

Wstępna analiza efektywności wykorzystania sztucznych sieci neuronowych do modelowania sygnału czasowego napięcia generatora udaru kombinowanego

Effectiveness of use of artificial neural networks for modeling time-voltage signal of the combination wave generator – preliminary analysis

Marek Dudzik, Ryszard Mielnik, Zofia Wróbel

W artykule zaprezentowano możliwość tworzenia modelu generatora udaru kombinowanego w sieciach neuronowych dla potrzeb analizy pracy elementów i układów ochrony przeciwprzepięciowej. W drugiej części artykułu przedstawiono efektywność wykorzystania sztucznych sieci neuronowych, typu feedforward o jednej warstwie ukrytej z czterema neuronami do modelowania czasowego sygnału napięcia na wyjściu generatora udaru kombinowanego. Uzyskane wyniki pokazują wysoką efektywność wykorzystania algorytmu Levenberga-Marquardta, pomimo braku jego optymalnej struktury. Opracowany model udaru napięciowego siecią neuronową może zastąpić model matematyczny generatora. Takie podejście umożliwi efektywne wykonywanie obliczeń symulacyjnych skutków przepięć pochodzenia atmosferycznego działających na układy ochrony przeciwprzepięciowych urządzeń elektrycznych.


Słowa kluczowe: sztuczne sieci neuronowe, generator udaru kombinowanego, modelowanie

Keywords: artificial neural network, combination wave generator, modeling

Pomiary, wykonywane w warunkach laboratoryjnych, mające na celu sprawdzenie skuteczności działania projektowanych układów ochrony przeciwprzepięciowej – są końcowym etapem badań i decydują o dopuszczeniu tych układów do użytkowania [12, 13, 15]. Tego typu badania wykonuje się z zastosowaniem m.in.: generatora udaru kombinowanego o przebiegu napięciowym $1,2/50 \mu\text{s}$, prądowym $8/20 \mu\text{s}$ i efektywnej impedancji wyjściowej $2\Omega \pm 10\%$.

Na podstawie dokumentacji generatora oraz normy PN-EN 61000-4 – kompatybilność elektromagnetyczna (EMC) [10] 5: Metody badań i pomiarów. Badanie odporności na udary (2014 r.), na rys. 1 przedstawiono schemat zastępczy generatora udaru kombinowanego [9, 10].

Dr inż. Marek Dudzik (marekdudzik@pk.edu.pl) – Instytut Elektrotechniki i Informatyki, Katedra Trakcji i Sterowania Ruchem Politechniki Krakowskiej, dr inż. Ryszard Mielnik – Instytut Elektromechanicznych Przemian Energii, Katedra Diagnostyki Maszyn Elektrycznych Politechniki Krakowskiej, dr inż. Zofia Wróbel – PKP PLK S.A. Zakład Linii Kolejowych w Rzeszowie



Rys. 1. Uproszczony schemat obwodu generatora udaru kombinowanego [9, 10]: U – źródło wysokiego napięcia, C_c – kondensator gromadzący energię, R_c – rezystancja ładowania, R_r , R_{s1} i R_{s2} – rezystory kształtujące czas trwania impulsu, R_m – rezystor dopasowujący impedancję, L_r – dławik kształtujący czas narastania

Fig. 1. Simplified circuit diagram of the combination wave generator of [9, 10]: where U – high-voltage source, C_c – energy storage capacitor, R_c – charging resistance, R_{s1} and R_{s2} – impulse duration shaping resistor, R_m – impedance matching resistor, L_r – rise time gland shaping inductor

Pomiar sygnału wyjściowego generatora udaru kombinowanego

Na potrzeby opracowania modelu czasowego sygnału napięcia na wyjściu generatora udaru kombinowanego przeprowadzono badania eksperymentalne, stosując generator udarowy Haefely PC6-288.1 i filtr Haefely FP 20/3-3.2 [15]. Rejestrację napięć udarów przeprowadzono za pomocą czterokanałowego oscyloskopu cyfrowego LeCroy LS-140, umożliwiającego rejestrację przebiegów w paśmie częstotliwości do 100 MHz, z dokładnością podstawy czasu 0,01%. Oscyloskop zasilono przez transformator separujący typu Tma 630S. Do pomiarów zastosowano sondę LeCroy 6 kV, 50 M Ω , 1000:1. Błąd pomiaru napięcia sondą wynosił $\pm 0,1\%$ dla napięcia stałego i $\pm 2\%$ dla napięcia przemiennego o częstotliwości do 100 MHz.

W badaniach charakterystyk układów ochrony przeciwprzepięciowej i ich elementów składowych [15], ważną rolę odgrywa powtarzalność wymuszeń udarowych. W celu sprawdzenia powtarzalności wyników pomiarów, na wstępie wykonano rejestrację dwudziestu pięciu wymuszeń dla każdego udaru napięciowego $1,2/50 \mu\text{s}$ dla $U = 1 \text{ kV}$. Wyniki pomiarów zapisywano w formacie PSPICE®, wybierając ostatecznie ten pakiet jako podstawowe narzędzie obróbki danych. Metodę oznaczania miar odpowiednich przebiegów napięciowych oparto na zależnościach [11]:

$$\bar{U}_m = \frac{1}{N} \sum_{i=1}^N U_m(i) \quad (1)$$

$$\sigma_{U_m} = \sqrt{\frac{\sum_{i=1}^N (U_m(i) - \bar{U}_m)^2}{N-1}} \quad (2)$$

$$\sigma_{U_m} = \frac{\sigma_{U_m}}{\sqrt{N}} \quad (3)$$

gdzie:

$U_m(i)$ – wartość maksymalna kolejnego napięcia pomiaru,

\bar{U}_m – wartość średnia wykonanej serii pomiarów.

Wyniki pomiarów udaru napięciowego rejestrowano w przedziałach czasowych $\Delta t_i = 0,1 \mu s$ (w formacie PSPICE®). Różnice pomiędzy maksymalnymi, mierzonymi wartościami nastawy na generatorze udaru kombinowanego a maksymalną wartością średnią, mieściły się w granicach 1%. Jako wynik końcowy wyznaczono przedział dla wartości. Na podstawie powyższych wyników, a szczególnie niskich wartości odchylenia standardowego na poziomie 0,3% uznano powtarzalność warunków badań.

Zastosowanie sztucznej sieci neuronowej do modelowania sygnału udaru napięciowego z generatora udaru kombinowanego

W badaniach naukowych sztuczne sieci neuronowe znajdują coraz większe zastosowanie [1-3, 6, 7]. Współcześnie badacze starają się analizować sygnały udaru napięciowego przez jego modelowanie oparte na teorii obwodów elektrycznych [4, 12, 14]. Dają one wymierne efekty, jednakże prezentowane modele są skomplikowane. Otwiera to drogę badań wykorzystującą sztuczne sieci neuronowe do modelowania wyjściowego sygnału generatora udaru kombinowanego. Celem przeprowadzonych badań było zamodelowanie funkcji przebiegu czasowego napięcia generatora udaru kombinowanego za pomocą sztucznych sieci neuronowych. Ma to umożliwić analizę pracy elementów i układów ochrony przeciwprzepięciowej w sieciach neuronowych bez konieczności korzystania z innych programów obliczeniowych.


Obliczenia zostały przeprowadzone przy następujących ustawieniach:

- maksymalna liczba epok uczenia się 1000,
- współczynnik błędu treningu sieci 0,
- współczynnik szybkości uczenia się sieci 0,01,
- liczba błędnych powtórzeń treningu sieci 12,
- momentum 0,9,
- minimalny błąd gradientu treningu sieci 10^{-10} ,
- liczba powtórzeń pomiędzy przedstawieniem wyniku uczenia się sieci 25,
- maksymalny czas treningu sieci - nieskończoność.

Do uczenia się sieci neuronowej zastosowano trening sieci jednokierunkowej (do 3 warstw) wg algorytmu Levenberga-Marquardta.

Dane wejściowe i wyjściowe modelu

Przeprowadzone badania symulacyjne i uzyskane wyniki zostały zrealizowane z wykorzystaniem środowiska Matlab w wersji R2011B. Dane do analizy, z wykorzystaniem SSN (sztucznych sieci neuronowych), zapisano jako dwa wektory po 10 000 par liczb. Do przetwarzania danych pomiarowych, wykorzystano sieć neuronową



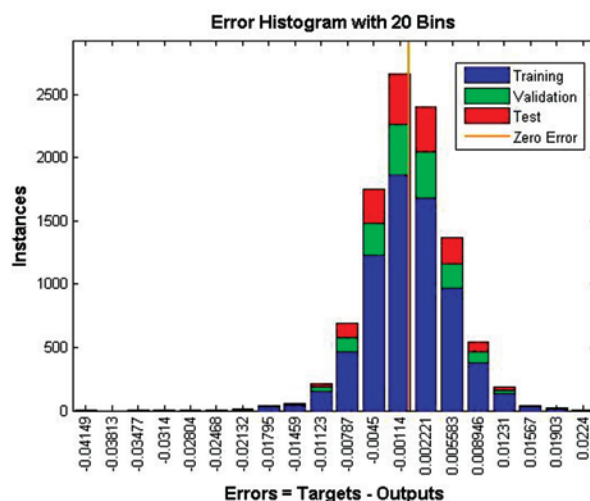
Rys. 2. Struktura utworzonej sieci neuronowej (źródło: opracowanie własne)
Fig. 2. The created neural network structure

wą jednowarstwową typu feedforward [1, 3, 6]. Na rys. 2 pokazano strukturę sieci neuronowej utworzonej w środowisku Simulink. Jest to struktura o jednej warstwie ukrytej (Hidden). Warstwa ta składa się z czterech neuronów. Na wejściu warstwy nie zaimplementowano opóźnień. Funkcją aktywacji w warstwie ukrytej jest funkcja tangensoidalna (tansig). W warstwie wyjściowej (output) zastosowano liniową funkcję aktywacji.


Danymi wejściowymi sieci były próbki (sample) czasu mierzonego sygnału napięcia generatora udaru kombinowanego. Natomiast danymi wyjściowymi były zarejestrowane próbki sygnału napięciowego tego generatora. Przy czym wartości próbek sygnału napięcia zostały wyskalowane w taki sposób, ażeby maksymalna wartość tego sygnału osiągnęła 1.

Wyniki z przeprowadzanych badań symulacyjnych

Na rys. 3 przedstawiono wyniki uzyskane z: treningu (training), walidacji (validation) i testu (test) sztucznej sieci neuronowej w postaci histogramu błędów (error histogram) [3]. Histogram ten ze względu na czytelność został podzielony na 20 słupków. Na osi odciętych został przedstawiony błąd bezwzględny, tzn. różnica pomiędzy rzeczywistą wartością otrzymaną z pomiaru sygnału napięcia a wartością wyjściową otrzymaną z sieci neuronowej. Na osi rzędnych została przedstawiona liczbie próbek (instances), która znalazła się w zakresie pokazanego błędów reprezentowanego przez dany słupek. Jak widać na rys. 3, rozkład błędów przypomina rozkład Gaussa. Zauważyć można także, że większość próbek znajduje się w zakresie błędów bezwzględnych między -0,00787 a 0,008946.



Rys. 3. Histogram błędów (źródło: opracowanie własne)
Fig. 3. Error histogram

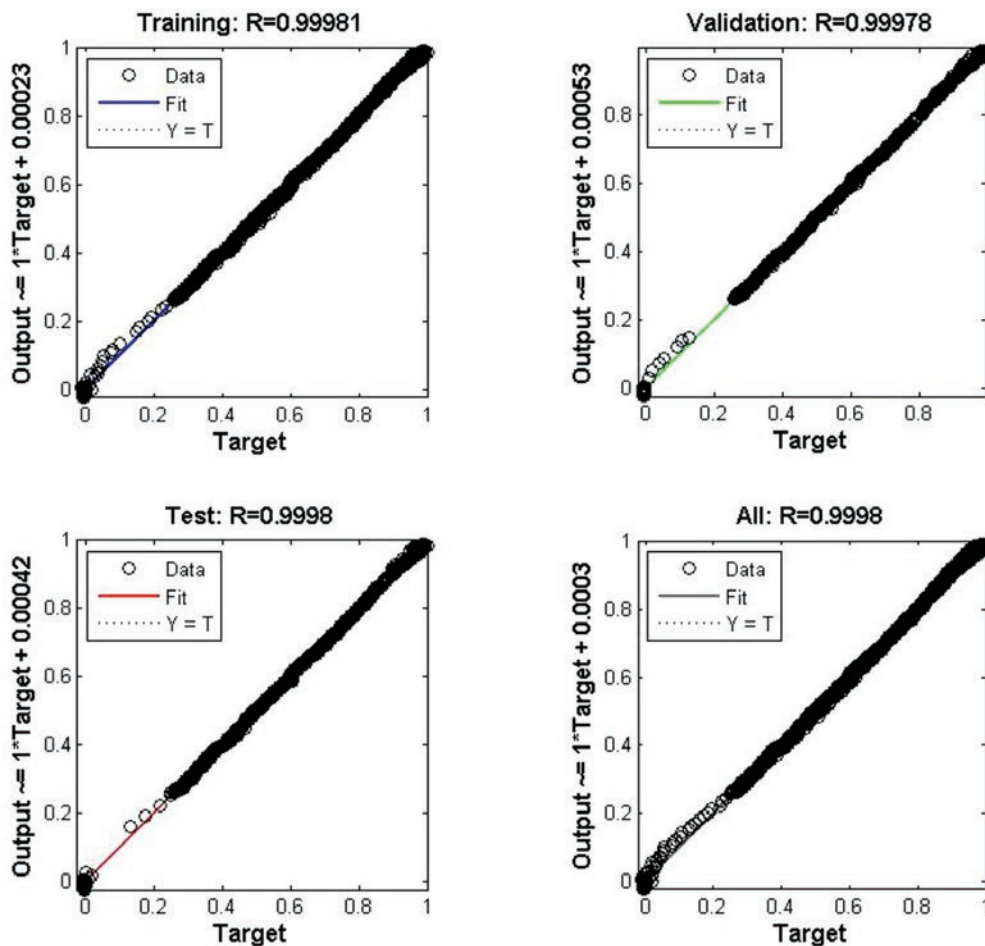


Rys. 4. Wydajność uczenia się sztucznej sieci neuronowej (źródło: opracowanie własne)
 Fig. 4. Performance learning of the ANN

Na rys. 4 przedstawiono wykres obrazujący wydajność uczenia się SSN dla kolejnych epok uczenia.

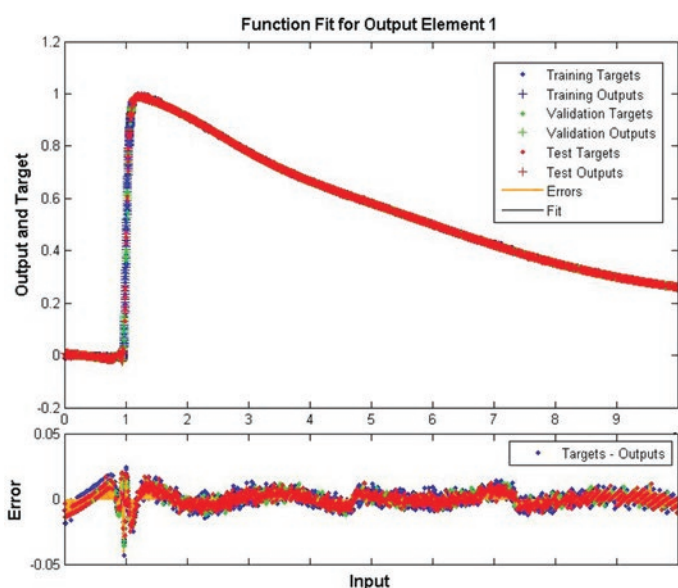
Jako funkcję wydajności przyjęto błąd średni kwadratowy (mse – mean squared error). Na osi odciętych zostały zapisane poszczególne epoki uczenia się sieci. Najlepszą walidację wydajności sieci neuronowej układ osiągnął dla epoki nr 382 i wyniosła ona $3,2712 \cdot 10^{-5}$. Widać, że układ sieci neuronowej przetwarzał algorytm uczenia się jeszcze przez 12 epok w celu potwierdzenia domniemanego minimum lokalnego dla postawionego zadania przy utworzonej strukturze sieci (rys. 2). Od epoki nr 1 do epoki nr 382 widoczna jest tendencja spadkowa przy obliczeniach walidacji podczas uczenia się sztucznej sieci neuronowej (SSN).

Na rys. 5 zaprezentowano wyniki regresji dla: treningu, walidacji, testu i wypadkowej regresji dla wszystkich danych przeznaczonych do treningu SSN z nauczycielem. Na rysunku tym na osi rzędnych zaprezentowane są wyniki, jakie podaje sieć neuronowa dla zadanych parametrów wejściowych. Na osi odciętych prezentowane są wartości wyniku rzeczywistego (targets), do którego wyniki podane przez wytrenowaną sieć neuronową powinny zmierzać. Wynik regresji $R = 1$ oznacza, że istnieje jednoznaczne odwzorowanie pomiędzy wartością rzeczywistą (z pomiaru lub symulacji – target) a odpowiedzią sieci neuronowej (output). Wyniki dla opisanego wy-



Rys. 5. Wyniki regresji dla: treningu, walidacji, testu i wypadkowej regresji dla wszystkich danych przeznaczonych do treningu SSN z nauczycielem (źródło: opracowanie własne)

Fig. 5. Regression results for: the training, validation and test and the regression for all data assigned to the ANN learning with a teacher



Rys. 6. Wyniki aproksymacji funkcji z wykorzystaniem SSN (źródło: opracowanie własne)

Fig. 6. Results of function fitting with the use of the ANN

żę przypadku są następujące – dla danych przeznaczonych dla treningu sieci $R = 0,99981$. Dane te stanowiły 70% wszystkich danych wykorzystanych na uczenie się SSN z nauczycielem. Dla danych przeznaczonych na walidację sieci $R = 0,99978$, stanowiły 15% wszystkich danych wykorzystanych na uczenie SSN z nauczycielem. Dla danych przeznaczonych na testy sieci $R = 0,9998$, stanowiły 15% wszystkich danych wykorzystanych na uczenie się SSN z nauczycielem. Dla wszystkich danych pomiarowych wypadkowa regresja $R = 0,9998$. Trening, walidacja i test są wykonywane podczas procedury uczenia się sieci neuronowej.

Na rys. 6 przedstawiono wynik aproksymacji otrzymany z procedury uczenia się sztucznej sieci neuronowej. Na tym rysunku kropką oznaczono wartość rzeczywistą uzyskaną z pomiaru (targets). Krzyżykiem zaznaczono wynik aproksymacji (wartości wyjściowe sieci na zadany sygnał wejściowy). Linie pionowe przedstawiają miarę błędu bezwzględego pomiędzy wspomnianą wartością rzeczywistą a wynikiem uzyskanym z aproksymacji funkcji. Linia ciągłą zaprezentowano funkcję aproksymującą.

Podsumowanie

W artykule przedstawiono model czasowego sygnału napięciowego generatora udaru kombinowanego zamodelowanego z wykorzystaniem sztucznej sieci neuronowej, typu feedforward o jednej warstwie ukrytej z czterema neuronami. Uzyskane rezultaty z przeprowadzonych badań na poziomie regresji 99,9% wskazują, że czasowy sygnał napięciowy generatora udaru kombinowanego może być modelowany przy wykorzystaniu sztucznej inteligencji. Badania nad zagadnieniami modelowania przebiegu czasowego napięcia generatora udaru kombinowanego powinny być kontynuowane m.in. w ujęciu optymalizacji struktury sieci. Konieczne są również analizy i obliczenia związane z przebiegiem czasowym prądu wspomnianego generatora. Jeśli analizy będą potwierdzały zgodność modelu na podobnym poziomie (jak w przypadku analiz przebiegu napięcia), wówczas będzie to skutkowało możliwością

zastąpienia skomplikowanego modelu matematycznego generatora udaru kombinowanego [14], przedstawioną i zoptymalizowaną strukturą sieci neuronowej lub kombinacją struktur. Pozwoli to na wykorzystanie opracowanego modelu generatora do analizy pracy elementów i układów ochrony przeciwprzepięciowej. Może to również posłużyć do stworzenia zupełnie nowej koncepcji związanej ze wspomnianą ochroną, podobnie jak rozwiązania zawarte w patencie [5] i koncepcjach [8].

Autorzy w następnych artykułach będą podejmować wspomniane analizy wpływu struktury na osiągnięte rezultaty modelowania zjawiska. Początkowo będą to możliwie wszystkie struktury dla jednej warstwy ukrytej.

Przedstawione w niniejszym artykule wyniki badań zostały uzyskane podczas prac realizowanych w ramach tematu badawczego E-2/581/2016/DS, który był finansowany z dotacji naukowej Ministerstwa Nauki i Szkolnictwa Wyższego.

Artykuł recenzowany, wpłynęło 14.03.2017

LITERATURA

- [1] Chrabąszcz I., Drapik S., Dudzik M., Kaczmarczyk A., Prusak J. 2015. Analiza obciążeń zespołów prostownikowych, dla „inteligentnych” kolejowych podstacji trakcyjnych DC – wstępne badania symulacyjne wybranych przypadków. *Logistyka* 6, 990–999.
- [2] Dudzik M., Łątka D., Repelewicz M., Stewarski E., Stręk A.M. 2014. A preliminary feasibility study of a short-term prognosis of mining towers tops’ displacements with the use of artificial neural networks. *Technical Transactions. Civil Engineering*.
- [3] Dudzik M., Drapik S., Prusak J. 2016. Approximation of overloads for a selected tram traction substation using artificial neural networks. *Technical Transactions*, 39–50.
- [4] Fotis G.P., Gonos I.F., Stathopoulos I.A. Simulation and experiment for surge immunity according to EN 61000-4-5. [on-line]. Available: https://www.atecorp.com/ATECorp/media/pdfs/61000-4-5_Abstract.pdf.
- [5] Jagiełło A.S., Chrabąszcz I., Drapik S., Dudzik M., Kobielski A., Prusak J. 2015. System do aktywnej regulacji obciążenia zespołów prostownikowych kolejowej podstacji trakcyjnej i sposób aktywnej regulacji obciążenia zespołów prostownikowych kolejowej podstacji trakcyjnej, numer zgłoszenia: P.411511, nasz znak: 150102. Poland 10.03.2015, zgłaszający: Politechnika Krakowska im. Tadeusza Kościuszki.
- [6] Kobielski A., Drapik S., Dudzik M., Prusak J. 2014. Wstępne studium efektywności zastosowania sieci neuronowych w badaniach obciążeń kolejowych podstacji trakcyjnych. *Technika Transportu Szynowego: TTS*.
- [7] Malina A., Dudzik M. 2014. Wykorzystanie algorytmów sieci neuronowych w celu zmniejszenia amplitud wahań momentu elektromagnetycznego w metodzie sterowania wektorowego DTC. *Elektrotechnika w zastosowaniach trakcyjnych*: [praca zbiorowa], Wydawnictwo PK.
- [8] Mielnik R. 2016. Synteza sterownika układu SZR urządzeń zasilania ruchem kolejowym z wykorzystaniem sieci Petriego oraz środowiska Labview. XVII Ogólnopolska Konferencja Trakcji Elektrycznej SEMTRAK 2016, *Zakopane*, 379–386.
- [9] PC6-288, opis ogólny generatora impulsów udarowych dużej energii.
- [10] PN-EN 61000-4: Kompatybilność elektromagnetyczna (EMC) – Część 4-5: Metody badań i pomiarów. Badanie odporności na udary, 2014.
- [11] Główny Urząd Miar, Wyrażanie niepewności pomiaru, *Przewodnik* © ISO 1995.
- [12] Siwik A., Wróbel Z. 2002 Modelling and Metrological features in overvoltage protection testing efficiency of lightning arresters applied in the railway feed system. 26th International Conference on Lightning Protection, Poland.
- [13] Wróbel Z. 2011. Simulation Possibility of Performance of Avalanche Diode Using a Combination Wave Generator. IEEE 20th International Symposium on Industrial Electronics (ISIE), 27–30 jun 2011, Gdańsk.
- [14] Wróbel Z. 2010. Possibility of the modelling of combination waves generators. *Przegląd Elektrotechniczny* 86 (9), 289–292.
- [15] Wróbel Z. 2002. Analiza układów ochrony przeciwprzepięciowej urządzeń sterowania ruchem kolejowym. Rozprawa doktorska. Kraków: AGH.