

**Tomasz PIOTROWSKI**

Politechnika Łódzka, Instytut Elektroenergetyki

## **Porównanie skuteczności rozpoznawania defektów transformatorów na podstawie stężeń gazów rozpuszczonych w oleju przez SSN trenowaną z nadzorem i bez nadzoru**

**Abstract.** *The paper presents and compares the effectiveness of detecting defects in transformers based on the analysis of gases dissolved in oil for two types of artificial neural networks. One of the network was trained in so called the supervised and the second one in unsupervised mode. To train and verify the neural network author used the real measurement data.*

**Słowa kluczowe:** transformator energetyczny, DGA, sztuczna sieć neuronowa

### **Wstęp**

Podstawową metodą stosowaną w diagnostyce transformatorów o izolacji papierowo-olejowej, ze względu na swą prostotę, potwierdzoną skuteczność i brak konieczności wyłączenia transformatora z ruchu jest metoda analizy gazów rozpuszczonych w oleju.

Pomimo tego, że metoda DGA (Dissolved Gas Analysis) charakteryzuje się dużą skutecznością, to jednak występują takie kombinacje stężeń gazów, dla których wykorzystywane w niej schematy interpretacyjne nie pozwalają na określenie charakteru defektu. Zastosowanie technik sztucznej inteligencji, a wśród nich sztucznych sieci neuronowych (SSN) pozwala ograniczyć liczbę takich przypadków [1].

Ponieważ istnieje szereg koncepcji realizacji SSN istotne jest porównanie ich skuteczności w wykrywaniu różnych typów defektów transformatora. Autor poddał weryfikacji dwie sieci: jedna trenowana była w trybie z nadzorem druga zaś bez nadzoru.

### **Tradycyjny sposób wykrywania i rozpoznawania defektów**

Postępowanie mające na celu wypracowanie diagnozy na podstawie pomierzonego składu gazów rozpuszczonych w oleju podzielone jest na dwa etapy. W pierwszym etapie sprawdza się, czy stężenia gazów przekraczają wartości typowe. W warunkach krajowych za wartości typowe powszechnie przyjmuje się te podawane przez Energopomiar [2]. Jeśli przekroczenie ma miejsce chociażby dla jednego z gazów, wtedy określany jest charakter potencjalnego defektu. Standardowo stosuje się schemat wnioskowania podany w PN-IEC 60599 [3].

W przywołanej normie możliwe jest rozpoznanie defektu cieplnego o różnym zakresie temperatur, wylądowań niepełnym oraz wylądowań o małej i dużej energii. W tym celu wykorzystywane są informacje o stężeniach następujących gazów: H<sub>2</sub> (wodór), CH<sub>4</sub> (metan), C<sub>2</sub>H<sub>2</sub> (acetylen), C<sub>2</sub>H<sub>4</sub> (etylen) i C<sub>2</sub>H<sub>6</sub> (etan), na podstawie których wyznacza się wartości 3 tak zwanych ilorazów charakterystycznych. Sposób kojarzenia charakteru defektu z wartościami ilorazów charakterystycznych podano w tabeli 1.

Tabela 1. Sposób uzyskiwania informacji o defekcie w metodzie proponowanej w normie PN-IEC 60599 [3].

Defekt	Oznaczenie	C <sub>2</sub> H <sub>2</sub> /C <sub>2</sub> H <sub>4</sub>	CH <sub>4</sub> /H <sub>2</sub>	C <sub>2</sub> H <sub>4</sub> /C <sub>2</sub> H <sub>6</sub>
Wyładowania niezupełne	PD	wd <sup>1)</sup>	<0,1	<0,2
Wyładowania niskoenergetyczne	D1	>1	0,1 – 0,5	>1
Wyładowania wysokoenergetyczne	D2	0,6 – 2,5	0,1 – 1	>2
Defekt cieplny t<300°C	T1	wd	>1 ale wd	<1
Defekt cieplny 300°C <t<700°C	T2	<0,1	>1	1 - 4
Defekt cieplny t>700°C	T3	<0,2	>1	>4
1) wd – wartość dowolna				

### Charakterystyka trenowanych sieci

Sztuczna sieć neuronowa jest zbiorem połączonych neuronów, które zależnie od przyjętej architektury, mogą być dodatkowo pogrupowane w warstwy. Przed zastosowaniem SSN do rozwiązywania określonego problemu musi ona zostać wytrenowana. Podczas trenowania (inaczej zwanego uczeniem) cała „wiedza” zapisywana i gromadzona jest w postaci wag. Proces uczenia sieci może odbywać się w trybie z nauczycielem lub w trybie bez nauczyciela.

W trybie uczenia z nauczycielem sieci prezentowane są tzw. wektory uczące składające się z danych wejściowych oraz oczekiwanych (wzorcowych) odpowiedzi. W trakcie nauczania przeprowadzana jest modyfikacja wag, aby zminimalizować błąd między otrzymywaną odpowiedzią na wyjściu sieci, a zadaną odpowiedzią wzorcową. Najbardziej znanym algorytmem trenowania stosowanym w przypadku sieci z warstwą ukrytą jest algorytm wstecznej propagacji błędów.

W przypadku sieci trenowanej w trybie bez nauczyciela wektor uczący składa się tylko z danych wejściowych, nie zawiera zaś odpowiedzi referencyjnych, z którymi porównywany jest sygnał pojawiający się na jej wyjściu, co umożliwia automatyczną korekcję działania sieci. Sieć może być uczona za pomocą algorytmów typu: „Zwycięzca bierze wszystko” („Winner Takes All” – WTA) lub też algorytmów typu „Zwycięzca bierze większość” („Winner Takes Most” – WTM). W pierwszym przypadku modyfikowane są wagi tylko jednego neuronu, w drugim zaś również wagi neuronów sąsiadujących z neuronem „zwycięzcą”. Autor do analizy wybrał sieć trenowaną algorytmem WTA.

Projektując obydwie typy sieci przyjęto wspólne założenia dotyczące liczby i rodzaju danych wejściowych oraz rozpoznawanych defektów. Na wejście sieci podawano wartości pięciu stężeń gazów powszechnie wykorzystywane w analizach DGA: H<sub>2</sub>, CH<sub>4</sub>, C<sub>2</sub>H<sub>2</sub>, C<sub>2</sub>H<sub>4</sub> i C<sub>2</sub>H<sub>6</sub>. SSN po zakończeniu uczenia powinny rozpoznawać trzy podstawowe defekty, a mianowicie: wyładowania, wyładowania niezupełne i uszkodzenia cieplne.

W celu trenowania i weryfikacji sieci zgromadzono dane pomiarowe pochodzące z rzeczywistych transformatorów, dla których znano występujący w nich defekt. Na etapie trenowania wykorzystano 80 zestawów pomiarowych: po 32 zestawy były powiązane z wyładowaniami i defektami cieplnymi, zaś 16 zestawów z wyładowaniami niezupełnymi. Zestawy trenujące zostały tak dobrane, aby defekty, były rozpoznawane również przez klasyczne metody DGA (w tym rekomendowaną przez PN-IEC 60599 [3]).

Dane uczące przed okazaniem sieciom zostały poddane procesowi normalizacji zgodnie z zależnościami (1) – uczenie z nauczycielem i (2) – uczenie bez nauczyciela.

## VII Lubuska Konferencja Naukowo-Techniczna – i-MITEL 2012

$$(1) \quad x'_i = 1 - 2 \cdot \frac{x_i - x_{min}}{x_{max} - x_{min}}$$

$$(2) \quad x'_i = \frac{x_i}{\sqrt{\sum_{i=1}^n x_i}}$$

Gdzie:

$x_i$  - stężenie i-tego gazu w próbce przed procesem normalizacji,

$x_{min}$  i  $x_{max}$  - minimalna i maksymalna wartość stężenia gazów w próbce przed normalizacją,

$x'_i$  - stężenie i-tego gazu w próbce po procesie normalizacji.

### Przykład diagnozy

W celu zilustrowania wyników otrzymywanych przy wykorzystywaniu opracowanych sieci neuronowych trenowanych w trybie z nauczycielem i bez nauczyciela rozpatrzone zostaną dwa przypadki pomierzonych stężeń gazów rozpuszczonych w oleju dwóch różnych transformatorów. Dane (przedstawione w tabeli 2) dla obydwu prezentowanych przykładów zaczerpnięto z literatury, odpowiednio z [4] i [5].

Tabela 2. Przykładowe stężenia gazów [ppm] analizowane przy pomocy opracowanych SSN.

Nr przypadku	H <sub>2</sub>	CH <sub>4</sub>	C <sub>2</sub> H <sub>2</sub>	C <sub>2</sub> H <sub>4</sub>	C <sub>2</sub> H <sub>6</sub>
1	24	13	319	43	5
2	65	61	3	143	16

W obydwu rozważanych przypadkach zastosowanie metody PN-IEC nie pozwoliło na wykrycie rodzaju defektu występującego w transformatorach.

Zastosowanie sztucznej sieci neuronowych zarówno trenowanej w trybie z nauczycielem, jak i w trybie bez nauczyciela pozwoliło na określenie charakteru defektu. Obydwe zaprezentowane sieci wskazały zgodnie w pierwszym przypadku na występowanie w transformatorze wyładowań, w drugim zaś defektu o charakterze cieplnym. Rzeczywiste defekty występujące w transformatorach potwierdziły słuszność diagnoz uzyskanych przez SSN.

### Rezultat testowania wytrenowanych sieci

Zaprojektowane i wytrenowane SSN w zdecydowanej większości przypadków w sposób prawidłowy rozpoznały rodzaj występującego w transformatorze defektu. Ponieważ zadane zestawy testowe były inne od zestawów uczących więc obydwie sieci charakteryzuje się zdolnością do uogólnień.

Wytrenowane SSN potrafiły skuteczniej rozpoznawać defekty niż tradycyjna metoda ilorazowa proponowana przez normę PN-IEC. Różnice sięgały od kilku do kilkunastu procent, zależnie od typu rozpoznawanego defektu.

Porównując obydwie typy sieci między sobą nie można jednoznacznie i zdecydowanie wskazać, że tylko jeden z nich nadaje się do rozpoznawania defektów na podstawie stężeń gazów rozpuszczonych w oleju transformatorowym. W ujęciu sumarycznym skuteczniejsza okazała się sieć trenowana w trybie z nauczycielem, jednakże były takie zestawy danych pomiarowych, dla których to sieć uczona bez nauczyciela dawała jako jedyną prawidłowy wynik.

### Literatura

1. Piotrowski T., Zastosowanie SSN w diagnozowaniu transformatorów na podstawie analizy gazów rozpuszczonych w oleju, *Przegląd Elektrotechniczny*, 86 (2010) nr 5.
2. Ramowa instrukcja eksploatacji transformatorów, Energopomiar-Elektryka, Gliwice (2006).
3. PN-EN 60599:2010 Urządzenia elektryczne impregnowane olejem mineralnym w eksploatacji – Wytyczne interpretacji analizy gazów rozpuszczonych i wolnych.
4. Islam S. M. et al, A Novel Fuzzy Logic Approach to Transformer Fault Diagnosis, *IEEE Transactions on Dielectrics and Electrical Insulation* Vol. 7 (2000), No. 2.
5. Siva Sarma D. V. S. S. et al, ANN Approach for Condition Monitoring of Power Transformers Using DGA, *IEEE Region 10 Conference TENCON*, Vol. C (2004)

---

**Autor:** dr inż. Tomasz Piotrowski; Instytut Elektroenergetyki, Politechnika Łódzka, Stefanowskiego 18/22, 90-924 Łódź, e-mail: tomasz.piotrowski@p.lodz.pl