

*sieci neuronowe, systemy elektroenergetyczne,
cyfrowe przetwarzanie sygnałów*

Mateusz PUSTUŁKA*, Jan IŻYKOWSKI*, Mirosław ŁUKOWICZ*

ZASTOSOWANIE SZTUCZNYCH SIECI NEURONOWYCH DO LOKALIZACJI ZWARĆ ŁUKOWYCH W LINIACH ELEKTROENERGETYCZNYCH W WARUNKACH NASYCENIA PRZEKŁADNIKÓW PRĄDOWYCH

W artykule zaprezentowano metodę lokalizacji zwarć łukowych w napowietrznych liniach elektroenergetycznych z wykorzystaniem sztucznych sieci neuronowych w warunkach nasycenia przekładników prądowych. Określanie miejsca zwarcia dokonywane jest na podstawie znajomości rodzaju zwarcia oraz pomiarów napięć i prądów z dwóch końców linii. Przystawiono wybrane wyniki z badań dokładności lokalizacji dla różnych stanów awaryjnych napowietrznej linii jednorodnej 400 kV o długości 50 km.

1. WSTĘP

Linie elektroenergetyczne odgrywają zasadniczą rolę w zapewnieniu przesyłu i dystrybucji energii elektrycznej z obszarów jej generacji do miejsc odbioru. Ze względu na różne zjawiska, takie jak wyładowania atmosferyczne, oblodzenia, trzęsienia ziemi, działania człowieka itp., te elementy systemu są szczególnie narażone na zwarcia. Aby ograniczyć niebezpieczny wpływ dużych prądów zwarcia, stosuje się zabezpieczenia eliminujące z pracy uszkodzone części systemu elektroenergetycznego. Po odstawieniu uszkodzonej linii zwarcie musi być zlokalizowane w celu dokonania niezbędnych napraw i przywrócenia sprawności systemu tak szybko, jak to tylko możliwe. Zmniejszenie czasu trwania przerwy w przesyśle energii jest istotne z punktu widzenia niezawodności zasilania, a także stabilności samego systemu elektroenergetycznego. Dodatkowo, jako cel lokalizacji, wymienia się również wskazanie miejsca w linii, w którym występuje osłabienie izolacji. Umożliwia to szybkie podjęcie dzia-

* Politechnika Wroclawska, Instytut Energoelektryki, Wybrzeże Wyspiańskiego 27, 50-370 Wrocław.

łań zapobiegających przekształceniu się takiego defektu w trwałe uszkodzenie. Im większą uzyskuje się dokładność lokalizacji, tym mniejsze są koszty inspekcji i naprawy uszkodzenia. Jednocześnie występuje krótszy okres przerwy w przesyle energii tą linią, co ma duże znaczenie ekonomiczne oraz techniczne (zmniejszenie ryzyka powstania black-out'u).

Istnieje wiele różnych sposobów minimalizacji czasu inspekcji i naprawy odstawionej linii. Do tej pory zaproponowane zostały dwie metody lokalizacji zwarć: algorytmy analityczne oraz metody oparte na sztucznej inteligencji. Najprostsze algorytmy lokalizacji zwarć opierają się na pomiarze ustalonych stanów napięć i prądów z jednego końca linii. W innych metodach wykorzystywane są informacje z obu końców linii. To sprawia, że metody te są odporne na błędy wynikające z niezerowej rezystancji zwarcia, która ma znaczący wpływ na dokładność algorytmów lokalizacji zwarć.

Zwykle dokładność algorytmów analitycznych jest bardzo wysoka, jednak w pewnych szczególnych przypadkach dokładność jest znacznie ograniczana. Dodatkowo błędy lokalizacji wynikają głównie z:

- braku lub niepełnej informacji o parametrach linii, szczególnie w odniesieniu do składowej zerowej impedancji,
- asymetrii obciążenia,
- nieznannej rezystancji i prądu zwarcia, co w znacznym stopniu odpowiada za błędy lokalizacji zwarć,
- małej dokładności w przypadku nasycenia przekładników prądowych (PP).

W związku z tym ważne jest zmniejszenie błędów w metodach lokalizacji zwarć poprzez zapewnienie jak najpełniejszej informacji o systemie lub wykorzystanie nowych algorytmów lokalizacyjnych.

Jak dotąd sztuczne sieci neuronowe (SSN) są najbardziej rozwijającą się techniką sztucznej inteligencji stosowaną w zabezpieczeniach systemów elektroenergetycznych. SSN są z powodzeniem wykorzystywane do rozwiązywania takich zadań jak wykrywanie zwarć [7], klasyfikacji typu zwarcia [4], dyskryminacji kierunku zwarcia, szacowanie obszaru awarii oraz realizacji schematów działania automatyki samoczynnego ponownego załączania (SPZ). Technika ta stosowana jest również do przetwarzania sygnałów, np. w kompensacji błędów przekładników prądowych i napięciowych, prognozowania przeciążeń i lokalizacji zwarć.


W pracy przedstawiono wyniki z zastosowaniem SSN do lokalizacji jednofazowych, łukowych zwarć doziemnych występujących na liniach elektroenergetycznych 400 kV. Lokalizacja zwarć łukowych w liniach elektroenergetycznych została przeprowadzona z wykorzystaniem pomiarów napięć i prądów mierzonych asynchronicznie w obu końców linii.

Zaproponowano również wstępne przetwarzanie sygnałów wejściowych, mające na celu zminimalizowanie składowej stałej prądu tak, żeby uzyskać względnie dokładną odległość do miejsca zwarcia w możliwie najkrótszym czasie od momentu jego wystąpienia.

Analiza została przygotowana w oparciu o błędy średnie, maksymalne oraz odchylenia standardowe wyników lokalizacji zwarć zamodelowanych w programie EMTP [2].

2. SYSTEM ELEKTROENERGETYCZNY

W celu oceny efektywności proponowanego rozwiązania do badań wybrano jednotorową linię elektroenergetyczną 400 kV, o długości 50 km, jak pokazano na rysunku 1. Pomiar prądów i napięć dokonywany był asynchronicznie na obu końcach linii.



Rys. 1. Schemat systemu elektroenergetycznego

Ze względu na brak możliwości uzyskania danych rzeczywistych wykorzystano program EMTP do zamodelowania odpowiednio dużej liczby zwarć, która jest wymagana do efektywnego uczenia sztucznych sieci neuronowych. W Tabeli 1 zawarte zostały wartości parametrów systemowych przyjętych do generowania populacji zbiorów danych uczących i testowych. Zarówno miejsce jak i rezystancja zwarcia oraz moc zwarciowa były zmieniane w sposób losowy.

Tabela 1. Parametry systemu dla generacji danych uczących i testujących

miejsce zwarcia [%]	0–100
długość linii [km]	50
rezystancja zwarcia [Ω]	0–10
moc zwarciowa [GVA]	3–32

3. DYNAMICZNY MODEL ŁUKU PIERWOTNEGO

Dynamiczny model łuku pierwotnego [3] opisuje równanie różniczkowe

$$\frac{dg_p}{dt} = \frac{1}{T_p} (G_p - g_p), \quad (1)$$

w którym:

g_p – dynamiczna przewodność łuku,

$G_p = \frac{|i|}{(V_p + R|i|)l_p}$ – statyczna przewodność łuku,

i – prąd łuku [A],

V_p – średni gradient napięcia ($V_p = 9,6 - 25$, [V/cm]),

R – statyczna rezystancja łuku na jednostkę długości [Ω/cm],

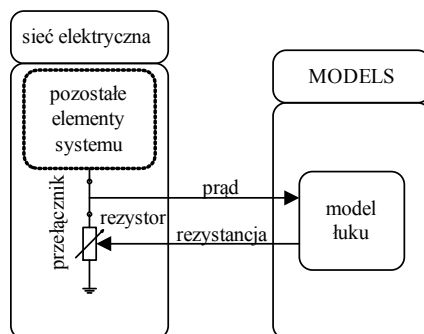
l_p – długość łuku (ogólnie zmienna w czasie) [cm],

$T_p = \frac{\alpha I_p}{l_p}$ – stała czasowa; $T_p = (0,8 - 1,1) \cdot 10^{-3}$ [s],



α – współczynnik empiryczny, uzyskany przez dopasowanie do danych pomiarowych ($\alpha = 2,85 - 1,1) \cdot 10^{-5}$,

I_p – wartość maksymalna prądu łuku [A].


W programie ATP-EMTP rezystancję łuku (rys. 5) modelowano przy wykorzystaniu rezystora sterowanego z procedury modelu łuku w segmencie MODELS (rys. 2). Rezystancja łuku wyznaczana jest w każdym kroku obliczeń na podstawie mierzonego prądu i rozwiązywanego numerycznie równania różniczkowego (1). Wyznaczana rezystancja łuku przekazywana jest do sterowanego rezystora i wykorzystywana w kolejnym kroku obliczeń sieciowych. Przykładowe przebiegi prądu łuku (i) i spadku napięcia na łuku (v) przedstawione zostały na rysunku 3. Rysunek 4 przedstawia natomiast zależność pomiędzy prądem a napięciem łuku.



Rys. 2. Modelowanie dynamicznego łuku pierwotnego przy użyciu programu EMTTP

Rys. 3. Prąd łuku (i) i spadek napięcia na łuku (v)

Rys. 4. Zależność między prądem i napięciem łuku



Rys. 5. Rezystancja łuku

4. BŁĘDY POMIAROWE

Wszystkie informacje o parametrach systemu elektroenergetycznego otrzymywane są na podstawie sygnałów pierwotnych mierzonych przez przekładniki prądowe i napięciowe. Przekładniki stosuje się w celu izolacji wtórnych obwodów pomiarowych od pierwotnych obwodów wysokiego napięcia, wzajemnej izolacji różnych obwodów wtórnych oraz do przetwarzania pierwotnych prądów i napięć na standardowe wartości wtórne [3].

Podstawowym rodzajem przekładników prądowych, powszechnie stosowanych w obwodach pomiarowych układów automatyki elektroenergetycznej, są przekładniki indukcyjne. Uzwojenia strony pierwotnej i wtórnej są sprzężone magnetycznie, a ich schemat zastępczy nie odbiega od schematu zastępczego transformatora jednofazowego (rys. 6), na którym (z uwzględnieniem przeliczania parametrów uzwojenia wtórnego na stronę pierwotną):


i_p, i'_s – prądy strony pierwotnej i wtórnej,

i_e, i_r, i_m – prądy gałęzi poprzecznej,

R_p, L_p – rezystancja uzwojeń strony pierwotnej, indukcyjność rozproszenia strony pierwotnej,


R'_s, L'_s – rezystancja uzwojeń strony wtórnej, indukcyjność rozproszenia strony wtórnej,

R_m, L_m – rezystancja odwzorowująca straty w rdzeniu, indukcyjność związana ze strumieniem zamykającym się w rdzeniu magnetycznym,
 R'_2, L'_2 – rezystancja i indukcyjność obciążenia.
 Znak „prim” oznacza sprowadzenie wielkości ze strony wtórnej na stronę pierwotną.




Rys. 6. Schemat zastępczy przekładnika prądowego

Z punktu widzenia warunków współpracy przekładników prądowych z zabezpieczeniami, ważna jest analiza błędów transformacji w stanach przejściowych. W tym przypadku, najważniejszym czynnikiem, który może powodować duże błędy przejściowe transformacji jest występowanie w prądach zwarciovych zanikającej składowej aperiodycznej. Strumień magnetyczny może wówczas przyjmować duże wartości nawet przy niezbyt dużej amplitudzie składowej podstawowej prądu, powodując nasycenie rdzenia magnetycznego. Ilustrują to przebiegi na rysunku 7.



Rys. 7. Transformacja prądu przez nasycony przekładnik prądowy

Pojawienie się składowej nieokresowej powoduje wystąpienie dużego błędu przejściowego, co może powodować błędną ocenę zdarzenia przez układy automatyki elektroenergetycznej [5]. Przebieg charakterystyki magnesowania przekładnika $\Phi(i_e)$ jest przedstawiony na rysunku 8.



Rys. 8. Uproszczona charakterystyka magnesowania przekładnika $\Phi(i_e)$

5. SZTUCZNA SIEĆ NEURONOWA DO LOKALIZACJI ZWARĆ


W badaniach zastosowano dwuwarstwową sztuczną sieć neuronową pobudzaną sygnałami pomiarowymi z dwóch końców linii. Rysunek 9 przedstawia architekturę sieci neuronowej, w której liczba wejść i wyjść, liczba warstw oraz liczba neuronów w poszczególnych warstwach zostały dobrane empirycznie dla zapewnienia realizacji postawionego zadania. Niestety nie ma metod analitycznych, które pozwoliłyby na oszacowanie tych wielkości i dobór najlepszej struktury sieci. W związku z tym konieczne jest zastosowanie metody prób i błędów [6].

Zaproponowana sieć neuronowa posiada 10 neuronów w warstwie wejściowej. Dane wejściowe to odpowiednio: moduły wektorów prądów i napięć z poszczególnych faz linii oraz części rzeczywiste i urojone odpowiednich ich ilorazów (rys. 10). Sygnały zasilające wejścia sieci neuronowej otrzymywano w wyniku pełnookresowej filtracji Fouriera oraz filtracji półokresowej z oknem sinusoidalnym wtórnych przebiegów napięciowych i prądowych (rys. 10).


Filtry z oknami sinusoidalnymi, cosinusoidalnymi są najbardziej powszechne ze względu na to, że zapewniają skuteczniejszą filtrację zakłóceń sygnałów przy stosunkowo prostym algorytmie [5], [6]. Dwa przypadki mają szczególne znaczenie praktyczne i są powszechnie stosowane: filtr pełnookresowy oraz filtr półokresowy.

Szczególnie korzystne właściwości mają filtry ortogonalne pełnookresowe. Zachowują się one jak filtry pasmowo przepustowe i tłumią do zera wszystkie harmoniczne pulsacji podstawowej sygnałów (która jest równa pulsacji własnej filtru). Filtry półokresowe mają mniej korzystne charakterystyki widmowe, ale ich zaletą jest dwa razy krótsze okno, czego efektem jest dwa razy szybsze ustalenie się sygnału wyjściowego po ewentualnych zmianach sygnału wejściowego. Można by powiedzieć, że dynamika takich filtrów jest dwa razy lepsza. Dwa zastosowane filtry pozwalają wyznaczyć składowe ortogonalne napięć i prądów, a także zapewniają skuteczną filtrację zakłóceń.

W warstwie ukrytej znajduje się 30 neuronów, a w warstwie wyjściowej 1 neuron. Odpowiedzią sieci jest pojedyncza wartość określająca estymowane miejsce zwarcia. W procesie uczenia sieci neuronowej zastosowano algorytm wstecznej propagacji błędów. Przed procesem uczenia i testowania sieci neuronowej wejścia zostały znormalizowane. Dodatkowo dane zostały podzielone na trzy grupy: dane uczące, dane testujące i dane walidacyjne, odpowiednio w stosunku 70–15–15. Proces uczenia kończył się w momencie osiągnięcia określonej ilości iteracji.



Rys. 9. Struktura sieci neuronowej



Rys. 10. Schemat blokowy lokalizatora

6. WYNIKI BADAŃ

Badania polegające na testowaniu zaprojektowanej sieci neuronowej oraz analizie otrzymanych wyników przeprowadzono z użyciem środowiska MATLAB wraz z biblioteką Neural Network Toolbox [1]. Do testów sztucznych sieci neuronowych wykorzystano sygnały zabezpieczeniowe otrzymane z komputerowego modelowania systemu elektroenergetycznego w programie ATP-EMTP. Błąd lokalizacji zwarcia definiowany jest przez równanie

$$\text{błąd (\%)} = \frac{|d_{SSN} - d_F|}{L} * 100\% \quad (2)$$

gdzie:

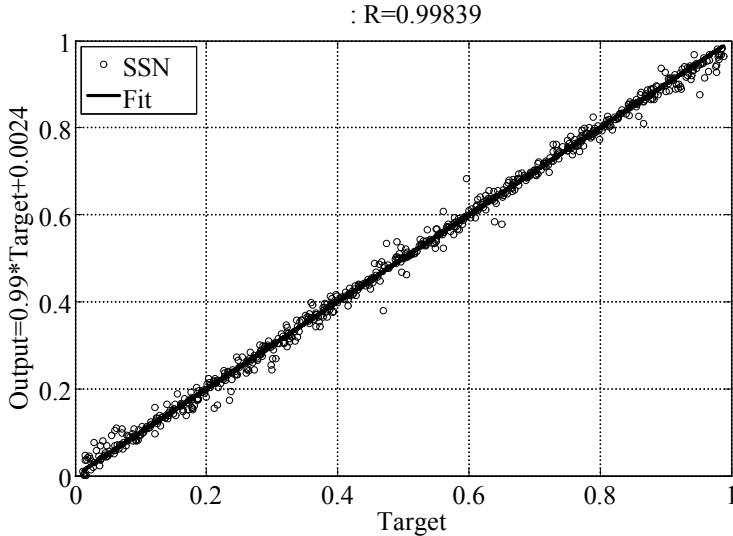
- d_{SSN} – wyjście sieci neuronowej,
- d_F – rzeczywiste miejsce zwarcia,
- L – długość linii elektroenergetycznej.

Tabela 2. Względne błędy lokalizacji dla 10 wybranych miejsc zwarcia oraz błędy maksymalne i średnie dla całej populacji danych testowych

Rzeczywiste miejsce zwarcia [km]	SSN [km]	błąd [%]
3,10	2,987	0,226
7,51	7,660	0,300
12,31	11,643	1,334
20,82	20,788	0,063
24,62	24,933	0,626
30,48	30,396	0,168
39,09	38,971	0,238
45,25	44,216	2,068
48,90	46,411	4,979
49,25	48,370	1,760
max		9,070
średnia		1,057
mediana		0,684
odchylenie std.		0,625

Tabela 2 przedstawia przykładowe wyniki lokalizacji dla sieci neuronowej wraz z błędami dla linii przesyłowej o długości 50 km. Dodatkowo zamieszczone zostały błędy średnie i maksymalne, odchylenie standardowe oraz mediana (odporna na występujące, najczęściej pojedyncze, odstające estymaty lokalizacji) dla całej populacji danych testowych, która wynosiła ok. 1000 przypadków zwarciovych. Na rysunku 11 przedstawiono regresję uzyskanych wyników, która prezentuje związek pomiędzy rzeczywistymi odle-

głościami do zwarcia i estymowanymi wartościami, będącymi odpowiedzią SSN. Potwierdza ona dosyć dużą dokładność sieci neuronowej w lokalizacji zwarć łukowych w warunkach nasycenia przekładników prądowych. Nie przedstawiono rezultatów dla klasycznego algorytmu lokalizacji zwarć, dla którego błędy są znacznie większe, sięgające w niektórych przypadkach zwarciovych kilkudziesięciu procent.



Rys. 11. Regresja uzyskanych wyników

7. PODSUMOWANIE

Zaprezentowana metoda lokalizacji zwarć łukowych z wykorzystaniem sztucznych sieci neuronowych sprawdzona została dla różnych stanów pracy napowietrznej linii jednotorowej 400 kV o długości 50 km. W celu uczenia i testowania przeprowadzono wielowariantową symulację zwarć. Testowanie obejmowało 1000 przypadków zwarciovych. W przypadku występowania błędów pomiarowych, będących rezultatem nasycenia przekładników prądowych, wyniki otrzymane z zastosowaniem SSN cechuje stosunkowo duża dokładność. Otrzymane rezultaty potwierdzają zadowalającą dokładność lokalizacji, szczególnie w porównaniu z dokładnością uzyskiwaną za pomocą algorytmów analitycznych. Ponadto lokalizatory neuronowe w przeciwieństwie do metod analitycznych dają tylko jedno rozwiązanie, podczas gdy w tych ostatnich istnieją często dwa formalnie prawidłowe wartości dla danej lokalizacji zwarcia.

LITERATURA

- [1] BEALE M.H., HAGAN M.T., DEMUTH H.B., *Neural Network Toolbox™ 7 User's Guide*,
- [2] DOMMEL H.W., *Electromagnetic Transients Program. Reference Manual (EMTP Theory Book)*, Bonneville Power Administration, Portland 1986.
- [3] IŻYKOWSKI J., *Fault location on Power Transmission Lines*, Oficyna Wydawnicza Politechniki Wrocławskiej, Wrocław 2008.
- [4] KEZUNOVIC M., RIKALO I., SOBAJIC D.J., *High-speed fault detection and classification with neural nets*, Electric Power Systems Research, Vol. 34, No. 2, 1995, 109–116.
- [5] ROSOŁOWSKI E., *Cyfrowe przetwarzanie sygnałów w automatyce elektroenergetycznej*, Wyd. Exit, Warszawa 2002.
- [6] SZAFRAN J., WISZNIEWSKI A., *Algorytmy pomiarowe i decyzyjne cyfrowej automatyki elektroenergetycznej*, WNT, Warszawa 2001.
- [7] YANG M.T., GU J.C., JENG C.Y., KAO W.S., *Detection High Impedance Fault in Distribution Feeder using Wavelet Transform and Artificial Neural Networks*, 2004 International Conf. on Power System Technology – POWERCON 2004, 652–657, Singapore, 21–24 November 2004.

ARC FAULT LOCATION ON POWER TRANSMISSION LINES UNDER SATURATION
OF CURRENT TRANSFORMER BASED ON ARTIFICIAL NEURAL NETWORK

The paper presents the method of arc fault location on power transmission lines using artificial neural network. The investigation was focused on the cases of CT saturation, resulting in the current signal transformation errors. Fault location is based on measurements of voltages and currents from two ends of the line, with knowledge of fault type. The accuracy of the location method was tested for different operating conditions of 400 kV power transmission line modeled in EMTP.