

Wstępne studium efektywności zastosowania sieci neuronowych w badaniach obciążeń kolejowych podstacji trakcyjnych

W artykule przedstawiono wyniki zastosowania sieci neuronowej do wnioskowania o danych statystycznych zarejestrowanego przebiegu chwilowych wartości obciążeń kolejowej podstacji trakcyjnej. Wskazano na możliwe zalety tego typu wnioskowania, jak i pojawiające się trudności, na które trzeba będzie jeszcze zwrócić uwagę.

Wstęp

Przeprowadzone przez autorów badania [3, 4, 9, 12] wskazują, że moce zespołów prostownikowych zainstalowanych na kolejowych podstacjach trakcyjnych są dobrane ze znacznym przewymiarowaniem. Jest to wynik stosowania dostępnych metod projektowania wyposażenia wspomnianych podstacji. Duża zmienność obciążeń trakcyjnych uzasadnia potrzebę posiadania rezerw mocy w układach zasilania [7, 11]. Kwestią wartą rozważenia jest skala tego przewymiarowania oraz ewentualne sformułowanie nowych zasad budowy tych układów w oparciu np. o wykorzystanie możliwości związanych z zastosowaniem sztucznych sieci neuronowych (SSN). W artykule przedstawiono wstępne wyniki pomiarów obciążeń wybranej podstacji trakcyjnej.

1. Wyniki pomiarów obciążeń trakcyjnych

Poniżej przedstawiono (rys. 1) przykładowy przebieg obciążenia kolejowej podstacji trakcyjnej „R”, zarejestrowany w szczycie porannym [2, 8]. Rejestracja prądów i napięć, dla każdej podstacji „B”, „R” i „P”, była realizowana całodobowo z częstotliwością 2 kHz. Do badań, które opisano w punkcie 3, wykorzystano przebiegi o zredukowanej częstotliwości (do 100 Hz). Wynikało to z technicznych możliwości przekształcania danych na dostępnym sprzęcie komputerowym.

Natomiast w tabeli 1 przedstawiono zbiorcze wyniki analizy obciążeń dla szczytu porannego w wymienionych wyżej podstacjach trakcyjnych [2]. Niektóre z nich były użyte jako dane wejściowe i wyjściowe dla badań z wykorzystaniem sieci neuronowej.

2. Sieć neuronowa

Sieć neuronowa (sztuczna sieć neuronowa – SSN) jest to ogólna nazwa struktur matematycznych i ich programowych lub sprzętowych modeli, realizujących obliczenia lub przetwarzanie sygnałów poprzez rzędy elementów, zwanych sztucznymi neuronami, wykonujących pewną podstawową operację na swoim wejściu. Oryginalną inspiracją takiej struktury była budowa naturalnych neuronów, łączących je synaps oraz układów nerwowych, w szczególności mózgu [10, 13].

Mózg człowieka ciągle jest najpotężniejszym z istniejących obecnie urządzeń stosowanych do przetwarzania informacji w czasie rzeczywistym. Gdy ma się do czynienia z zadaniami ta-


kimi jak rozpoznawanie, skojarzenia czy klasyfikacja, mózg może pokonać nawet najszybszy superkomputer [5]. Sieci neuronowe natomiast mogą przeprowadzać niezwykle obliczenia i działania z bardzo dużą szybkością, wydajnością i dokładnością [5, 6].

2.1. Wprowadzenie

Rysunek 3 prezentuje strukturę utworzonej sieci neuronowej. Jest to struktura o jednej warstwie ukrytej (*hidden*). Warstwa ta składa się z 30 neuronów. Na wejściu warstwy nie zaimplementowano opóźnień dla tej warstwy. Funkcją aktywacji w warstwie ukrytej jest funkcja tangensoidalna (*tansig*). W warstwie wyjściowej (*output*) zastosowano liniową funkcję aktywacji.

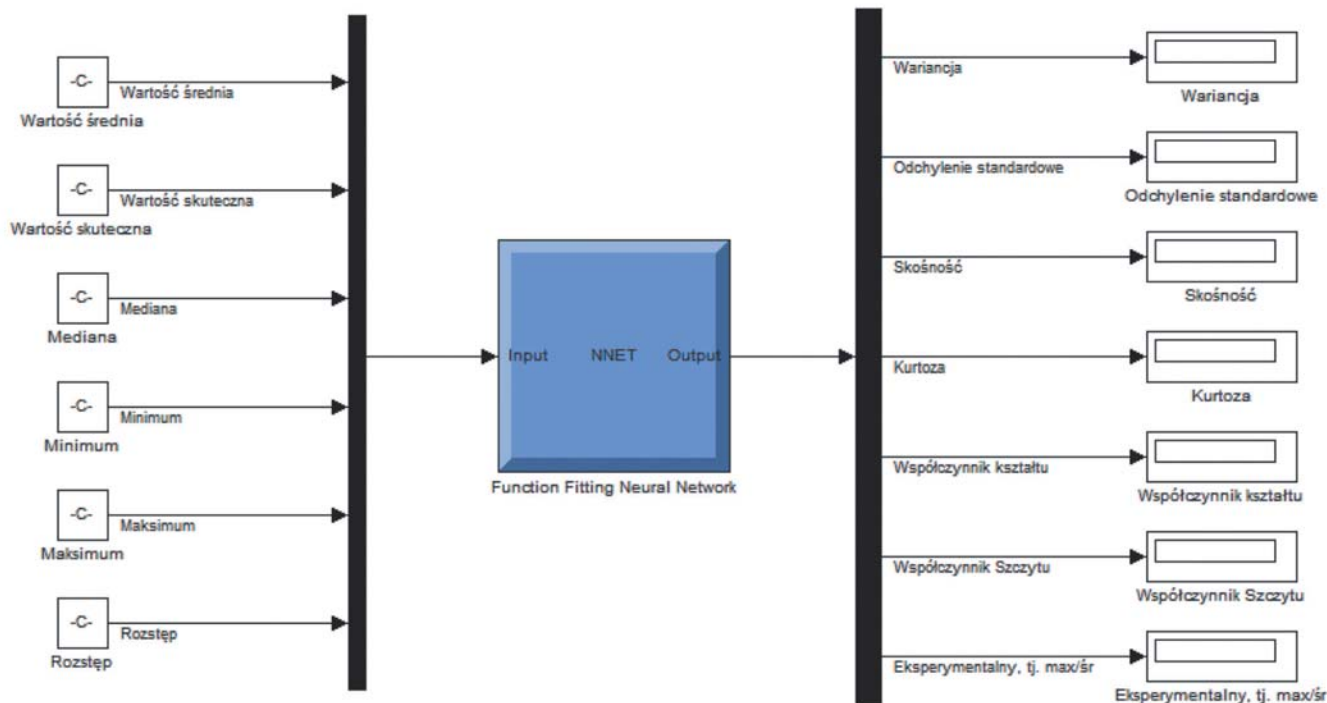
Zadaniem postawionym treningowi sieci była aproksymacja (*fitting a function*) wyników obliczeń parametrów elektrycznych i statystycznych przeprowadzonych na podstawie analizowanych danych dla wyników otrzymanych z wykonanych obliczeń i analiz badanych przebiegów. Obliczonymi parametrami statystycznymi były: wariancja, odchylenie standardowe, skośność, kurtoza. Danymi otrzymanymi z wykonanych obliczeń i analiz badanych przebiegów były: wartość średnia, wartość skuteczna, mediana, minimum, maksimum, rozstęp oraz współczynnik kształtu, współczynnik szczytu, współczynnik eksperymentalny, tj. (wartość max)/(wartość średnia).

Celem badań było określenie funkcji, która łączyłaby określonymi zależnościami możliwe do otrzymania w trakcie pomiarów



Rys. 1. Przebieg zmienności prądu w podstacji trakcyjnej „R” w godz. 6:00–8:00

Źródło: oprac. własne.



Rys. 2. Blok sieci neuronowej utworzonej w środowisku Simulink

Źródło: oprac. własne.

dane pomiarowe oraz dane elektryczne i statystyczne wynikające z obliczeń przeprowadzonych po ich zgromadzeniu.


Przedstawione poniżej (pkt 3.2) wyniki uzyskano dla następującego ustawienia parametrów uczenia się sieci neuronowej [1]:

- maksymalna liczba epok uczenia się: 100,
- współczynnik błędu treningu sieci: 0,
- współczynnik szybkości uczenia się sieci: 0,01,
- inkrement współczynnika szybkości uczenia się sieci: 1,05,
- dekrement współczynnika szybkości uczenia się sieci: 0,7,
- liczba błędnych powtórzeń treningu sieci: 6,
- maksymalny inkrement wydajności sieci: 1,04,
- momentum: 0,9,
- minimalny błąd gradientu treningu sieci: 10^{-10} ,
- liczba powtórzeń pomiędzy przedstawieniem wyniku uczenia się sieci: 25,

Tab. 1. Parametry elektryczne i statystyczne dla założonego szczytu porannego

| Podstacja | B | | R | | P | |
|----------------------------------|-----------|-----------|-----------|-----------|-----------|-----------|
| | 6:00–7:00 | 7:00–8:00 | 6:00–7:00 | 7:00–8:00 | 6:00–7:00 | 7:00–8:00 |
| Zakres czasowy | 6:00–7:00 | 7:00–8:00 | 6:00–7:00 | 7:00–8:00 | 6:00–7:00 | 7:00–8:00 |
| Wartość średnia [kA] | 0,6191 | 0,6829 | 0,7439 | 0,8881 | 0,3138 | 0,4025 |
| Mediana [kA] | 0,5896 | 0,6544 | 0,7168 | 0,8616 | 0,2912 | 0,3848 |
| Wartość minimalna [kA] | 0,1208 | 0,0880 | 0,0312 | 0,0704 | 0,0704 | 0,1084 |
| Wartość maksymalna [kA] | 1,8888 | 1,6056 | 1,4928 | 2,1624 | 0,7816 | 0,8488 |
| Rozstęp [kA] | 1,7680 | 1,5176 | 1,4616 | 2,0920 | 0,7112 | 0,7404 |
| Wariancja [kA] | 0,0477 | 0,0589 | 0,0212 | 0,0478 | 0,0125 | 0,0159 |
| Odchylenie standardowe [kA] | 0,2184 | 0,2426 | 0,1457 | 0,2186 | 0,1118 | 0,1260 |
| Skośność [-] | 0,9333 | 0,5867 | 0,7389 | 0,9710 | 0,6146 | 0,4873 |
| Kurtoza [-] | 4,6598 | 3,4000 | 3,2639 | 4,7379 | 2,8475 | 2,8445 |
| Współczynnik kształtu [-] | 1,0604 | 1,0612 | 1,0190 | 1,0298 | 1,0615 | 1,0478 |
| Współczynnik szczytu [-] | 2,8771 | 2,2155 | 1,9692 | 2,3642 | 2,3460 | 2,0125 |
| Współczynnik eksperymentalny [-] | 3,0509 | 2,3511 | 2,0066 | 2,4347 | 2,4904 | 2,1087 |

Źródło: oprac. własne.



Rys. 3. Struktura utworzonej sieci neuronowej

Źródło: oprac. własne.


- maksymalny czas treningu sieci: nieskończoność.

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

2.2. Przeprowadzenie obliczeń

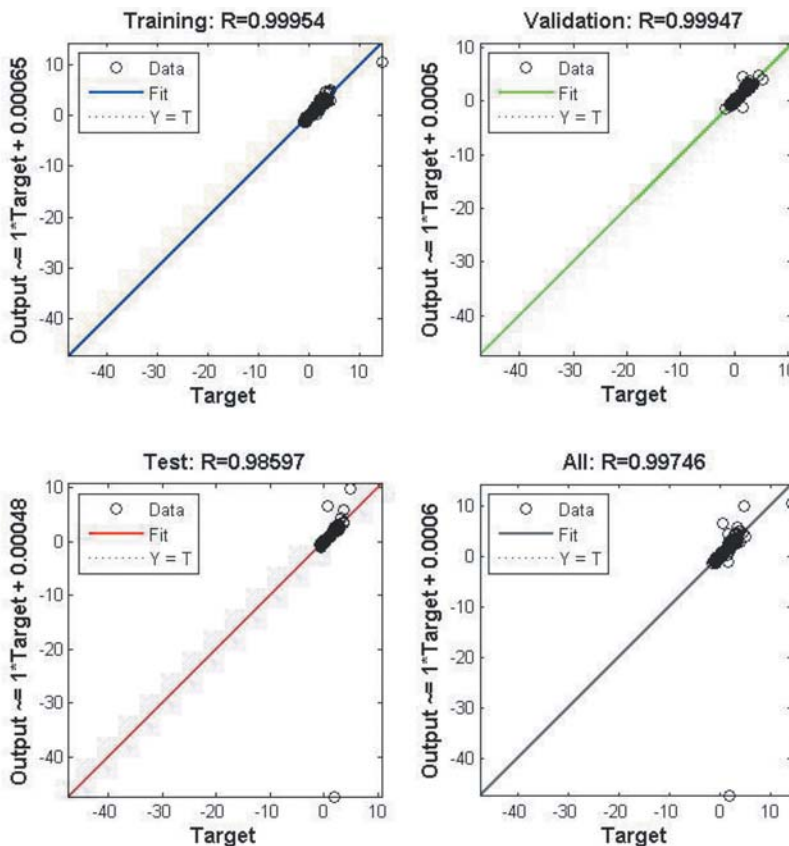
Na rysunku 4 przedstawiono wyniki uzyskane z treningu (*Training*), walidacji (*Validation*) i testu (*Test*) sztucznej sieci neuronowej w postaci histogramu błędów (*Error Histogram*).

Na rysunku 5 przedstawiono wykres obrazujący wydajność uczenia się SSN. Na osi rzędnych przedstawiono funkcję wydajności. Jako funkcję wydajności przyjęto błąd średni kwadratowy (*Mean Squared Error – mse*). Na osi odciętych zostały zapisane poszczególne epoki uczenia się sieci. Najlepszą walidację wydajności sieci neuronowej układ osiągnął dla epoki nr 12 i wyniosła ona 0,00062684. Widać, że układ sieci neuronowej przetwarzał algorytm uczenia się jeszcze przez 6 epok w celu potwierdzenia domniemanego minimum globalnego dla postawionego zadania przy utworzonej strukturze sieci (rys. 3). Od epoki nr 1 do epoki nr 12 widoczna jest tendencja spadkowa testów walidacji uczenia się sztucznej sieci neuronowej (SSN).




Rys. 4. Histogram błędu
Źródło: oprac. własne.

Rysunek 6 prezentuje 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 – według rysunku 2 (przeliczone wyniki pomiarów w rozdzielni napięcia stałego kolejowej podstacji trakcyjnej). Na osi odciętych prezentowane są wartości wyniku rzeczywistego (*targets*), do którego wyniki podawane przez wytrenowaną sieć neuronową powinny zmierzać.



Rys. 6. Wyniki regresji dla treningu, walidacji, testu i wypadkowej regresji dla wszystkich danych przeznaczonych do treningu SSN z nauczycielem
Źródło: oprac. własne.



Rys. 5. Wydajność uczenia się sztucznej sieci neuronowej
Źródło: oprac. własne.

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 wyżej przypadku są następujące: dla danych przeznaczonych dla treningu sieci $R = 0,99954$. Dane te stanowiły 70% wszystkich danych wykorzystanych na uczenie się SSN z nauczycielem. Dla danych przeznaczonych na walidację sieci $R = 0,99947$. Dane te stanowiły 15% wszystkich danych wykorzystanych na uczenie SSN z nauczycielem. Dla danych przeznaczonych na testy sieci $R = 0,98597$. Dane te stanowiły 15% wszystkich danych wykorzystanych na uczenie się SSN z nauczycielem. Dla wszystkich danych pomiarowych wypadkowa regresja $R = 0,99746$.

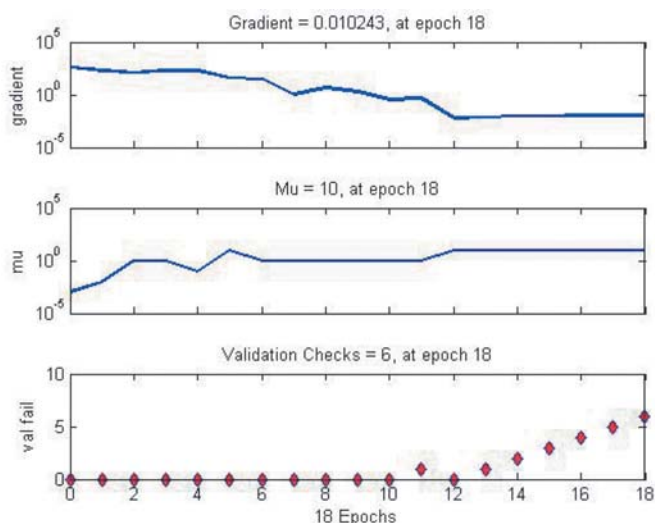
Trening, walidacja i test są wykonywane podczas procedury uczenia się sieci neuronowej.

Na rysunku 7 przedstawiono wybrane parametry SSN dla kolejnych epok uczenia się. Jak widać, gradient dla 18 epoki uczenia się wynosi 0,010243. Współczynnik μ dla tej epoki równa się 10.

Podsumowanie

Pomimo faktu, iż wyniki obliczeń wyglądają obiecująco, pamiętać należy, że wielkości statystyczne – między innymi takie jak wariancja czy też odchylenie standardowe – zależą od wartości chwilowych sygnałów mierzonych. W związku z powyższym w celu zmniejszenia błędów sieci należałoby wprowadzić do grona wartości wejściowych zbiór wartości chwilowych mierzonych przez tę aparaturę.

Zapoznanie się z możliwościami wykorzystania sieci neuronowych w badaniach parametrów zmienności obciążeń trakcyjnych powinno przyczynić się do powstania koncepcji z zakresu jakościowych zmian w projektowaniu i budowie układów zasilania dla linii kolejowych i tramwajowych. W efekcie powinno to przynieść ograniczenie zużycia energii, a w szczególności różnego rodzaju strat w systemie zasilania. Kolejnym pozytywnym efektem powinna być poprawa ekonomicznej konkurencyjności elektrycznego transportu szynowego oraz ograniczenie emisji szkodliwych czynników do atmosfery.



Rys. 7. Parametry błędów SSN dla danej epoki uczenia się: a) minimalny błąd gradientu treningu sieci, b) współczynnik μ , c) sprawdzenie walidacji

Źródło: oprac. własne.

Bibliografia:

- Bartman J., Podstawowe funkcje biblioteki narzędziowej „Neural Network Toolbox. Version 5” pakietu MATLAB v. 6, Uniwersytet Rzeszowski, Zakład Elektrotechniki i Informatyki: <http://www.neurosoft.edu.pl/jbartman/SSN%20w%20Matlabie.pdf> (dostęp z dnia 13.04.2014 r.).
- Drapik S., Kobielski A., Prusak J., Fluktuacja obciążeń podstacji trakcyjnych w ujęciu teorii szeregów czasowych, „Technika Transportu Szynowego” 2010, nr 7–8.
- Drapik S., Kobielski A., Prusak J., Selected Issues of Traction Substation Load Variability, [in:] *Modern Electric Traction, Power Supply*, K. Karwowski, A. Szelaąg (ed.), Gdańsk University of Technology, Gdańsk 2009.
- Dudzik M., Prusak J., Ocena możliwości miniaturyzacji podstacji trakcyjnych tramwajowych, Konferencja Naukowa „Ad-ductus 2012”, Politechnika Śląska, Katowice-Ogrodzieniec, 20–21 kwietnia 2012.
- Hilgard E. R., Wprowadzenie do psychologii, Państwowe Wydawnictwo Naukowe, Warszawa 1973.

- <http://www.mini.pw.edu.pl> (dostęp z dnia 11.03.2014 r.).
- Kałuża E., Bartodziej G., Ginalski Z., *Układy zasilania i podstacje trakcyjne*, Skrypty uczelniane nr 1220, Politechnika Śląska, Gliwice 1985.
- Kobielski A., Drapik S., Dudzik M., Prusak J., *Time Series as an Aid to Research of Traction Substation Load*. International Symposium on Power Electronics, Electrical Drives, Automation and Motion SPEEDAM 2012, Sorrento, 20–22 June 2012 [IEEE Conference Publicationa – materiały wydane w wersji elektronicznej].
- Kobielski A., Prusak J., Popczyk M., Ocena procedur pomiarowych na przykładzie zmienności kolejowych obciążeń trakcyjnych, „Czasopismo Techniczne. Elektrotechnika” 2009, R. 106, nr 1-E.
- Korbicz J., Obuchowicz A., Uciński D., *Sztuczne sieci neuronowe. Podstawy i zastosowania*, Akademicka Oficyna Wydawnicza PLJ, Warszawa 1994.
- Mierzejewski L., Szelaąg A., Gałuszewski M., *System zasilania trakcji elektrycznej prądu stałego*, Wydawnictwa Politechniki Warszawskiej, Warszawa 1989.
- Strojny J. (red.), Chrabąszcz I., Prusak J., Drapik S., *Trakcja elektryczna prądu stałego. Układy zasilania*, dodatek do miesięcznika „INPE” 2009, nr 11.
- Tadeusiewicz R., *Sieci neuronowe*, Akademicka Oficyna Wydawnicza RM, Kraków 1992.

Autorzy:

dr inż. **Andrzej Kobielski** – Instytut Pojazdów Szynowych, Wydział Mechaniczny, Politechnika Krakowska
 inż. **Sławomir Drapik** – ZUE S.A. Kraków
 dr inż. **Janusz Prusak**, mgr inż. **Marek Dudzik** – Katedra Trakcji i Sterowania Ruchem, Wydział Inżynierii Elektrycznej i Komputerowej, Politechnika Krakowska

Preliminary study of the neural networks application efficiency in research of railway traction substation load

The paper presents the results of a neural network application in use in inference of the statistical data, which were calculated from measured time signals of railway traction substation. There were pointed the possible advantages of this type of application, as well as appearing difficulties that should be paid attention.

Zapraszamy do ponowienia prenumeraty w 2015 r.

Cena miesięcznika w prenumeracie promocyjnej u Wydawcy

| Liczba zamówionych egzemplarzy | Koszt prenumeraty | | |
|--------------------------------|-------------------|------------|------------|
| | rocznej | półrocznej | kwartalnej |
| 1 | 348 zł | 174 zł | 87 zł |
| 2 lub więcej – każdy po | 312 zł | 156 zł | 78 zł |

Sposób zamówienia

Prenumeratory instytucjonalni: Zamówienia należy składać na adres Wydawcy. Płatność po otrzymaniu faktury wraz z pierwszym zamówionym numerem. Można dokonywać przedpłat na konto Wydawcy.

Prenumeratory indywidualni:

Wpłaty należy dokonywać na konto: Instytut Naukowo-Wydawniczy „TTS” sp. z o.o., ul. 25 Czerwca 68/62, 26-600 Radom
Numer rachunku bankowego 18 2490 0005 0000 4520 9624 5908 (ALIOR BANK)

Prenumerata promocyjna dla odbiorców indywidualnych

Podobnie jak w latach ubiegłych prenumeratory indywidualni mogą skorzystać z prenumeraty z bonifikatą 50%, jeżeli:

- prenumerują miesięcznik „Świat Kolei” (okresy prenumerat obu czasopism muszą się pokrywać),
- są studentami (dotyczy wszystkich uczelni i rodzajów studiów) lub uczniami średnich szkół technicznych o kierunku kształcenia transport (wymagane jest przesłanie kopii legitymacji studenckiej lub uczniowskiej). Cena jednego numeru z 50-procentową bonifikatą – 14,50 zł brutto z VAT.

Prenumeratę można zamawiać także w firmach: GARMOND PRESS S.A., Kolporter Sp. z o.o. Sp. k., „RUCH” S.A.