



Grzegorz MALITOWSKI

Politechnika Śląska, Instytut Elektroenergetyki i Sterowania Układów

Próba identyfikacji wyładowań niezupełnych w wybranych modelowych układach izolacyjnych

Streszczenie. W artykule dokonano próby identyfikacji wnz przyelektrodowych z wykorzystaniem elektrycznej metody pomiarowej. Analiza danych pomiarowych oparta jest na parametrach statystycznych obliczanych na podstawie wybranych rozkładów fazowych i intensywności wnz. Wykorzystano sztuczne sieci neuronowe (implementowane w pakiecie Matlab 6), umożliwiające klasyfikację wybranych danych pomiarowych z wykorzystaniem wcześniej utworzonej bazy odcisków wnz.

Abstract. (An attempt on partial discharge recognition in selected simple insulating systems). The attempt on recognition of high voltage/earthed electrode bounded cavities in selected samples is presented in the paper. The measurements are proceeded with ultra wide band discharge analyzer. The analysis is based on statistical evaluation of partial discharge distributions and other quantities. The neural network based (implemented in Matlab 6) recognition is used for classification of collected data – PD fingerprints.

Słowa kluczowe: wyładowania niezupełne, wnz, odcisk wnz, defekty przyelektrodowe, sztuczne sieci neuronowe.
Keywords: partial discharge, PD, fingerprint, electrode-bounded cavity, artificial neural networks.

Wstęp

Identyfikacja wyładowań niezupełnych (wnz) może służyć do określania rodzajów defektów występujących w wysokonapięciowych układach izolacyjnych. Zakres opisywanych badań dotyczy wyładowań mierzonych w modelowanych defektach przyelektrodowych w wybranych próbkach materiałowych. Pomiar wykonano z wykorzystaniem metody elektrycznej przy użyciu detektora TE 571, firmy Haefely Trench. Analiza została przeprowadzona w oparciu o parametry statystyczne generowane przez oprogramowanie detektora, które opisują wybrane rozkłady fazowe i intensywności mierzonych wielkości [1]:

- rozkłady fazowe maksymalnej wartości ładunku pozornego wyładowań $H_{qmax}(\varphi)$;
- rozkłady fazowe średniej wartości ładunku pozornego wyładowań $H_{qn}(\varphi)$;
- rozkłady fazowe liczby wyładowań $H_n(\varphi)$;
- rozkłady intensywności wyładowań zależnie od ładunku $H(q)$ i energii wyładowań $H(p)$.

Wybrano 29 parametrów statystycznych liczonych dla powyższych rozkładów wnz (zestawione w tabeli 1) – dalej nazywane odciskiem wnz [3, 4]. Są to współczynniki:

- asymetrii (As);
- korelacji (CC);
- skośności (Sk);
- skupienia (Ku);
- określające liczbę maksimów ($Peak$);
- określające różnicę napięcia zapłonu w dwóch półokresach (PF).

Tabela 1. Zestawienie współczynników statystycznych liczonych dla wybranych rozkładów (+/- oznacza, że dany współczynnik liczony jest osobno dla dodatniej i ujemnej połówki okresu).

| | $H_{qmax}(\varphi)$ | $H_{qn}(\varphi)$ | $H_n(\varphi)$ | $H(q)$ | $H(p)$ | Σ |
|----------|---------------------|-------------------|----------------|--------|--------|----------|
| As | 1 | 1 | 1 | x | x | 3 |
| CC | 1 | 1 | 1 | x | x | 3 |
| Sk | 2 (+/-) | 2 (+/-) | 2 (+/-) | 1 | 1 | 8 |
| Ku | 2 (+/-) | 2 (+/-) | 2 (+/-) | 1 | 1 | 8 |
| $Peak$ | 2 (+/-) | 2 (+/-) | 2 (+/-) | x | x | 6 |
| PF | x | 1 | x | x | x | 1 |
| Σ | | | | | | 29 |

Identyfikacja wnz w dalszej części artykułu opiera się o wykorzystanie techniki sztucznych sieci neuronowych (ssn) do klasyfikacji wyników pomiarów. Do tego celu wykorzystano odcisk wnz jako wektor wejściowy dla wybranych ssn.


Dobór próbek i układ pomiarowy

Do badań wykorzystano trzy próbki, w których zamodelowano defekty przyelektrodowe w kształcie walca umieszczone osiowo. Próbki różniły się między sobą jedynie średnicą zamodelowanego defektu. Wymiary próbek zestawiono w tabeli 2.

Tabela 2. Wymiary próbek


| Numer próbki: | 1 | 2 | 3 |
|---------------------------------|------|-----|-----|
| Średnica defektu (mm) | 2,9 | 3,3 | 5,0 |
| Głębokość defektu (mm) | 0,7 | | |
| Średnica zewnętrzna próbki (mm) | 40,0 | | |
| Odstęp między elektrodami (mm) | 5,0 | | |

Próbki umieszczano między dwoma elektrodami: płaską oraz dopasowaną do wgłębienia próbki (z miejscem na gumową uszczelkę), ponieważ układ badano w oleju. Dla zapewnienia dobrego przylegania elektrod do powierzchni próbki i uszczelnienia układu zastosowano odpowiedni uchwyt z tekstolitu (rys 1.)



Rys. 1. Elementy układu badanego: a) przekrój układu; b) kompletny układ z zamontowanym dociskiem i przewodami zasilającymi; 1 – elektrody, 2 – próbka, 3 – uszczelka

Wszystkie pomiary wykonywano w układzie, którego schemat pokazany jest na rysunku 2. Należy podkreślić, że układ zasilany jest poprzez transformator separujący i umieszczony w klatce Faradaya (z niezależnym systemem uziemienia).



Rys. 2. Schemat układu pomiarowego: 1 – transformator probierczy, 2 – obiekt badany, 3 – kondensator, 4 – czwórnik sprzęgający, 5 – przewód łączący (ekranowany), 6 – detektor TE-571, 7 – kalibrator KAL 451

Plan pomiarów i przetwarzanie danych

Do badań wykorzystano trzy różne próbki, podłączane na dwa sposoby: z defektem znajdującym się po stronie elektrody wysokiego napięcia (HV), bądź po stronie elektrody uziemionej (LV). Uzyskano w ten sposób 6 różnych próbek. Pomiarów przeprowadzono przy napięciu równym 110% wartości napięcia, przy którym następował zapłon wyładowań w poszczególnych układach.

Dla potrzeb weryfikacji, czy faktycznie mierzone są wnz w modelowanym defekcie, przeprowadzono pomiary dla każdej próbki z defektem wypełnionym olejem.

Czas każdego pomiaru ustalono na 20 minut i podzielono na cztery przedziały rejestracji po 5 minut każdy. Na podstawie zarejestrowanych danych z jednego cyklu pomiarowego wygenerowano cztery odciski wnz. Każdy z sześciu układów badanych poddano 15 cyklom pomiarowym, uzyskując w sumie 90 zestawów po 4 odciski wnz, czyli w sumie 360 odcisków.

W celu wykorzystania ssn zebrane dane podzielono na cztery zbiory, schematycznie przedstawione na rysunku 3:

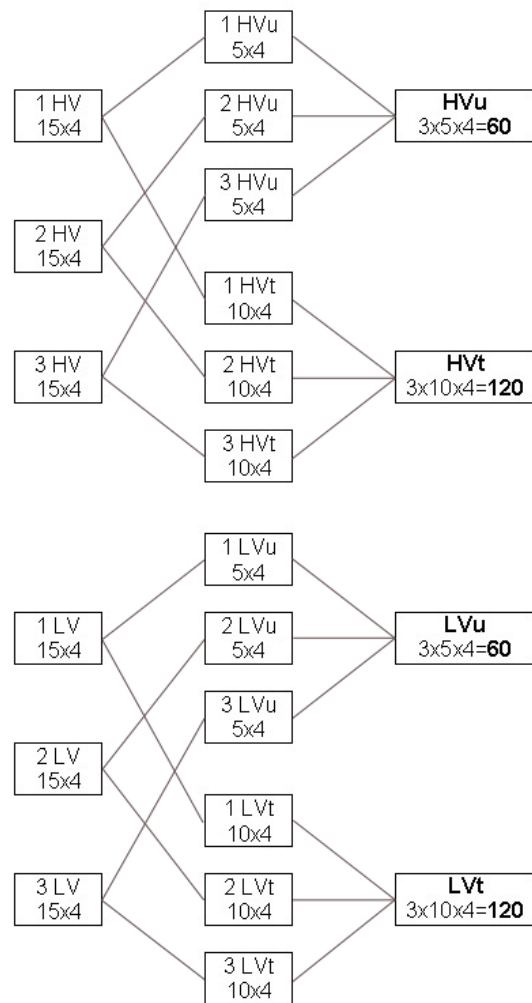
- 1) „odciski wnz uczące HV” pochodzące z 3, 6, 9, 12 i 15 cyklu pomiarowego każdej próbki z defektem umiejscowionym po stronie elektrody wysokiego napięcia ($HVu=1HV+2HVu+3HVu$);
- 2) „odciski wnz uczące LV” pochodzące z 3, 6, 9, 12 i 15 cyklu pomiarowego każdej próbki z defektem umiejscowionym po stronie elektrody uziemionej ($LVu=1LVu+2LVu+3LVu$);
- 3) „odciski wnz sprawdzające HV” pochodzące z 1, 2, 4, 5, 7, 8, 10, 11, 13, i 14 cyklu pomiarowego każdej próbki z defektem umiejscowionym po stronie elektrody wysokiego napięcia ($HVt=1HVt+2HVt+3HVt$);
- 4) „odciski wnz sprawdzające LV” pochodzące z 1, 2, 4, 5, 7, 8, 10, 11, 13, i 14 cyklu pomiarowego każdej próbki z defektem umiejscowionym po stronie elektrody wysokiego napięcia ($LVt=1LVt, 2LVt, 3LVt$).

Sieci neuronowe zastosowane w badaniach pełnią funkcję klasyfikatora wektorowego, przypisującego wzorzec w procesie uczenia sieci - odpowiedniej grupie. Z uwagi na zbliżony kształt defektów zdecydowano się na zbudowanie sieci neuronowej, której zadaniem byłaby klasyfikacja danych jako pochodzących od wyładowań występujących w defekcie po stronie elektrody wysokiego napięcia (HV), bądź po stronie elektrody uziemionej (LV).


Do tych celów wybrano jednokierunkową sieć trzywarstwową z sigmoidalnymi bipolarnymi funkcjami aktywacji wszystkich neuronów. W ramach dochodzenia do optymalnej architektury sieci (wykazującej najlepsze zdolności generalizacji) sprawdzono sieci o następującej strukturze (rys. 4.):

- 29 neuronów w warstwie wejściowej (liczba elementów odcisku wnz);
- 3 do 14 neuronów w warstwie ukrytej;

- 2 neurony w warstwie wyjściowej (liczba rodzajów rozpoznawanych przez sieć wnz – dwie grupy - HV i LV).




Rys. 3. Schemat podziału danych pomiarowych



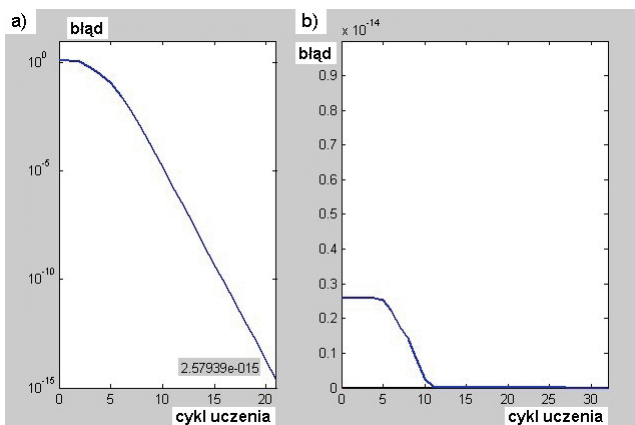
Rys. 4. Uproszczony schemat struktury zastosowanych ssn

W procesie uczenia sieci wykorzystano 120 wektorów uczących, dla których znane były odpowiedzi sieci. Jedna połowa tych wektorów pochodziła ze zbioru HVu, natomiast druga - ze zbioru LVu.

Układ zaimplementowano w pakiecie Matlab 6. Uczeniu poddano 12 wyżej przedstawionych struktur sieci neuronowych z wykorzystaniem procedury „trainlm” (korekcja wag oparta na algorytmie Levenberga-Marquardta) [5]. Założono maksymalną wartość błędu na poziomie 10^{-30} . Po zakończonym procesie nauki wszystkie zaimplementowane sieci poddano sprawdzeniu z wykorzystaniem danych z zbiorów HVt i LVt (w sumie 240 wektorów testujących). Procentową liczbę poprawnych identyfikacji dla wszystkich sieci przedstawia diagram na rysunku 5. Z przedstawionych wyników widać, że najlepsze rezultaty uzyskuje się za pomocą struktury opatrzonej numerem 4. Jest to sieć z sześcioma neuronami w warstwie ukrytej. Na rysunku 6 przedstawiony jest proces uczenia tej sieci – po 53 cyklach uczących błąd dla danych uczących osiąga wartość zero.



Rys. 5. Procentowa liczba poprawnych klasyfikacji dla 12 wybranych sieci



Rys. 6. Uczenie sieci – minimalizacja błędów dla różnych granicznych wartości gradientu: a) min.grad=1e-10; b) kontynuacja dla min.grad=1e-1000

Dokładne działanie sieci dla danych sprawdzających (HVT i LVt) przedstawione jest na rysunku 7. Zakładając, że wektor wyjściowy ma postać [neuron1; neuron2], gdzie neuron1(2) to wartości poszczególnych wyjść sieci, poprawne działanie sieci charakteryzuje się odpowiednim wyjściem:

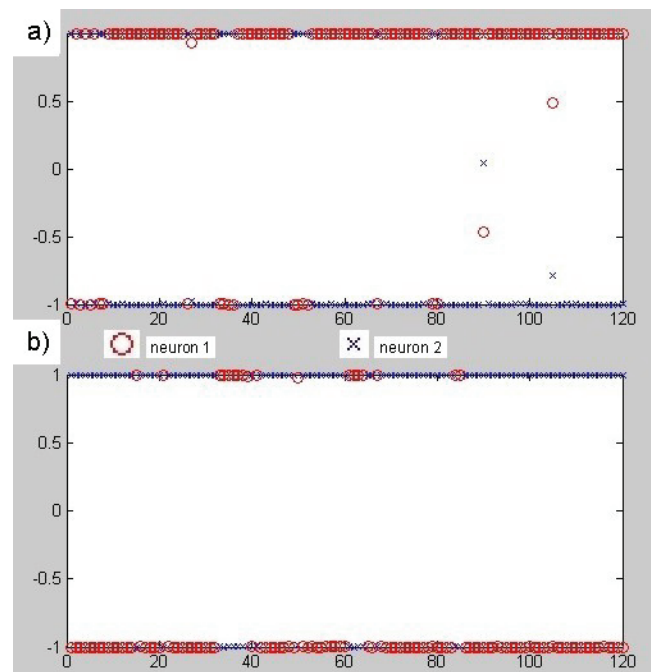
- [1; -1] dla danych HVT;
- [-1; 1] dla danych LVt.

Na rysunku 8 przedstawiona jest procentowa liczba poprawnych identyfikacji dla poszczególnych próbek. Widoczna jest tu wyraźna tendencja wzrostu poprawności działania sieci wraz ze wzrostem rozmiarów defektu; defekt w próbce 3 miał największe rozmiary.


Podsumowanie

Wybrana struktura sieci neuronowej pozwala na dobrą identyfikację wnz (95%) dla próbek o największej średnicy defektu. Wraz ze zmniejszaniem się rozmiarów wtrąciny przebiegowej skuteczność działania sieci spada. Skrajnie, dla próbki nr 1 liczba poprawnych identyfikacji jest na poziomie 75%. Należy podkreślić, że dane testujące nie były prezentowane sieci w procesie uczenia. Znaczącą rolę o niskim poziomie ładunku (przy próbach wykonanych z defektami całkowicie wypełnionymi olejem), można stwierdzić, że rejestrowane wnz występują w defektach modelowanych, a nie poza nimi.

W celu uzyskania lepszej identyfikacji defektów należy rozważyć zastosowanie ssn do analizy trójwymiarowych obrazów fazowych wnz, z liczbą wyładowań zakodowaną w postaci kolorów.



Rys. 7. Wartości wyjść sieci dla danych sprawdzających: a) HVT; b) LVt
próbka nr 1 – odciski 1 do 40, próbka nr 2 – odciski 41 do 80, próbka nr 3 – odciski 81 do 120



Rys. 8. Procentowa liczba poprawnych identyfikacji dla poszczególnych próbek

LITERATURA

- [1] Partial Discharge Detector Type TE 571 – Operation Manual, *Tettex Instruments v. 4.0* (2000)
- [2] Florkowska B., Wyładowania niepełne w układach izolacyjnych wysokiego napięcia – analiza mechanizmów, form i obrazów, *PAN-IPPT, Warszawa, 1997*
- [3] Gulski E., Kreuger F.H., Computer-aided recognition of Discharge Sources, *IEEE Trans. on Electrical Insulation*, vol. 27 (1992), 82-92
- [4] Malitowski G., Analiza powtarzalności pomiarów wyładowań niepełnych w wybranych układach pomiarowych, *Przegląd Elektrotechniczny - Konferencje*, 1/2006, 152-154
- [5] Osowski S., Sieci neuronowe do przetwarzania informacji, *Oficyna Wydawnicza Politechniki Warszawskiej, Warszawa, 2000*

Autor: mgr inż. Grzegorz Malitowski, Politechnika Śląska, Instytut Elektroenergetyki i Sterowania Układów, ul. Krzywoustego 2, 44-100 Gliwice, e-mail: grzegorz.malitowski@polsl.pl