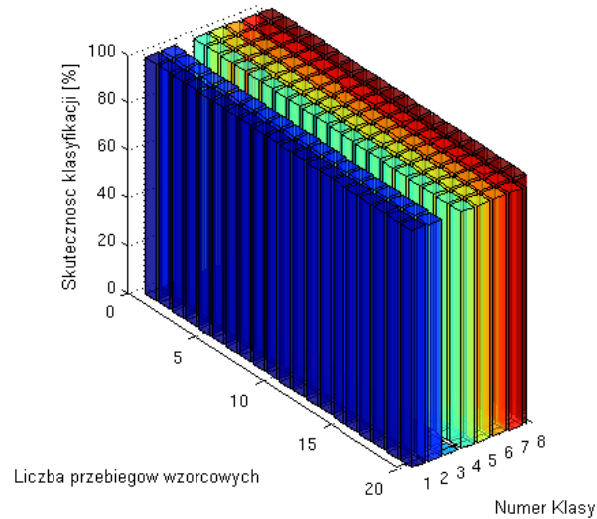


Rys. 7.6. Skuteczność klasyfikacji algorytmu KAM, w funkcji liczby przebiegów wzorcowych dla Klasy 1, określona względem pozostałych Klas.


Na podstawie zależności przedstawionych na rys. 7.6 można stwierdzić, że skuteczność rozpoznawania Klasy 1 względem Klasy 2 wzrasta wraz z liczbą przebiegów wzorcowych. Po przekroczeniu liczby 5 przebiegów skuteczność rozpoznania ma stałą wartość. Ponadto można zauważyć, że skuteczność rozpoznawania Klasy 6, nieznacznie maleje w funkcji liczby przebiegów wzorcowych.



Rys. 7.7. Skuteczność klasyfikacji algorytmu KAM, w funkcji liczby przebiegów wzorcowych dla Klasy 2, określona względem pozostałych Klas.




Rys. 7.8. Skuteczność klasyfikacji algorytmu KAM, w funkcji liczby przebiegów wzorcowych dla Klasy 3, określona względem pozostałych Klas.



Rys. 7.9. Skuteczność klasyfikacji algorytmu KAM, w funkcji liczby przebiegów wzorcowych dla Klasy 4, określona względem pozostałych Klas


Rys. 7.7 - 7.9 przedstawiają odpowiednio skuteczność rozpoznawania dla Klasy 2, Klasy 3 i Klasy 4, względem pozostałych Klas. Na podstawie uzyskanych zależności można stwierdzić, że dla tych Klas, nie istnieje wyraźna

korelacji między liczbą przebiegów wzorcowych, a skutecznością klasyfikacji. Jedynie w przypadku Klasy 2 występuje nieznaczny spadek skuteczności klasyfikacji dla 20 przebiegów wzorcowych.




Rys. 7.10. Skuteczność klasyfikacji algorytmu KAM, w funkcji liczby przebiegów wzorcowych dla Klasy 5, określona względem pozostałych Klas.

Na rys. 7.10 można zauważyć występowanie fluktuacji wartości skuteczności rozpoznawania Klasy 5, względem Klas: 1, 2, 6 i 7. Stabilizacja skuteczności rozpoznawania następuje, po osiągnięciu przez algorytm liczby 10 przebiegów wzorcowych.




Rys. 7.11. Skuteczność klasyfikacji algorytmu KAM, w funkcji liczby przebiegów wzorcowych dla Klasy 6, określona względem pozostałych Klas.

Skuteczność rozpoznawania Klasy 6 względem Klasy 1 wzrasta wraz z liczbą przebiegów wzorcowych, natomiast względem Klasy 7 maleje w funkcji tej samej liczby. Najbardziej gwałtowny spadek skuteczności klasyfikacji, można zaobserwować po przekroczeniu liczby 15 przebiegów wzorcowych.



Rys. 7.12. Skuteczność klasyfikacji algorytmu KAM, w funkcji liczby przebiegów wzorcowych dla Klasy 7, określona względem pozostałych Klas.


Zależności przedstawione na rys. 7.12 mają istotne znaczenie dla właściwego doboru liczby przebiegów wzorcowych. Skuteczność rozpoznawania Klasy 7 względem Klasy 6 ma maksimum lokalne przy 15 przebiegach.



Rys. 7.13. Skuteczność klasyfikacji algorytmu KAM, w funkcji liczby przebiegów wzorcowych dla Klasy 8, określona względem pozostałych Klas.

Rys. 7.13 przedstawia rozkład skuteczności klasyfikacji dla Klasy 8 względem pozostałych Klas. Uzyskane zależności cechuje duża równomierność rozkładu, z wyjątkiem Klasy 6, gdzie wyraźnie można zaobserwować nagły spadek wartości skuteczności klasyfikacji, który ma miejsce między przebiegiem 10, a 14.

Wyniki skuteczności klasyfikacji dla wszystkich zdefiniowanych Klas, w formie zagregowanej, przedstawiono na rys. 7.14.



Rys. 7.14. Wykres skuteczności klasyfikacji algorytmu KAM, w funkcji liczby przebiegów wzorcowych dla wszystkich zdefiniowanych Klas.

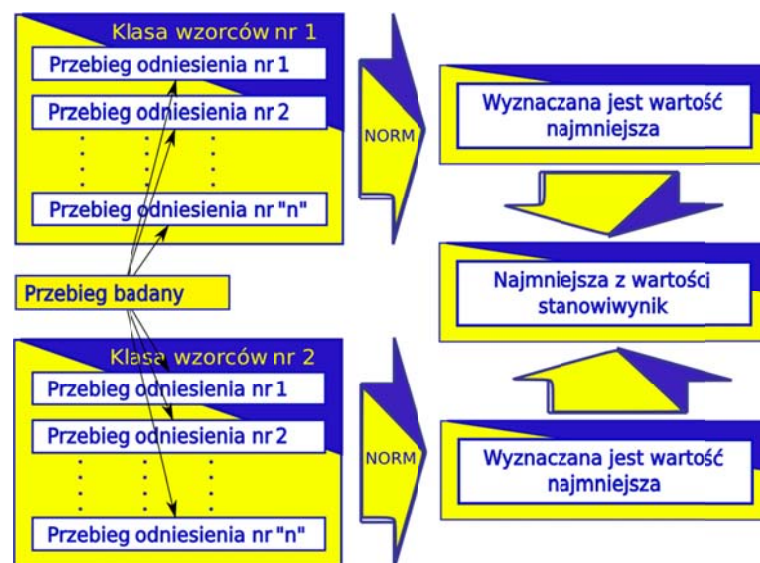
Wiersze o numerach od 1 do 8 oznaczają zagregowane wyniki skuteczności klasyfikacji dla poszczególnych Klas. Jak można zaobserwować stabilizacja skuteczności procesu klasyfikacji następuje po przekroczeniu liczby 14 przebiegów wzorcowych, zaimplementowanych do struktury algorytmu KAM. Na tej podstawie w dalszych pracach związanych z zastosowaniem algorytmu KAM do klasyfikacji i rozpoznawania podstawowych form WNZ, zastosowano liczbę 15 przebiegów w ramach danej Klasy wzorców [85, 86].

7.4. Dobór i walidacja klasyfikatorów binarnych

Jak opisano w rozdz. 7.3 w początkowej fazie badań, dotyczących algorytmu KAM, jako klasyfikator binarny zastosowano algorytm najbliższy sąsiad (*ang. Nearest Neighbor NN*), a jako kryterium oceny przyjęto wartość odchylenia standardowego (STD) (Rys. 7.5).

W kolejnej części badań porównano dwa klasyczne klasyfikatory, typu: NN i najbliższa średnia (*ang. Nearest Mean NM*). Jako kryterium oceny dla klasyfikatorów NN i NM, przyjęto kolejno STD i normę średnio-kwadratową (NORM). W ten sposób skonstruowano cztery klasyfikatory, za pomocą których przebadano wszystkie przebiegi zgromadzone w bazie danych.

Pojedynczą iterację klasyfikatora binarnego NN, przy użyciu kryterium STD, przedstawiono na rys. 7.5. Natomiast na rys. 7.15 zilustrowano strukturę klasyfikatora NN, gdzie jako kryterium oceny zastosowano NORM.

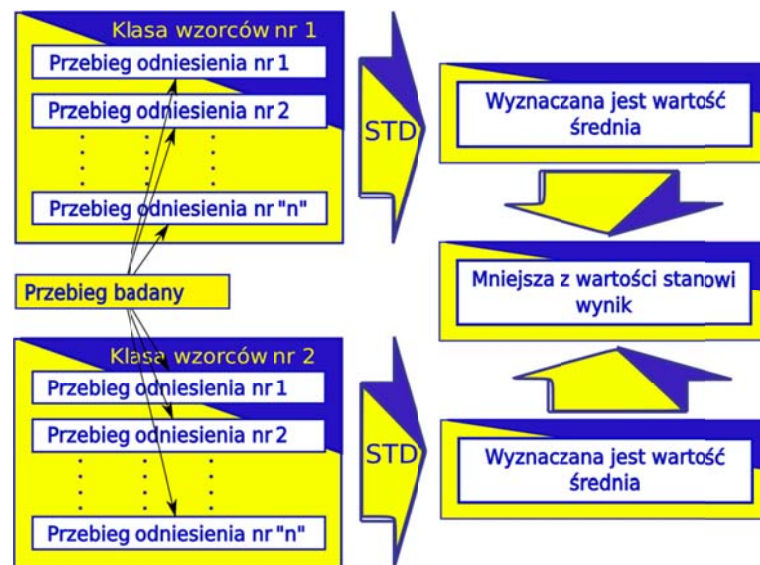


Rys. 7.15. Poglądowe przedstawienie pojedynczej iteracja klasyfikatora binarnego NN, z wykorzystaniem kryterium NORM.

Analogicznie jak w poprzednim przypadku (Rozdz. 7.3), w pierwszym kroku badany przebieg jest odejmowany od każdego z 15 przebiegów wzorcowych, które uszeregowano w danej Klasie wzorców. Następnie dla każdego z uzyskanych wyników wyznaczano wartość NORM. Otrzymane w ten sposób

wartości porównywano w ramach swojej Klasy wzorców, w celu wskazania najmniejszej z nich. Krok ostatni to analiza porównawcza wyników uzyskanych w ramach Klas wzorców, wraz z zakwalifikowaniem badanego przebiegu do jednej z rozpatrywanych Klas.

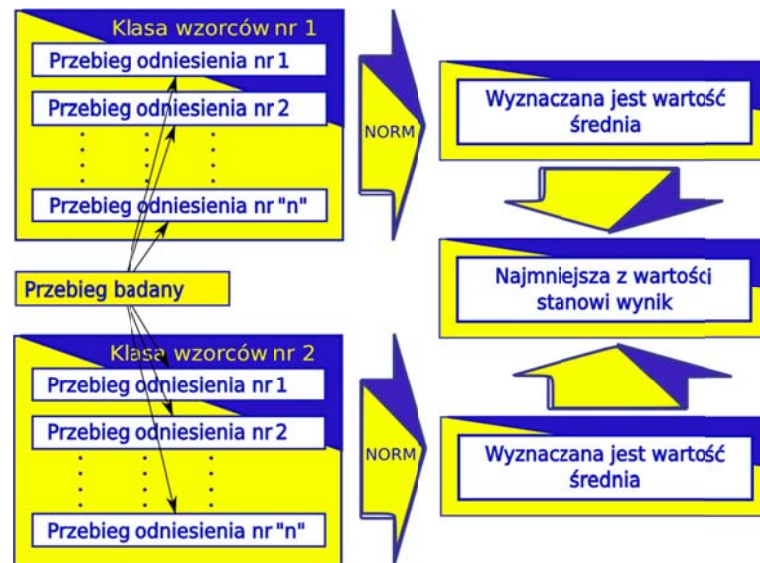
W komplementarny sposób przedstawiono klasyfikator NM, gdzie jako kryterium oceny zastosowano STD. Jego strukturę zilustrowano na rys. 7.16.



Rys. 7.16. Poglądowe przedstawienie pojedynczej iteracja klasyfikatora binarnego NM, z wykorzystaniem kryterium STD.

Zasada działania tego algorytmu, różni się od poprzedniego przypadku, tym że po obliczeniu dla każdego z 15 przebiegów wartości odchylenia standardowego, wyznaczana jest wartość średnia (a nie najmniejsza) w ramach danej Klasy wzorców. Kolejny krok algorytmu nie uległ zmianie.


Ostatnim z przetestowanych klasyfikatorów binarnych był algorytm NM z zastosowaniem jako kryterium oceny NORM. Jego schemat przedstawiono na rys. 7.17.



Rys. 7.17. Poglądowe przedstawienie pojedynczej iteracja klasyfikatora binarnego NM, z wykorzystaniem kryterium NORM.


Struktura tego klasyfikatora jest analogiczna do algorytmu opisanego poprzednio, jednak zamiast kryterium oceny w postaci STD zastosowano NORM [86].

Dla klasyfikatorów z rodziny NM uzyskano następujące wyniki skuteczności klasyfikacji: 70,7% - dla STD i odpowiednio 72,7%, dla NORM. Strukturę otrzymanych wyników przedstawiono na rys. 7.18 i 7.19.






Rys. 7.18. Rozkład wyników skuteczności klasyfikacji dla algorytmu NM z wykorzystaniem jako kryterium STD.




Rys. 7.19. Rozkład wyników skuteczności klasyfikacji dla algorytmu NM z wykorzystaniem kryterium NORM.

Na rys. 7.18 zilustrowano rozkład wyników skuteczności klasyfikacji, dla algorytmu NM z wykorzystaniem jako kryterium STD. Wartością oczekiwaną tego rozkładu są elementy znajdujące się na głównej przekątnej. Przebiegi reprezentujące Klasę 6 były najczęściej niewłaściwie zaliczane do Klasy 7, natomiast przebiegi reprezentujące Klasę 5 do Klasy 6. Ponadto występowały liczne błędy przy klasyfikacji Klasy 1, względem Klasy 2 i Klasy 7 względem Klas 1 i 2.

Dla kolejnego klasyfikatora binarnego (Rys. 7.19) uzyskano wyniki komplementarne do opisywanych wyżej. Najistotniejszą przyczyną wielu niepoprawnych sklasyfikowań, jest sama zasada działania kryterium NM. Ma on zbyt dużą zdolność do uogólniania, co w tym zastosowaniu okazuje się być wadą. Natomiast klasyfikatory oparte na algorytmie NN, nie posiadają tej cechy. Dzięki temu uzyskane skuteczności rozpoznawania mają większą wartość i wynoszą odpowiednio: 90,5% dla STD i 90,2% dla NORM. Strukturę otrzymanych wyników przedstawiono na rys. 7.20 i 7.21.



Rys. 7.20. Rozkład wyników skuteczności klasyfikacji dla algorytmu NN z wykorzystaniem kryterium STD.



Rys. 7.21. Rozkład wyników skuteczności klasyfikacji dla algorytmu NN z wykorzystaniem kryterium NORM.

Średnia skuteczność rozpoznawania przekracza wartości 90%, co zobrazowano na rys. 7.20 i 7.21. Największa liczba niepoprawnych sklasyfikowań występuje w obrębie Klasy 6 względem Klas 7 i 5, oraz w obrębie Klasy 7 względem Klas 6 i 1. Obniża to w znaczący sposób całkowitą skuteczność omawianego klasyfikatora multikomparacyjnego.



Rozprawa doktorska: „Zastosowanie algorytmu multikomparacyjnego do klasyfikacji sygnałów emisji akustycznej generowanych przez wyładowania niezupełne”

Na podstawie uzyskanych wyników, w dalszych badaniach jako klasyfikator binarny zastosowano NN z wykorzystaniem jako kryterium oceny, zarówno STD, jak również NORM.




8. Analiza porównawcza skuteczności rozpoznawania Zoptymalizowanego Algorytmu Multikomparacyjnego i Klasycznego Algorytmu Multikomparacyjnego

8.1. Określenie warunków pracy Zoptymalizowanego Algorytmu Multikomparacyjnego

W celu porównania skuteczności rozpoznawania podstawowych Klas WNZ przez algorytmy KAM i Zoptymalizowanego Algorytmu Multikomparacyjnego (ZAM), a także ich wydajności, zapewniono takie same warunki działania dla obu metod. Dlatego ZAM został przetestowany w oparciu o tą samą konfigurację bazy danych scharakteryzowaną w rozdz. 7.1, z wykorzystaniem tego samego deskryptora opisanego również w rozdz. 7.1.

8.2. Mechanizm działania Zoptymalizowanego Algorytmu Multikomparacyjnego

ZAM, podobnie jak algorytm KAM, wykorzystuje w procesie rozpoznawania Klas WNZ wysoką skuteczność klasyfikatorów binarnych. Elementami, które zostały zoptymalizowane były struktura i liczba wykonywanych porównań. Dla ZAM liczba wykonywanych porównań, jest równa liczbie Klas pomniejszonej o jeden, stąd dla ośmiu Klas wynosi siedem (Rys. 8.1).



Rys. 8.1. Struktura iteracji wykonywanych przez algorytm ZAM.

Każda z podstawowych Klas WNZ przedstawionych na rys. 8.1 jest ilustrowana za pomocą jednej elipsy. Strzałki o dwóch grotach symbolizują



kolejne porównania cząstkowe. Natomiast strzałki z jednym grotem stanowią wyniki tych porównań. Elipsy o nazwach: Klasa x1, ..., Klasa x6 reprezentują kolejne wyniki cząstkowe, natomiast elipsa o nazwie Klasa x7 jest wynikiem końcowym. Przebieg podlegający procesowi klasyfikacji jest reprezentowany przez elipsę o nazwie Klasa X. W pierwszym kroku przebieg klasyfikowany jest porównywany z pierwszą parą Klas (Klasa 1 i Klasa 2). W wyniku tego porównania następuje wskazanie na jedną z Klas, do której przebieg klasyfikowany, wykazuje większe podobieństwo. W drugim kroku, przebieg klasyfikowany jest porównywany z parą Klas w skład, której wchodzi Klasa 3 oraz Klasa, która została wskazana w pierwszym kroku omawianego algorytmu. Taki sposób rozpoznawania jest cyklicznie powtarzany, aż do otrzymania ostatecznego wyniku (Klasa X7).

Zaproponowany algorytm jest bardziej wydajny pod względem obliczeniowym od algorytmu KAM, ponieważ wykonuje cztery razy mniejszą liczbę operacji [87]. Analizując strukturę logiczną algorytmów KAM i ZAM można stwierdzić, że powinny one generować zbliżone wyniki, ponieważ dla obu algorytmów zachodzi taka sama liczba wskazań cząstkowych (dla analizowanego przypadku 7) w odniesieniu do analizowanej Klasy. Istotną różnicą między porównywanymi algorytmami jest możliwość niezakwalifikowania badanego przebiegu do żadnej z Klas w przypadku algorytmu KAM. Taka sytuacja występuje, wówczas gdy kryterium siedmiu zgodnych wskazań cząstkowych, nie jest spełnione. Taki przypadek nie występuje przy zastosowaniu ZAM. Dla analizowanych przypadków nie ma to jednak kluczowego znaczenia, ponieważ każdy z badanych przebiegów należy do jednej z rozważanych Klas. Natomiast własność ta jest istotna, w przypadku gdy algorytm będzie wykorzystywany w celu odróżnienia sygnału EA generowanej przez daną formę WNZ od sygnału, który nim nie jest (np. sygnały zakłóceń). W takiej sytuacji uzyskanie poprawnych wyników jest również możliwe, po uprzedniej modyfikacji bazy danych. Jednakże w celu obiektywnej analizy porównawczej obu algorytmów, wykorzystano przyjętą dotychczas bazę danych.




8.3. Wyznaczenie skuteczności klasyfikacji Zoptymalizowanego Algorytmu Multikomparacyjnego

W celu określenia skuteczności klasyfikacji algorytmu ZAM przebadano przy jego wykorzystaniu, scharakteryzowaną wcześniej bazę danych, która zawierała 8 Klas WNZ. Uwzględniono przy tym dwa kryteria oceny porównywanych sygnałów EA: STD i NORM. W tab. 8.1 zestawiono wyniki uzyskane dla algorytmów KAM i ZAM.

Tab. 8.1. Zestawienie porównawcze skuteczności klasyfikacji podstawowych Klas WNZ przy zastosowaniu algorytmów KAM i ZAM.


Lp.	Algorytm	Kryterium	Wartość skuteczności [%]
1	KAM	Norma średniokwadratowa	90,2
2		Odchylenie standardowe	91,0
3	ZAM	Norma średniokwadratowa	90,2
4		Odchylenie standardowe	90,5

W przypadku zastosowania kryterium NORM, otrzymane rezultaty są takie same dla obu badanych algorytmów. Natomiast dla kryterium STD, ZAM jest mniej skuteczny, przy czym tylko o 0,5%. Podobna sytuacja ma miejsce przy porównaniu cząstkowych wyników skuteczności rozpoznawania, uzyskiwanych przez badane algorytmy, dla poszczególnych Klas WNZ. Na rys. 7.21 i 8.2 przedstawiono rozkłady skuteczności klasyfikacji, kolejno dla algorytmów KAM (Rys. 7.21) i ZAM (Rys. 8.2) z wykorzystaniem jako kryterium oceny NORM.



Rys. 8.2. Rozkład skuteczności klasyfikacji, dla algorytmu ZAM z wykorzystaniem jako kryterium NORM.

Na podstawie uzyskanych wyników można stwierdzić, że skuteczność klasyfikatorów, przy rozpoznawaniu poszczególnych Klas WNZ, jest porównywalna. W przypadku Klas od 1 do 5 oraz dla Klasy 8 uzyskiwane wyniki skuteczności klasyfikacji osiągają wartości powyżej 97%. Natomiast trudno rozpoznawalne są względem siebie Klasa 6 i Klasa 7. Zagadnienie to jest związane z fizycznymi uwarunkowaniami badanego zjawiska i zostanie omówione w dalszej części pracy, które zostało także scharakteryzowane w artykułach [85, 86]. Warto jednocześnie zauważyć, że oba typy klasyfikatorów są obciążone tym błędem w porównywalnym stopniu.



Rys. 8.3. Rozkład skuteczności klasyfikacji, dla algorytmu ZAM z wykorzystaniem jako kryterium STD.

Na rys. 7.20 i 8.3 przedstawiono rozkłady skuteczności klasyfikacji, kolejno dla algorytmów KAM i ZAM, uzyskane przy wykorzystaniu klasyfikatora NN i STD jako kryterium oceny. Podobnie jak w poprzednim przypadku skuteczność klasyfikatorów jest porównywalna. Klasy od 1 do 5 oraz Klasa 8 są rozpoznawane ze skutecznością powyżej 97%. Natomiast Klasa 6 i Klasa 7 wykazują duży stopień podobieństwa względem siebie, co utrudnia ich prawidłową identyfikację.

Na podstawie uzyskanych wyników stwierdzono, że:

- istnieje potrzeba poprawienia skuteczności klasyfikacji, w odniesieniu do trudno rozpoznawalnych Klas, poprzez wykorzystanie dodatkowych informacji zawartych w sygnałach EA, zgromadzonych w bazie danych. W tym celu zmodyfikowano zastosowany deskryptor.
- Algorytm ZAM miał wyższą wydajność, dlatego w dalszych badaniach wykorzystywano jedynie modyfikowaną przez Autora strukturę algorytmu KAM.



9. Ocena możliwości zastosowania deskryptora czasowo-częstotliwościowego w strukturze Zoptymalizowanego Algorytmu Multikomparacyjnego

W celu zwiększenia skuteczności rozpoznawania poszczególnych Klas WNZ, w analogicznej strukturze klasyfikatora ZAM, jaką badano w poprzednim rozdziale, zastosowano deskryptor czasowo-częstotliwościowy. Aby istniała możliwość porównania uzyskanych wyników klasyfikacji, podobnie jak poprzednio, zastosowano bazę danych, która zawierała przebiegi sygnałów EA reprezentujące osiem podstawowych form WNZ.

Na podstawie przeprowadzonych analiz, których wyniki przedstawiono w rozdz. 8.3 wykazano, że najbardziej skutecznym klasyfikatorem binarnym jest algorytm NN, z wykorzystaniem jako kryterium oceny STD [85, 86].


W celu sprawdzenia wpływu deskryptora, na skuteczność klasyfikacji podstawowych form WNZ, oprócz widma gęstości mocy, zastosowano spektrogramy, które obliczono dla zgromadzonych w bazie przebiegów czasowych sygnałów EA. Deskryptor ten omówiono szerzej w rozdz. 4.2.3 [11, 88]. Podstawowym zagadnieniem, jakie należało rozważyć na etapie wstępnym, było przeprowadzenie doboru parametrów spektrogramów, które zapewniałyby uzyskanie możliwie najwyższej skuteczności klasyfikacji.

W oparciu o wyniki wcześniejszych prac Autora zamieszczone w niniejszej rozprawie i rozprawę doktorską [38] wykazano, że przy wykorzystaniu deskryptora częstotliwościowego (widmowej gęstości mocy), zastosowanie rozdzielczości w dziedzinie częstotliwości na poziomie 130 przedziałów jest wystarczające dla poprawnego rozpoznawania poszczególnych form WNZ. Dalsze zwiększanie rozdzielczości nie powodowało zwiększenia skuteczności klasyfikacji. Dlatego w zastosowanym deskrypcorze czasowo-częstotliwościowym założono rozdzielczość w dziedzinie częstotliwości na poziomie 130 przedziałów, dla pasm dominujących częstotliwości w zakresie od 65 kHz do 700 kHz [11, 85].

Czas trwania pojedynczego przebiegu EA wynosił 20 ms. Jest to wartość odpowiadająca czasowi trwania jednego okresu napięcia zasilającego badane



iskierniki, modelujące podstawowe formy WNZ. Autor założył, że istotną informacją, z punktu widzenia poprawności klasyfikacji, jest określenie czy WNZ występują w jednym czy w obu półokresach napięcia zasilającego. W tym celu zbadano zmianę skuteczność klasyfikacji algorytmu ZAM, z zaimplementowanym deskryptorem czasowo częstotliwościowym, w funkcji zmiany liczby zdefiniowanych przedziałów w dziedzinie czasu (Rys. 9.11). Rozdzielczość w dziedzinie czasu zmieniano w zakresie od dwóch do tysiąca przedziałów [87, 89]. Zakres przeprowadzonych analiz obejmował 108 różnych konfiguracji deskryptora. Przy czym analiza pojedynczej konfiguracji deskryptora, polegała na przeprowadzeniu procesu klasyfikacji dla całej bazy danych, z wykorzystaniem badanego deskryptora, który posiadał określoną i niezmienną podczas testu, liczbę przedziałów w dziedzinie czasu. W pracy przedstawiono i omówiono pięć wybranych konfiguracji deskryptora.




Rys. 9.1. Spektrogram sygnałów EA generowanych przez WNZ Klasy 8, dla rozdzielczości w dziedzinie czasu równej 1020 przedziałów.


Rys. 9.1 przedstawia spektrogram sygnałów EA generowanej przez WNZ Klasy 8, reprezentującej wyładowania w układzie wieloostre-plyta ze swobodnie przemieszczającymi się cząstkami stałymi o nieokreślonym potencjale. W tym przypadku liczba przedziałów w dziedzinie czasu wynosiła




1020. Natomiast na rys. 9.2 zilustrowano uzyskany przy jego wykorzystaniu rozkład skuteczności klasyfikacji. Skuteczność klasyfikacji, wyznaczona względem wszystkich rozpoznawalnych Klas (całkowita skuteczność klasyfikacji), z wykorzystaniem opisywanego deskryptora, dla 1020 przedziałów w dziedzinie czasu, wyniosła 84,5%. Jest to wartość niższa od uzyskanej w analogicznych warunkach dla deskryptora częstotliwościowego (widma gęstości mocy), która wynosiła 90,5%.



Rys. 9.2. Rozkład skuteczności klasyfikacji dla badanej bazy danych przy rozdzielczości w dziedzinie czasu równej 1020 przedziałów.




Rys. 9.3. Spektrogram sygnałów EA generowanej przez WNZ Klasy 8, obliczony dla rozdzielczości w dziedzinie czasu równej 505 przedziałów.




Rys. 9.4. Rozkład skuteczności klasyfikacji dla badanej bazy danych przy rozdzielczości w dziedzinie czasu równej 505 przedziałów.

Na rys. 9.3 i 9.4 przedstawiono kolejno spektrogram tego samego sygnału EA dla rozdzielczości 505 przedziałów w dziedzinie czasu i odpowiadający mu rozkład skuteczności klasyfikacji WNZ. Całkowita skuteczności klasyfikacji w tym przypadku wzrosła i wynosiła 91,0%.




Rys. 9.5. Spektrogram sygnałów EA generowanej przez WNZ Klasy 8, obliczony dla rozdzielczości w dziedzinie czasu równej 100 przedziałów.


W kolejnym etapie badań zmniejszono liczbę przedziałów w czasie do 100, a uzyskane wyniki przedstawiono odpowiednio na rys. 9.5 i 9.6. Całkowita skuteczność klasyfikacji wzrosła dla tego przypadku 93,4%.




Rys. 9.6. Rozkład skuteczności klasyfikacji dla badanej bazy danych przy rozdzielczości w dziedzinie czasu równej 100 przedziałów.




Rys. 9.7. Spektrogram sygnałów EA generowanej przez WNZ Klasy 8, obliczony dla rozdzielczości w dziedzinie czasu równej 8 przedziałów.



Rys. 9.8. Rozkład skuteczności klasyfikacji dla badanej bazy danych przy rozdzielczości w dziedzinie czasu równej 8 przedziałów.



Rys. 9.9. Spektrogram sygnałów EA generowanej przez WNZ Klasy 8, obliczony dla rozdzielczości w dziedzinie czasu równej 5 przedziałów.



Rys. 9.10. Rozkład skuteczności klasyfikacji dla badanej bazy danych przy rozdzielczości w dziedzinie czasu równej 5 przedziałów.


Na podstawie przedstawionego na rys. 9.10 rozkładu skuteczności klasyfikacji, można stwierdzić poprawę skuteczności rozpoznawania Klasy 6 względem Klasy 7, w stosunku do poprzednich konfiguracji deskryptora (Rys. 9.5 i Rys. 9.7). Całkowita skuteczność klasyfikacji wzrosła także w tym



przypadku i wynosi 95,6%. Dalsze zmniejszanie liczby przedziałów w dziedzinie czasu, powoduje równoczesne zmniejszenie skuteczności rozpoznawania poszczególnych Klas WNZ przez algorytm ZAM, co przedstawiono na rys. 9.11 i w sposób zbiorczy w tab. 9.1.

Tab.9.1. Zestawienie wybranych wyników skuteczności klasyfikacji ośmiu klas WNZ, uzyskane przy użyciu ZAM z zaimplementowanym deskryptorem czasowo-częstotliwościowym, dla różnej liczby przedziałów w dziedzinie czasu.

Liczba przedziałów w dziedzinie czasu	2	3	4	5	7	8	9	10	14	20	40	60	80	100	505	1020
Całkowita skuteczność klasyfikacji [%]	91,9	94,0	94,6	95,6	94,4	93,1	93,4	93,8	95,6	94,9	94,0	94,4	93,7	93,4	91,0	85,4



Rys. 9.11. Skuteczność klasyfikacji ośmiu klas WNZ, uzyskana przy użyciu ZAM, z zaimplementowanym deskryptorem czasowo-częstotliwościowym, w zależności od liczby przedziałów w dziedzinie czasu.


Uzyskane wyniki wskazują, że zaproponowany deskryptor może być wykorzystany do klasyfikacji podstawowych form WNZ, wraz z testowaną strukturą. Wartość całkowitej skuteczności klasyfikacji na poziomie 95,6%, uzyskane dla 5 i 14 przedziałów w dziedzinie czasu, można uznać za zadowalającą (Tab. 9.1, Rys. 9.11).



W dalszych obliczeniach zastosowano deskryptor czasowo-częstotliwościowy, w konfiguracji z 5 przedziałami w dziedzinie czasu, ponieważ jego skuteczność klasyfikacji, podobnie jak deskryptora z 14 przedziałami w dziedzinie czasu, była największa. Natomiast ilość danych, jaką musi przetworzyć algorytm ZAM, związana z zastosowaniem deskryptora w konfiguracji z 5 przedziałami w dziedzinie czasu, w porównaniu z zastosowaniem w analogiczny sposób, deskryptora z 14 przedziałami w dziedzinie czasu, jest blisko trzy razy mniejsza. Wynika to z faktu, że macierz opisująca sygnał, posiadający 5 przedziałów w dziedzinie czasu i 130 punktów uśredniania w dziedzinie częstotliwości, będzie miała rozmiar 5 kolumn i 130 wierszy, natomiast zwiększenie liczby przedziałów do 14, skutkuje rozbudową macierzy do 14 kolumn, przy jednoczesnym zachowaniu 130 wierszy.


10.Badanie zmodyfikowanej bazy danych za pomocą Zoptymalizowanego Algorytmu Multikomparacyjnego

Modyfikacja bazy danych polegała na dołączeniu do niej Klasy 9, którą scharakteryzowano rozdz. 6 niniejszej rozprawy. Testowanie zmodyfikowanej bazy danych przeprowadzono zgodnie z założeniami przyjętymi w rozdz. 9. Ze 100 przebiegów reprezentujących każdą z badanych Klas WNZ typowano na drodze losowej 15, które przyjmowano jako wzorcowe. Pozostałe 85 przebiegów poddawano pojedynczo procesowi klasyfikacji. Oznacza to, że nie mogła zaistnieć sytuacja, w której rozpoznawany przebieg był jednocześnie wzorcowym. Operację klasyfikacji wykonano kolejno dla każdej z dziewięciu Klas. Tym samym proces rozpoznawania przeprowadzono oddzielnie dla każdego z 765 przebiegów.



Rys. 10.1. Skuteczność klasyfikacji algorytmu ZAM dla Klasy 1 względem Klas pozostałych.

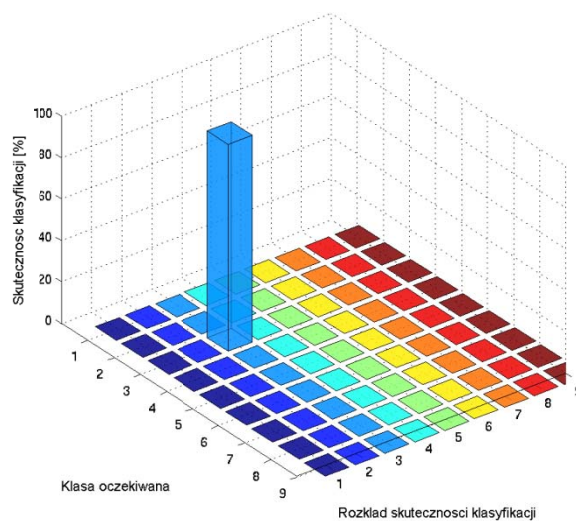
Na rys. 10.1 przedstawiono skuteczność klasyfikacji Klasy 1 względem Klas pozostałych, na którym można zaobserwować, że jest ona rozpoznawana ze skuteczności przekraczającą 96%. Jedyne błędne sklasyfikowania nastąpiły względem Klasy 2.




Rys. 10.2 Skuteczność klasyfikacji algorytmu ZAM dla Klasy 2 względem pozostałych Klas.



Na rys. 10.2 i 10.4 przedstawiono skuteczności klasyfikacji dla dwóch Klas WNZ. Są one rozpoznane w sposób właściwy. Odsetek niepoprawnych sklasyfikowań przebiegów wynosi jedynie 1,2%. Skuteczność klasyfikacji wynika ze struktury czasowo-częstotliwościowej sygnałów EA reprezentujących te Klasy. Struktura ta jest powtarzalna i nie posiada istotnych różnic, w ramach danej Klasy.




Rys. 10.3. Skuteczność klasyfikacji algorytmu ZAM dla Klasy 3 względem pozostałych Klas.






Rys. 10.4. Skuteczność klasyfikacji algorytmu ZAM dla Klasy 4 względem pozostałych Klas.

W przypadku Klasy 3 i 5 (Rys. 10.3 i 10.5) uzyskano analogiczne rezultaty jak dla Klasy 2 i 4. Z tą jednak różnicą, że nie nastąpiło ani jedno niepoprawne sklasyfikowanie.




Rys. 10.5. Skuteczność klasyfikacji algorytmu ZAM dla Klasy 5 względem pozostałych Klas.






Rys.10.6. Skuteczność klasyfikacji algorytmu ZAM dla Klasy 6 względem pozostałych Klas.




Rys. 10.7. Skuteczność klasyfikacji algorytmu ZAM dla Klasy 7 względem pozostałych Klas.

W przypadku Klasy 6 i 7 występują liczne błędne sklasyfikowania. Jest to konsekwencją dużego podobieństwa sygnałów EA generowanych przez obie formy WNZ. Wynika to z faktu, że reprezentują one ten sam typ układu wyładowczego, tj. iskiernik wieloostre- płyta, przy czym w przypadku Klasy 7 występowały dodatkowo przemieszczające się swobodnie pęcherzyki gazowe. Mogło więc dojść do sytuacji, w której WNZ nie występowały w pęcherzyku gazowym lecz bezpośrednio w oleju elektroizolacyjnym. Może to powodować stosunkowo dużą liczbę niepoprawnie sklasyfikowanych przebiegów względem Klasy 6. Ponadto istotne znaczenie mają także struktury czasowo-częstotliwościowe sygnału EA generowanego przez obie formy WNZ. Na wyznaczonych spektrogramach występują równocześnie składowe częstotliwościowe w szerokim spektrum częstotliwościowym. Istnieje więc dodatkowa trudność w znalezieniu częstotliwości charakterystycznych dla obu porównywanych form WNZ.



Rys. 10.8. Skuteczność klasyfikacji algorytmu ZAM dla Klasy 8 względem pozostałych Klas.


Klasa 8 i Klasa 9 (Rys. 10.8 i 10.9) są poprawnie rozpoznawane dla wszystkich badanych przebiegów. Potwierdza to konieczność uzupełnienia bazy wiedzy o dodatkową, 9 Klasę WNZ.



Rys. 10.9. Skuteczność klasyfikacji algorytmu ZAM dla Klasy 9 względem pozostałych Klas.



Rys. 10.10 przedstawia całkowitą skuteczność klasyfikacji dla wszystkich badanych Klas. Uzyskane wyniki uzupełniono o zestawienie tabelaryczne (Tab. 10.1).



Rys. 10.10. Całkowita Skuteczność klasyfikacji algorytmu ZAM.



Tab. 10.1. Całkowita skuteczność klasyfikacji algorytmu ZAM, dla badanej bazy danych, z wyszczególnieniem na skuteczności dotyczące poszczególnych Klas.

Klasa	Klasa 1	Klasa 2	Klasa 3	Klasa 4	Klasa 5
Skuteczność klasyfikacji dla poszczególnych klas [%]	96,5	98,8	100,0	98,8	100,0
Klasa	Klasa 6	Klasa 7	Klasa 8	Klasa 9	-----
Skuteczność klasyfikacji dla poszczególnych klas [%]	91,8	77,6	100,0	100,0	-----
Całkowita skuteczność klasyfikacji [%]	95,9				

Podsumowując, w niniejszym rozdziale przedstawiono wyniki badań, które przeprowadzono przy wykorzystaniu algorytmu ZAM i deskryptora czasowo-częstotliwościowego, dla bazy danych, zawierającej przebiegi EA generowane przez dziewięć podstawowych form WNZ. Wyładowania te mogą występować w wysokonapięciowych układach izolacyjnych transformatorów elektroenergetycznych podczas ich normalnej eksploatacji.

Wykazano również konieczność uzupełnienia opracowanej bazy danych o kolejną Klasę przebiegów, co spowodowało zwiększenie skuteczności rozpoznawania.



11. Wnioski

Na podstawie uzyskanych w rozprawie wyników pomiarowych i przeprowadzonych analiz można sformułować następujące wnioski:

- I. Na podstawie doniesień literaturowych [38, 48-60, 63, 66-76], można stwierdzić, że otrzymany wynik całkowitej skuteczności klasyfikacji, na poziomie 95,9% należy uznać za wysoce zadowalający. Wykazano więc, że klasyfikator oparty na algorytmie multikomparacyjnym, umożliwia rozpoznawanie jednoźródłowych form WNZ, rejestrowanych metodą EA, które są generowane w izolacji papierowo – olejowej, dla ściśle określonych warunków metrologicznych. Tym samym Autor niniejszej rozprawy, uważa postawioną w niej tezę za udowodnioną.

- II. Przebadano dwa rodzaje algorytmów multikomparacyjnych: KAM i ZAM. Najwyższe wyniki skuteczności klasyfikacji uzyskano dla algorytmu ZAM, z zastosowaniem deskryptora czasowo-częstotliwościowego. Dla bazy danych zawierającej 8 Klas WNZ, całkowita skuteczność klasyfikacji wyniosła 95,6% (tab. 9.1), natomiast rozbudowa bazy danych spowodowała wzrost całkowitej skuteczności klasyfikacji do 95,9% (tab. 10.1), ponieważ dla Klasy 9 uzyskano 100% skuteczność rozpoznawania. W przypadku bazy zawierającej 9 Klas WNZ, najniższa z otrzymanych skuteczności klasyfikacji dotyczyła Klasy 7 i wyniosła 77,6% (tab. 10.1). Większość niepoprawnych sklasyfikowań Klasy 7, występowała względem Klasy 6 (rys. 9.10). Zdaniem Autora było to spowodowane tym, że Klasy 6 i 7 reprezentują ten sam układ elektrod, to jest wielostrze-płyta, z tą różnicą, że w przypadku Klasy 7 w oleju izolacyjnym występują dodatkowo pęcherzyki powietrza. Stąd istnieje możliwość, że WNZ nie były generowane w pęcherzyku powietrza, ale występowało bezpośrednio w oleju. Dlatego wśród przebiegów reprezentujących Klasę 7, mogły się znaleźć przebiegi charakterystyczne dla Klasy 6. Jeżeli przebieg, który jest niecharakterystyczny dla danej



Kasy, został wylosowany jako przebieg wzorcowy, to mogło to mieć negatywny wpływ, na skuteczność procesu klasyfikacji. Częściowym rozwiązaniem tego problemu, jest zmiana sposobu typowania przebiegów wzorcowych, z losowania, na dobór wykonywany przez eksperta.

- III. Liczba przebiegów wzorcowych przy, której uzyskiwany jest optymalny wyniki procesu klasyfikacji został wyznaczona na poziomie 15. Jednakże jest to wartość przybliżona, ponieważ przebiegi wzorcowe są losowane oddzielnie, dla każdego procesu klasyfikacji. Dlatego może wystąpić sytuacja, w której podczas rozpoznawania przeprowadzonego dwukrotnie, w identycznych warunkach, uzyska się różniące się wyniki. Jednak z przeprowadzonych symulacji wynika, że różnica ta jest mało znacząca i w odniesieniu do skuteczności całkowitej, nie przekracza dziesiątych części procenta.
- IV. W przypadku zastosowania deskryptora czasowo-częstotliwościowego, w konfiguracji jaką zaproponował Autor niniejszej rozprawy, istotny wpływ na skuteczność klasyfikacji ma poprawne zastosowanie funkcji automatycznego wyzwalań karty pomiarowej. Liczba rejestrowanych próbek, poprzedzających sygnał wyzwalający proces rejestracji, musi być taka sama dla sygnałów badanych, jak dla sygnałów EA zapamiętanych w bazie danych i w niniejszej pracy przyjęto 5000 próbek.
- V. Zdaniem Autora, celowe jest wyselekcjonowanie przez eksperta grupy przebiegów, która będzie traktowana jako wzorcowa dla danej Klasy, zamiast przeprowadzania każdorazowego procesu ich losowania. Tego typu selekcja, powinna odbyć się na etapie prac wdrożeniowych i można ją traktować jako wprowadzenie dodatkowej wiedzy do systemu ekspertowego.



- VI.** Skuteczność klasyfikacji uzyskana za pomocą algorytmu KAM, w dużym stopniu zależy od zaimplementowanego w jego strukturze klasyfikatora binarnego. Natomiast w niewielkim stopniu zależy od zastosowanego kryterium oceny.
- VII.** Dla warunkach, w których zostały przeprowadzone symulacje, algorytmy KAM i ZAM wykazują bardzo zbliżoną skuteczność klasyfikacji, przy czym ZAM wykonuje czterokrotnie mniejszą liczbę, porównywalnych pod względem czasu obliczeń, operacji numerycznych.
- VIII.** Możliwa jest jednoznaczna klasyfikacja zdefiniowanych form WNZ, dla przebiegów EA w zakresie częstotliwości co najmniej od 65 kHz do 700 kHz.
- IX.** Dla uzyskania optymalnej skuteczności klasyfikacji, z wykorzystaniem deskryptora czasowo-częstotliwościowego, dla konfiguracji zaproponowanej przez Autora, istotnym zagadnieniem jest dobór odpowiedniej rozdzielczości, tego przekształcenia w dziedzinie czasu. W analizowanych przypadkach, najwyższe wartości skuteczności klasyfikacji uzyskano, przy zastosowaniu rozdzielczości na poziomie 5 i 14 przedziałów w dziedzinie czasu.
- X.** Zaproponowana forma WNZ typu ostrze-płyta, ze swobodnie przemieszczającymi się pęcherzykami gazowymi, jest poprawnie rozpoznawana przez zastosowany algorytm. Wprowadzenie jej do bazy danych, poszerza wiedzę na temat defektów izolacji papierowo-olejowej.



Bibliografia

1. Florkowska B.: Mechanizmy, pomiary i analiza wyladowań niezupełnych w diagnostyce układów izolacyjnych wysokiego napięcia, Polska Akademia Nauk, Warszawa, 2001.
2. Skubis J.: Wybrane zagadnienia z techniki i diagnostyki wysokonapięciowej, Of. Wyd. Pol. Op., Of. Wyd., Opole, 1998.
3. Boczar T.: Widma emisji akustycznej generowanej przez wyladowania niezupełne w izolacji olejowej, Pol. Op., Of. Wyd., 2000.
4. Florkowska B.: Analiza mechanizmów WNZ w układach elektroizolacyjnych wysokiego napięcia, Wyd. AGH, Kraków, 1995.
5. Włodek R.: Mechanizmy działania WNZ w dielektrykach, PWN, Warszawa, 1992,
6. Gacek Z.: Wysokonapięciowa technika izolacyjna, Wyd. Pol. Śl., Gliwice, 1996.
7. Flisowski Z.: Technika wysokich napięć, WNT, Warszawa, 1992.
8. Boczar T.: Identyfikacja formy wyladowania niezupełnego na podstawie jego widm częstotliwościowych emisji akustycznej, Rozprawa doktorska, Wydział EI. Pol. Śl. w Gliwicach, Gliwice, 1998.
9. Boczar T.: Identification of Fundamental Forms of PDs Based of the Results of Frequency Analysis of Their AE, Journal of Acoustic Emission, Vol. 17, No. 3-4, 1999, Los Angeles, USA , pp. 7-12.
10. Boczar T.: Możliwości identyfikacji formy wyladowania na podstawie widma częstotliwościowego jego EA, VI Symp. EUI, Zakopane, 1997, str. 35-40.
11. Boczar T.: Obiektywizacja wyników akustycznej metody oceny wyladowań niezupełnych przy zastosowaniu do opisu sygnałów analizy statystycznej i cyfrowych metod przetwarzania, Of. Wyd. Pol. Op., 2003.
12. Boczar T., Borucki S., Cichoń A., Lorenc M.: Rozpoznawanie wyladowań elektrycznych rejestrowanych metodą emisji akustycznej przy wykorzystaniu sieci neuronowych, Przegląd Elektrotechniczny – Konferencja 1'2005, Jubileuszowe X Sympozjum EUI'2005, Problemy



eksploatacji układów izolacyjnych wysokiego napięcia, Krynica, 27-30 września 2005, str. 30 – 33.

13. Boczar T.: Identification of Fundamental Forms of Partial Discharges Based of the Results of Frequency Analysis of Their Acoustic Emission, Proceedings of the International Conference AE, Brno, 1999, pp.13 – 19.
14. Boczar T., Borucki S., Cichoń A., Lorenc M.: Recognizing partial discharge forms measured by the acoustic emission method using the spectrum power density as a parameter of the artificial neuron network, The Molecular and Quantum Acoustics, Annual Journal, Vol. 26, 2005, pp. 35 – 44.
15. Kurtasz P., Boczar T.: The application of the optimized multicomparative algorithm for classifying acoustic signals, generated by partial discharges, cataloged in the modified database, Pomiary Automatyka Robotyka, Vol. 12, 2010, No 12, pp. 73-79.
16. Gacek Z.: Technika wysokich napięć, Skrypt Pol. Śl., Nr 183, Gliwice, 1994.
17. Fleszyński J., Lutyński B.: Ładunki przestrzenne i przedprzebiciowe zjawiska elektrohydrodynamiczne w cieczach izolacyjnych. II Symp.: Ładunek przestrzenny i zjawiska starzeniowe w dielektrykach, Zielona Góra , 1987, str. 45-51.
18. Szczepański Z., praca zbiorowa: Układy izolacyjne urządzeń elektroenergetycznych, WNT, Warszawa, 1978.
19. Filipczyński L.: Przetworniki i pola ultradźwiękowe, Problemy i Metody Współczesnej Akustyki, PWN, Warszawa-Poznań, 1989.
20. Zmarzły D., Szmechta M.: Badania kawitacji w olejach izolacyjnych, Przegląd Elektrotechniczny, Nr 10, 2008, str. 40-43.
21. Jezierski W.: Transformatory, WNT, Warszawa, 1983.
22. Lidmanowski W.: Zarys teorii wyładowań w dielektrykach, WNT, Warszawa, 1988.



23. Lechowski Z., Skowroński J.: Nowe spojrzenie na mechanizm przebiecia wywołany WNZ w warstwowych układach izolacyjnych, *Energetyka*, Nr 5, 1981, str. 177-181.
24. Wodziński J.: O korelacji pomiędzy wartościami intensywności WNZ, a szybkością degradacji izolacji papierowo-olejowej, *Symp. Problemy WNZ w układach elektroizolacyjnych*, PTETiS-AGH, Zakopane, 1975, str. 187-194.
25. Wodziński J.: *Wysokonapięciowa technika prób i pomiarów*, PWN, Warszawa, 1997.
26. Goliński J.: Powstawanie i rozwój WNZ powierzchniowych, *IV Symp. Problemy WNZ w układach elektroizolacyjnych*, Zakopane, 1983, str. 101-108.
27. Paciorek Z.: Wyładowania powierzchniowe przy napięciu przemiennym ze składową stałą, *II Symp. IWN Poznań-Kiekrz*, 1994, str. 193-197.
28. Zdanowski M.: Influence of Composition of Dielectric Liquid Mixtures on Electrostatic Charge Tendency and Physicochemical Parameters, *Dielectrics and Electrical Insulation*, IEEE Trans., Vol. 15, 2008, pp. 572-532.
29. Florkowska B.: *Diagnostyka wysokonapięciowych układów izolacyjnych urządzeń elektroenergetycznych*, Wyd. AGH, Kraków, 2009.
30. Filipczyński L.: *Wytwarzanie i obróbka fal ultradźwiękowych*, Akustyka molekularna i nieliniowa, IPPT-PAN, Warszawa, 1965.
31. Gronowski B.: *Propagacja sygnałów EA od WNZ w kondensatorach elektroenergetycznych*. Rozprawa doktorska, Wydz. EI. PW, Warszawa, 1989.
32. Bish N. B., Howson P. A., Howlett R. J.: Dielectric Condition Monitoring of High Voltage System Using Intelligent Partial Discharge Analysis, *Proceedings of 2nd International ICSC Symposium on Engineering of Intelligent Systems*, University of Paisley Scotland UK, June 2000, Vol. 2, pp. 644-650.



33. Wotzka D., Boczar T., Zmarzły D.: Analysis of acoustic wave propagation in a power transformer model, *Acta Physica Polonica A*, Vol. 116, No. 3, 2009, pp. 428-431.
34. Kucharska B.: Parametry EA emitowane przez WNZ, *Rozprawa Doktorska*, Wyd. EI. Pol. Śl. w Gliwicach, Gliwice, 1995.
35. Malecki I., Ranachowski J.: *Emisja akustyczna. Źródła, metody, zastosowania*, PAN-KBN, Warszawa, 1994.
36. Malecki I., Witos Z.: *Deskryptory emisji akustycznej*, *Prace IPPT – PAN*, Nr 39, Warszawa, 1993.
37. Wotzka D.: *Modelowanie sygnałów EA generowanej przez wybrane klasy WNZ*, *Rozprawa Doktorska*, WEAiI Politechniki Opolskiej, 2011.
38. Borucki S.: *Możliwości rozpoznawania form WNZ rejestrowanych metodą EA przy zastosowaniu sieci neuronowych*, *Rozprawa Doktorska*, WEAiI Politechniki Opolskiej, 2006.
39. Piotrowski J.: *Pomiarowe zastosowanie analizy sygnałów*, PWN, Warszawa, 1991.
40. Piotrowski J.: *Procedury pomiarowe i estymacje sygnałów*, *Skrypt Pol. Śl.*, Nr 1889, Gliwice, 1994.
41. Szabatın J.: *Podstawy teorii sygnałów*, WKiŁ, Warszawa, 2000.
42. Oppenheim A., V. (red.): *Sygnały cyfrowe*, WNT, Warszawa, 1982.
43. Wojtkiewicz A. (red.): *Cyfrowe przetwarzanie sygnałów*, Of. Wyd. PW, Warszawa, 1995.
44. Boczar T.: *Możliwości zastosowania do opisu sygnałów emisji akustycznej od wyładowań niezupełnych analizy statystycznej i cyfrowych metod przetwarzania sygnałów*, Of. Wyd. Pol. Op., Opole, 2003.
45. Białasiewicz J. T.: *Falki i aproksymacje*, WNT, Warszawa, 2000.
46. Debnath L.: *Wavelet Transforms and Time-Frequency Analysis*, Birkhauser, Boston, 2001.
47. Zieliński T. P.: *Od teorii do cyfrowego przetwarzania sygnałów*, Wyd. EAIiE AGH, Kraków, 2002.



48. Danikas M. G., Gao N., Aro M.: Partial Discharge Recognition Using Neural Networks: a review, *Electrical Engineering*, Vol. 85, 2003, pp. 87 – 93.
49. Gulski E., Kreuger F. H.: Computer - Aided Recognition of Discharge Sources, *IEEE Transactions on Electrical Insulation*, Vol. 27, No. 1, 1992, pp. 82-92.
50. Gulski E., Krivida A.: Neural Networks as a tool for recognition of partial discharges, *IEEE Transactions Dielectrics and Electrical Insulation*, Vol. 28, 1993, pp. 984 – 1001.
51. Hong T., Fang M. T. C., Hilder D.: PD Classification by the Modular Neural Network Based on Task Decomposition, *IEEE Transactions DEI*, Vol. 3, 1996, pp. 207 – 212.
52. Kexiong T., Fugil L.: Artificial Neural Networks Used for Partial Discharge Recognition, *High Voltage Engineering*, Vol. 22, 1996, pp. 3 – 6.
53. Mazroua A. A., Salama M. M., Bartnikas R.: Neural Networks System Using the Multilayer Perceptron Technique for Recognition of PD Pulse Shapes Due to Cavities and Electrical Trees, *IEEE Trans. Power Delivery*, Vol. 10, 1995, pp. 92 – 96.
54. Mazroua A. A., Salama M. M., Bartnikas R.: PD Pattern Recognition with Neural Networks Using the Multilayer Perceptron Technique, *IEEE DEI*, Vol. 28, 1993, pp. 1082 – 1089.
55. Satish L., Gururaj B. I.: Partial discharge pattern classification using multiplayer neural network, *Proceedings IEE A*, July 1993, pp. 323 – 330.
56. Satish L., Zaengl W. S.: Artificial Neural Networks for Recognition of 3-D Partial Discharge Patterns, *IEEE EI*, Vol. 1, No. 2, 1994, pp. 265 – 273.
57. Candela R., Mirelli G, Schifani R.: PD Recognition by Means of Statistical and Fractal Parameters and a Neural Network, *IEEE EI*, Vol. 7, No. 1, 2000, pp. 87 – 94.



58. Bish N. B., Howson P. A., Howlett R. J., Fawcett T. J., Hilder D. A., Black I. A.: Partial Discharge Monitoring Leading to the Diagnosis of Dielectric Breakdown Mechanisms Using Neural Network Analysis, 35th Universities Power Engineering Conference, Queens University Belfast, Vol. 2, 2001, pp. 825-829.
59. Bish N. B., Howson P. A., Howlett R. J., Fawcett T. J., Hilder D.: Intelligent Recognition of Partial Discharges in High Voltage Dielectrics, 36'h Universities Power Engineering Conference UPEC 2001, University of Wales Swansea 12 – 14, 2001, pp. 280-284.
60. Karthikeyan B., Gopal S., Venkatesh S.: Partial discharge pattern classification using composite versions of probabilistic neural network inference engine, Expert Systems with Applications: An International Journal archive, Vol. 34, Issue 3, April 2008, pp. 1938- 1947.
61. Borucki S., Boczar T., Cichoń A.: Comparative Analysis of Algorithms Teaching an Artificial Neural Network Used for Recognizing AE Signals Generated by PD Forms, VIII International Workshop for Candidates for a Doctor's Degree, OWD' 2006-21-24, October 2006, pp. 147 – 152.
62. Boczar T., Borucki S., Cichoń A., Lorenc M.: The assumptions of the expert system of examining insulation systems of power transformers based on the results obtained by using the acoustic emission method, 36th International Conference and Exhibition, Defektoskopie 2006, 7 - 9 November, 2006, pp. 31 – 35.
63. Borucki S., Boczar T.: Skuteczność rozpoznawania przez SSN podstawowych form WNZ przy wykorzystaniu wyników analizy czasowo-częstotliwościowej sygnałów EA, Przegląd Elektrotechniczny – konferencje 1'2006, VIII Ogólnopolskie Sympozjum Inżynieria Wysokich Napięć, Poznań – Będlewo, 8 – 10 maja 2006, str. 41 – 44.
64. Borucki S., Cichoń A., Boczar T.: The Possibilities of Time-Frequency Analysis to Identification of the Acoustic Emission Signals Generated by Multisource Partial Discharges, Acústica 2008 conference, 20-22 October 2008, Universidade de Coimbra, Portugal.



65. Borucki S., Cichoń A.: The influence of a Multilayer Paper-Oil Insulation of Power Transformers on the Measurement Results of Partial Discharges Measured by the Acoustic Emission Method, *Physics and Chemistry of Solid State*, V.7, No.1, 2006, pp. 160 – 166.
66. Ludpa S., Pattanadech N., Leelajindakraierk M., Yutthagowith P.: Pattern Classification of Partial Discharge in High Voltage Equipment by Regression Analysis, *Proceedings of ECTI-CON 2008*, ©2008 IEEE, pp. 921-924.
67. Hao L., Lewin P. L., Tian Y. and Dodd S. J.: Partial Discharge Identification Using a Support Vector Machine, *2005 Annual Report Conference on Electrical Insulation and Dielectric Phenomena*, 2005 IEEE, pp. 414 – 417.
68. He Y., Ou Z Y., Guo H.: A method of fingerprint identification based on space invariant transforms and support vector machines, *Proceedings of the second ICMLC, Xi'an, China, Nov 2003*, pp. 1322-1327.
69. Shawe-Taylor J., Christianini N.: *Kernel Methods for Pattern Analysis*, Cambridge University Press 2004.
70. Wang P., Lewin P L., Tian Y., Sutton S J, Swingler S G.: Application of Wavelet-Based De-noising to Online Measurement of Partial Discharges, *Proceedings of the 2004 IEEE ICSD, Toulouse France, Vol. 2, July 2004*, pp. 699 702.
71. Hao L., Lewin P. L. and Dodd S.: Comparison of support vector machine based partial discharge identification parameters, In *Conference record of the 2006 IEEE International Symposium on Electrical Insulation*, June 2006, pp 110-113.
72. Hunter J. A., Hao L., Lewin P. L., Evagorou D., Kyprianou A. and Georghiou G. E.: Comparison of two partial discharge classification methods, 978-1-4244-6301-5, 2010 IEEE.
73. Gulski E. and Kreuger F. H.: Computer-aided recognition of partial discharge sources, *IEEE Trans. on Electric. Insul.*, Vol. 27, February 1992, pp. 82-92.



74. Chen X., Cavallini A., Montanari G. C.: Statistical Analysis and Fuzzy Logic Identification of Partial Discharge in Paper-Oil Insulation Systems, Proceedings of the 9th International Conference on Properties and Applications of Dielectric Materials July 19-23, 2009, Harbin, China, 978-1-4244-4368-0/09/\$25.00 ©2009 IEEE, pp. 505 – 508.
75. Chalashkanov N., Kolev N., Dodd S., Fothergill J.C.: PD Pattern Recognition Using ANFIS, 2008 Annual Report Conference on Electrical Insulation Dielectric Phenomena, 978-1-4244-2549-5/\$25.00 2008 IEEE, pp. 417-420.
76. Park Seong-Hee, Jung Hae-Eun, Yun Jae-Hun, Kim Byoung-Chul, Kang Seong-Hwa, Lim Kee-Joe: Classification of Defects and Evaluation of Electrical Tree Degradation in Cable Insulation Using Pattern Recognition Method and Weibull Process of Partial Discharge, International Conference on Condition Monitoring and Diagnosis, Beijing, China, April 21-24 2008, 978-1-4244-1622-6/08/\$25.00 ©2007 IEEE.
77. EA System, EA Signal Conditioner, instrukcja obsługi, Warszawa, 2001.
78. Witkowski P., Kurtasz P., Boczar T.: Wpływ ilości źródeł wyładowań niezupełnych na otrzymywane wyniki mierzone metodą emisji akustycznej, Zeszyty Naukowe Politechniki Opolskiej Nr 338/2010, Opole, 12.2010, str. 71 – 79.
79. Skubis J.: Emisja akustyczna w badaniach izolacji urządzeń elektroenergetycznych, Polska Akademia Nauk, IPPT, Opole, 1998.
80. Boczar T.: Identification of a specific type of partial discharges form acoustic emission frequency spectra, IEEE Trans. Dielectr. Electr. Insul., Vol. 11, No. 3, 2001, JW.
81. Boczar T., Borucki S., Cichoń A.: Wzorce wyładowań niezupełnych mierzonych metodą emisji akustycznej, Energetyka Nr 5 (659), maj 2009, ISSN 0013-7294, str. 278 – 283.



82. Boczar T., Borucki S., Cichoń A., Lorenc M.: Time-frequency analysis of the AE signal generated by PDs onbushing and stand-off insulators, Quarterly Archive of Acoustics (Supplement), Vol. 31, No. 4, Warszawa 2006, pp. 325-334.
83. Zmarzły D., Zmarzły M., Koszałka L.: Multikomparacyjny algorytm klasyfikacji wykorzystujący punktową separację parametrów, Komputerowe Systemy Rozpoznawania, KOSYR, 1999, str. 1-6.
84. Rutkowski L.: Metody i techniki sztucznej inteligencji, WN PWN, Warszawa, 2006.
85. Kurtasz P., Boczar T., Witkowski P., Lorenc M.: Zastosowanie algorytmu multikomparacyjnego do klasyfikacji sygnałów akustycznych pochodzących od wyładowań niezupełnych, Przegląd Elektrotechniczny, 07/2010.
86. Kurtasz P., Boczar T.: Analiza porównawcza Zoptymalizowanego i Klasycznego Algorytmu Multikomparacyjnego w zastosowaniu do klasyfikacji sygnałów akustycznych generowanych przez wyładowania niezupełne, Pomiar Automatyka Kontrola, 09/2010.
87. Kurtasz P., Boczar T.: Klasyfikacja sygnałów akustycznych pochodzących od wyładowań niezupełnych z zastosowaniem Zoptymalizowanego Algorytmu Multikomparacyjnego oraz deskryptora czasowo- częstotliwościowego, Przegląd Elektrotechniczny, 11/2010, IWN 2010.
88. Rosołowski E.: Cyfrowe przetwarzanie sygnałów w automatyce elektroenergetycznej, Ak Of. Wyd. EXIT, Warszawa, 2002.
89. Kurtasz P., Boczar T.: The application of the optimized multicomparative algorithm for classifying acoustic signals, generated by partial discharges, cataloged in the modified database, Pomiar Automatyka Robotyka ,12/2010.
90. Salama M. M. A., Bartnikas R.: Determination of neural-network topology for partial discharge pulse pattern recognition, IEEE Tran., Vol. 13, No. 2, 2002, pp. 446-456.



91. Candela R.: PD Recognition by Means of Statistical and Fractal Parameters and a Neural Network, IEEE Transactions on Dielectrics and electrical Insulation, Vol.7, No. 1, February 2000.
92. Young Chan Choi, Seung Wan Jung, Soo Nam Kim, Seong Il Kim, Joong Lok Kwon: Development of automatic identification method for GIS PD (Partial Discharge) defects diagnosis, Power Tech, 2007, IEEE Lausanne 978-1-4244-2189-3.
93. Evagorou D., Kyprianou A., Lewin P.L., Stavrou A., Efthymiou V., Metaxas A.C., Georghiou1 G.E.: Feature extraction of partial discharge signals using the wavelet packet transform and classification with a probabilistic neural network, IET Sci. Meas. Technol., 2010, Vol. 4, Iss. 3, pp. 177– 192 do: 10.1049/iet-smt.2009.0023, The Institution of Engineering and Technology 2010.
94. Salama M. M. A.: Fuzzy logic applied to PD pattern classification, IEEE Transactions on Dielectrics and Electrical Insulation, Vol.7, No. 1, 2000, pp. 118-123.
95. Jeong-Tae Kim, Won Choi, Sung-Kwun Oh, Keon-Jun Park, Gil-Sung Kim, Grzybowski S.: Fuzzy-Neural Networks (FNNs) Algorithm for Partial Discharge Pattern Recognition, 2008 International Conference on High Voltage Engineering and Application, Chongqing, China, November 9-13, 2008 978-1-4244-2810-6/08/\$25.00 ©2008 IEEE.
96. Canxin Guo, Li Zhang, Yong Qian, Chengjun Huang, Hui Wang, Linpeng Yao, Xiuchen Jiang: Application of Adaptive Neuro Fuzzy Inference System to the Partial Discharge Pattern Recognition, the sample data, 978-1-4244-4738-1/09/\$25.00 ©2009 IEEE.
97. Azizian Fard M., Asghar Akbari, Reza Shojaee, Reza Mirzaei H., Peyman Naderi: Partial Discharge Defects Classification Using Neuro-Fuzzy Inference System.
98. 2010 International Conference on Solid Dielectrics, Potsdam, Germany, July 4-9 2010, 978-1-4244-7944-3/10/\$26.00 ©2010 IEEE.
99. Kouadria D., Watt G.: The Use Of Statistical Techniques For The Identification Of Partial Discharges In Electrical Machines 1999 The



institution of Electrical Engineers, Printed and published by the IEE, Savoy Place, London WC2R OBL, UK.

100. Kouadria D., Watt G.: The Use Of Statistical Techniques For The Identification Of Partial Discharges In Electrical Machines 1999 The institution of Electrical Engineers, Printed and published by the IEE, Savoy Place, London WC2R OBL, UK.
101. Kundu P., Kishore N.K. and Sinha A.K.: Frequency Domain Analysis of Acoustic Emission Signals for Classification of Partial Discharges, 2007 Annual Report Conference on Electrical Insulation and Dielectric Phenomena, 1-4244-1482-2/07/\$25.00 ©2007 IEEE.
102. Contin A., Pastore S.: Classification and Separation of Partial Discharge Signals by Means of their Auto-correlation Function Evaluation, IEEE Transactions on Dielectrics and Electrical Insulation, Vol. 16, No. 6; December 2009 1070-9878/09/\$25.00 © 2009 IEEE.
103. Evagorou D., Kyprianou A., Georghiou G. E., Hunter J. A., Hao L., Lewin P. L.: Performance of the Support Vector Machine Partial Discharge classification method to noise contamination using phase synchronous measurements, 2010 Annual Report Conference on Electrical Insulation and Dielectric Phenomena, 978-1-4244-9470-5/10/\$26.00 ©2010 IEEE.
104. Kundu P., Kishore N.K., Sinha A.K.: Classification of Acoustic Emission Based Partial Discharge in Oil Pressboard Insulation System using Fractal Features, 2010 Annual Report Conference on Electrical Insulation and Dielectric Phenomena, 978-1-4244-9470-5/10/\$26.00 ©2010 IEEE.
105. Zdanowski M.: Static electrification properties of hexane and cyclohexane mixtures, Dielectric Liquids, 2008, ICDL 2008, IEEE International Conference on 978-1-4244-1585-4.
106. Strona internetowa firmy Acquitek: <http://www.acquitek.com/>, stan na dzień 04.06.2011,
107. Krupka J., Morawski R., Opalski L.J. : "Metody numeryczne". Of. Wyd. Pol. War., Warszawa, 1997,



Rozprawa doktorska: „Zastosowanie algorytmu multikomparacyjnego do klasyfikacji sygnałów emisji akustycznej generowanych przez wyładowania niezupełne”

108. Zydrón P.: Wybrane zagadnienia analizy czasowej i częstotliwościowej wyładowań niezupełnych, AGH, Kraków, 2001.
109. Oppenheim A. V., Schfer R. W.: Discrete-Time Signal Processing, Englewood Cliffs, New York, Prentice-Hall, 1989.
110. Cichoń A. :Nowa metoda diagnostyki stanu technicznego podobciążeniowych przełączników zaczepów, Politechnika Opolska, Of. Wyd. P.O., Opole, 2011.
111. AE Sensor Name WD type AH 17 Calibration Certificate, Physical Acoustics Corporation 2005.