

Jerzy TCHÓRZEWSKI*

MODELOWANIE NEURONALNE ROZWOJU SYSTEMU ELEKTROENERGETYCZNEGO. CZĘŚĆ 1. OBSZARY MODELOWANIA

W pracy zamieszczono wybrane wyniki badań dotyczące modelowania neuralnego rozwoju systemu elektroenergetycznego. Zwrócono uwagę, że w modelowaniu neuronalnym wykorzystującym sztuczne sieci neuronowe projektuje się, a nie programuje rozwój systemu. Pokazano, że wśród różnych rodzajów architektury sztucznych sieci neuronowych oraz różnych reguł uczenia brak jest takich, które wprost odpowiadałyby naturze rozwoju SEE. Zwrócono uwagę na właściwości sieci perceptronowych, ontogenicznych oraz samorozwijających się, które możliwe są do wykorzystania przy projektowaniu i uczeniu modelu rozwoju SEE.

SŁOWA KLUCZOWE: sztuczne sieci neuronowe, rozwój systemów elektroenergetycznych, projektowanie rozwoju, algorytmy uczenia, inżynieria rozwoju

1. WPROWADZENIE

W związku ze wzrostem zapotrzebowania na badanie rozwoju systemów wielkich tej klasy jak system elektroenergetyczny (SEE lub system EE) poszukuje się nowych metod modelowania [2, 9]. Do metod modelowania zalicza się obok metod klasycznych (analitycznych i identyfikacyjnych) takie metody modelowania jak metody modelowania sztucznej inteligencji: neuralnego, ewolucyjnego, rozmytego, immunologicznego, mrówkowego, itp. [1, 7-10, 15-16].

Modelowanie neuronalne może dotyczyć m.in. systemów sterowania, systemów realizacji oraz systemów rozwoju. Na potrzeby tych zastosowań rozwijane są odpowiednie metody modelowania neuralnego i związane z nimi architektury i algorytmy uczenia sztucznych sieci neuronowych (SSN). I tak na potrzeby modelowania neuralnego systemów sterowania rozwinęły się m.in. SSN wielowarstwowe jednokierunkowe, SSN rekurencyjne oraz różnego typu systemy hybrydowe, w tym z zanurzeniami [7-10, 15-16]. Na potrzeby modelowania neuralnego systemów realizacji (wykonawczych) rozwinęły się m.in. SSN dualne, samoorganizujące się, chaotyczne, itp. [2, 5, 7, 10] Na

* Uniwersytet Przyrodniczo-Humanistyczny w Siedlcach.

potrzeby modelowania neuralnego systemów rozwoju rozwijane są m.in. SSN ontogeniczne oraz SSN samorozwijające się [2, 4, 11].

W modelowaniu neuronalnym wykorzystuje SSN, przy pomocy których projektuje się system EE, a następnie uczy modelu systemu. Do głównych zalet SSN wykorzystywanych w modelowaniu neuronalnym zalicza się m. in.: adaptacyjność, samoorganizację, możliwość równoległego przetwarzania informacji, niski koszt budowy modelu systemu oraz odporność na uszkodzenia. SSN nauczona modelu systemu EE posiada konkretną architekturę dostosowaną do struktury systemu, dobraną funkcję aktywacji do realizowanego procesu rozwoju systemu oraz wyuczone wartości wag połączeń neuronalnych. Wszystkie one predestynują SSN do ściśle zorientowanych kategorii zastosowań, jak na przykład do analizy danych ze zdolnością do wykrywania grup, klasyfikacji ze zdolnością do prowadzenia odkryć, aproksymacji, predykcji, optymalizacji, rozpoznawania obrazów, uczenia maszynowego, itp.

Do bardziej obiecujących rozwiązań należą SSN z zanurzeniami, w tym sieci, w których pojedyncze neurony złożone są z zanurzonych w nich sztucznych sieci neuronowych oraz tzw. systemowe sztuczne sieci neuronowe. Podstawowym dylematem projektanta używającego SSN jest kompromis między rozmiarami zbioru danych, przeznaczonego do nauki i testowania sieci oraz złożonością jej architektury. Mocno rozbudowana architektura SSN powoduje, że model systemu EE świetnie odwzorowujący zbiór danych użyty do estymacji parametrów, nie sprawdza się na zbiorze dotychczas nie używanych danych, pomimo przynależności do tej samej populacji statystycznej, gdyż występuje zjawisko przetrenowania sieci i brak generalizacji wiedzy.

Unikalne właściwości SSN, niemożliwe do powtórzenia przez żaden tradycyjny program komputerowy, pozwalają uzyskać znacznie lepsze wyniki w rozwiązywaniu zadań związanych z uczeniem, w tym uczeniem rozwoju systemu EE. SSN okazały się także prostym narzędziem wspomagającym rozwiązanie problemu poszukiwania prawidłowości rozwoju, zwłaszcza z zakresie obszaru data mining. Największą zaletą jest tutaj m.in. szybkość działania nauczonej sieci neuronowej, co wynika z równoległości przetwarzania informacji oraz ich oryginalnego sposobu funkcjonowania.

2. OBSZARY MODELOWANIA SYSTEMÓW

W naukach technicznych coraz częściej korzysta się z modelu systemu, przeprowadzając na nim eksperymenty badawcze zamiast przeprowadzać je na systemie rzeczywistym. Najczęściej wykorzystywanie modelu zamiast systemu jest podyktowane potrzebą zmniejszenia kosztów bądź uzyskania wyników badań w sytuacjach, które na rzeczywistym systemie są niemożliwe do uzyskania.

Do modelu systemu prowadzą różne drogi. Najczęściej korzysta się z modelowania analitycznego oraz modelowania identyfikacyjnego, a więc ze sposobu przybliżonego odtwarzania najważniejszych właściwości systemu. Takie ujęcie modelowania łączy w sobie modelowanie klasyczne, a więc tworzenie modelu matematycznego na podstawie praw rządzących systemem rzeczywistym (praw fizycznych, ekonomicznych, itp.) zwane modelowaniem analitycznym oraz modelowanie identyfikacyjne, najczęściej nazywane po prostu identyfikacją systemu [9, 11-14].

W ostatnim czasie wzrosło także zainteresowanie możliwością wykorzystania modelowania neuronowego do zbudowania modelu i nauczenia go rozwoju systemu EE [13-14]. Podstawowym celem modelowania w elektroenergetyce jest uproszczenie złożonej rzeczywistości obejmowanej systemem EE, pozwalające na poddanie wyodrębnionego z rzeczywistości systemu EE określonemu procesowi badawczemu, gdyż dzięki modelowaniu m.in. zmniejsza się lub powiększa system do dowolnej wielkości, jego podsystemy, a nawet układy. Zazwyczaj na modelu bada się wszystkie podsystemy, czy układy integrując je w jeden system jak np. system EE, czy wręcz przeciwnie bada się wybrany aspekt zagadnienia, pomijając inne, np. model rozwoju systemu elektroenergetycznej sieci przesyłowej.

Modelowanie pełni szczególną rolę w naukach technicznych oraz techniczno-ekonomicznych, traktujących systemy wielkie jak np. system EE jako systemy złożone, poddając je badaniom dzięki modelowaniu występujących w nim relacji i procesów.

Proces identyfikacji w takim ujęciu, pomimo swej odmiennej natury projektowej, może zostać zaliczony do modelowania i wówczas modelowanie identyfikacyjne dotyczy tworzenia modelu systemu przy wykorzystaniu praw statystyki odniesionych do systemu rzeczywistego, w którym prawa nim rządzące są niemożliwe lub trudne do wyodrębnienia. W chwili obecnej można ponadto mówić o neuronowej identyfikacji systemu EE, a więc o procesie tworzenia modelu systemu rzeczywistego EE w oparciu o zorientowany model sztucznej sieci neuronowej poddawany uczeniu na zbiorze danych liczbowych ujętych w pliku uczącym i pliku testującym [5, 7, 10, 15-16]. W wyniku przyjęcia uogólnionego pojęcia modelowania prowadzącego do uzyskania modelu systemu za pomocą różnych technik modelowania generuje się bazę wyjściową do definiowania szeregu sytuacji szczególnych.

Należą zatem do nich m.in.: modelowanie analityczne, w którym tworzony jest model matematyczny systemu w oparciu o znajomość praw natury fizycznej rządzących rzeczywistym obiektem systemu EE, modelowanie identyfikacyjne, w którym tworzony jest model systemu EE w oparciu o znajomość praw natury statystycznej rządzących rzeczywistym obiektem oraz modelowanie neuronalne, w którym tworzony jest model systemu EE w oparciu o znajomość praw natury adaptacyjnej rządzących rzeczywistym obiektem.

3. OBSZARY MODELOWANIA NEURONALNEGO

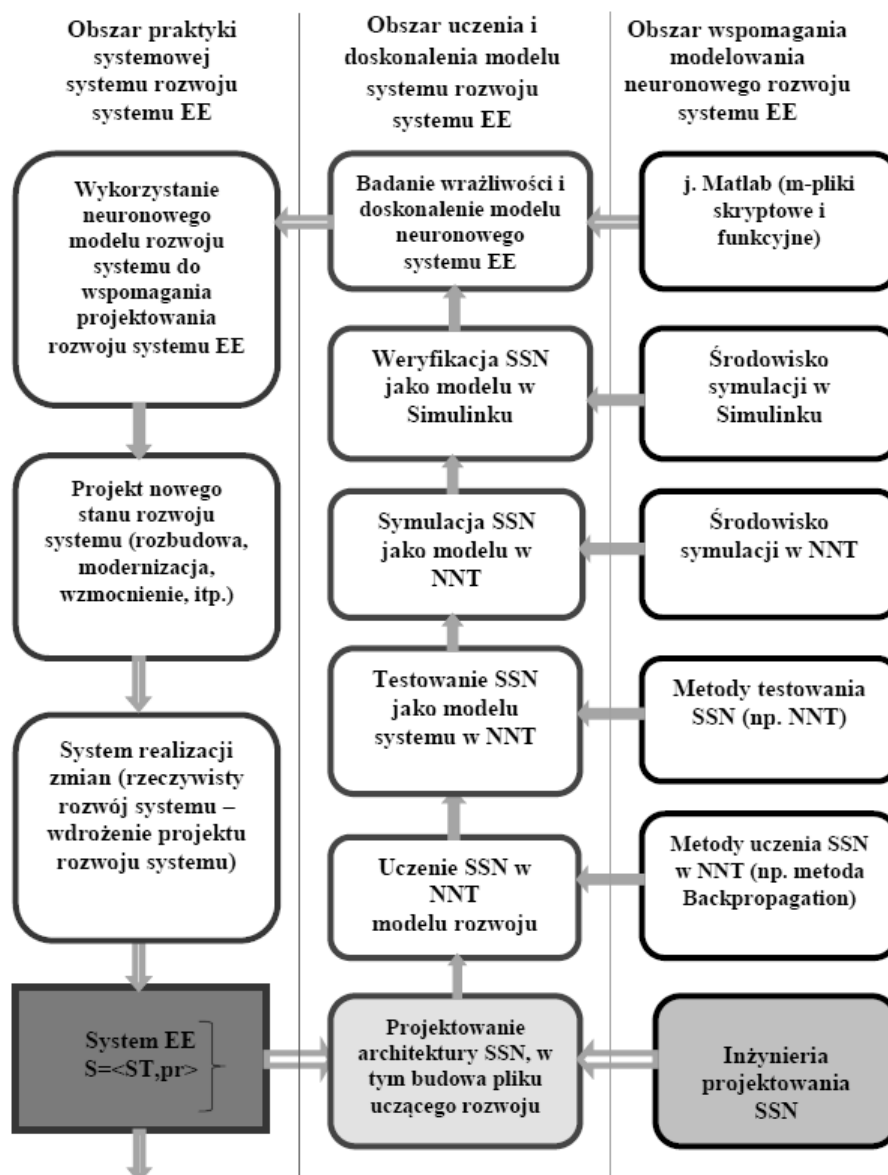
Wśród obszarów modelowania neuronowego systemu EE (rys. 1) wyróżnia się obszary: wspomaganie modelowania neuronowego rozwoju, uczenia i doskonalenia rozwoju oraz praktyki systemowej rozwoju systemu elektroenergetycznego.

Z każdym obszarem związane są określone środowiska programistyczne oraz metody projektowania i uczenia sztucznych sieci neuronowych. Wyróżnione obszary na rys. 1 dotyczą środowiska MATLABA i Simulinka, stąd w obszarze wspomaganie modelowania rozwoju zostały wyróżnione odpowiednie biblioteki oraz język Matlab. Najniższy poziom modelowania neuralnego wiąże się z systemowym ujęciem projektowania architektury SSN oraz pliku uczenia i testowania. W literaturze przedmiotu brak jest w tym względzie wypracowanych konkretnych metod przygotowania eksperymentu badawczego, w tym struktury pliku uczenia i testowania modelu systemu rozwoju systemu EE. Projektanci wykorzystują najczęściej inżynierię oprogramowania, jej metody i procedury projektowe. Właściwie przygotowany eksperyment badawczy wymaga dokładnej identyfikacji rozwoju systemu EE, w tym jego struktury i procesu rozwoju. Rozwój SEE oraz jego podsystemów rządzi się prawami rozwoju, dzięki czemu uczenie SSN modelu systemu ma swój głębszy sens. Jednakże katalog ogólnych praw rządzących rozwojem systemu EE nie jest jeszcze sporządzony. Można tutaj podjąć próbę odniesienia praw ogólnych systemów np. w ujęciu inżynierii systemów działania i mówić m.in. o: prawie zabezpieczenia systemu EE, prawie służby systemu, prawie rozwoju systemu (jego zamienialności) [3].

Następnym poziomem modelowania neuralnego jest poziom uczenia modelu systemu, który w środowisku MATLABA może być realizowany np. za pomocą wspomaganie w środowisku Neural Network Toolboxa oraz Fuzzy Logic Toolboxa. Istnieją przy tym różne metody uczenia, w tym Backpropagation. Brak jest jednak metod zorientowanych na systemy rozwoju. Nie ma metod doboru liczby neuronów wejściowych, wyjściowych oraz liczby warstw ukrytych i liczby neuronów w każdej warstwie ukrytej. Ponadto przyjęto, że ze sprzężeniami związane są jedynie wagi, co z punktu widzenia teorii sterowania można sprowadzić jedynie do członów proporcjonalnych. Brak jest uzasadnionych wyników badań dotyczących wykorzystania innych członów, jak np. całkowych czy też różniczkowych.

Do obiecujących metod uczenia SSN rozwoju systemu EE należą metody wykorzystywane w SSN ontogenicznych [2], w SSN rozwijających się [2, 9] oraz w SSN perceptronowych [1, 7-10, 15-16]. Jeszcze słabiej rozwinięte są metody testowania SSN, chociaż środowisko Neural Network Toolboxa ma wbudowane odpowiednie metody testowania. Na uwagę zasługują też metody

symulacji rozwoju za pomocą SSN oraz metody badania wrażliwości modeli rozwoju w celu doskonalenia modelu neuralnego rozwoju systemu EE. Otrzymany model neuronalny rozwoju systemu EE jest wykorzystywany do wspomagania projektowania rozwoju SEE.



Rys. 3. Ogólny schemat blokowy modelowania neuralnego rozwoju systemu EE.
[Źródło: Opracowanie własne]

4. WNIOSKI I KIERUNKI DALSZYCH BADAŃ

Obok modelowania analitycznego oraz modelowania identyfikacyjnego rozwijane są metody modelowania neuralnego. Brak jest jednak jeszcze rozwiniętej inżynierii projektowania neuralnego rozwoju systemu EE oraz metod uczenia i testowania modeli rozwoju.

W części 2 pn. Modele systemu IEEE RTS zamieszczono wybrane wyniki badań dotyczące modelowania neuralnego rozwoju systemu EE na bazie danych testowych IEEE RTS 96, m.in.: sposób tworzenia macierzy danych wejściowych oraz wyjściowych, sposób doboru parametrów sieci, itp. W wyniku projektowania i uczenia SSN uzyskano modele rozwoju SEE, które poddano badaniom wrażliwości m.in. na zmianę liczby warstw ukrytych oraz liczby neuronów w warstwie.

LITERATURA

- [1] Helt P., Parol M., Piotrowski P.: Metody sztucznej inteligencji w elektroenergetyce. OW PW. Warszawa 2000.
- [2] Jankowski N.: Ontogeniczne sieci neuronowe. O sieciach zmieniających swją strukturę. AOW EXIT. Warszawa 2003.
- [3] Konieczny J.: Inżynieria systemów działania. WNT. Warszawa 1983.
- [4] Kłopotek M., Tchórzewski J.: The concept of discoveries in evolving neural net. International Conference on "IIS. Advances in soft computing". IPI PAN. Warszawa 2002.
- [5] Korbicz J.: Sztuczne sieci neuronowe i ich zastosowanie w elektrotechnice i energetyce. Przegląd Elektrotechniczny nr 9/2009, s. 194-200.
- [6] MATLAB User's Guide. Inc. Natick 1994.
- [7] Osowski S.: Sieci neuronowe do przetwarzania informacji. OW PW. Warszawa 2000.
- [8] Rutkowska D., Piliński M., Rutkowski L.: Sieci neuronowe, algorytmy genetyczne i systemy rozmyte. PWN. Warszawa 1997.
- [9] Świerszcz M.: Sieci neuronowe w problemach modelowania, identyfikacji i sterowania procesów. PB. Białystok 2005.
- [10] Tadeusiewicz R. [i inni]: Wprowadzenie do sieci neuronowych. StatSoft, STATISTICA Neural Networks PL. Kraków 2001.
- [11] Tchórzewski J., Kłopotek M.: A case study in neural network evolution. Prace IPI PAN, nr 943, Warszawa 2002, s. 1-12.
- [12] Tchórzewski J.: Neural networks for processing knowledge about electric energy market. Academic Journals. Electrical Engineering, nr 53, s. 51-63, PP. Poznań 2007.
- [13] Tchórzewski J., Gawinkowki M., Korzeniowski M.: System identification toolbox and neural network toolbox using to searching discovery on electric power market. Poznań University of Technology Academic Journals, Electrical Engineering, nr 53, PP. Poznań 2007, s. 75-88.

- [14] Tchórzewski J.: Identification of the Electrical Energy Stock Exchange and creating knowledge maps using MATLAB environment with SIT and NNT Toolboxes. Energy Market 2009 6th International Conference on the European, 27-29, May 2009, pp.1-6.
- [15] Zieliński J.[i inni]: Inteligentne systemy w zarządzaniu. PWN. Warszawa 2000.
- [16] Żurada J., Barski M., Jędruch W.: Sztuczne sieci neuronowe. PWN. Warszawa 1996.

NEURONAL MODELING OF DEVELOPMENT POWER SYSTEM. PART 1. THE AREAS OF MODELING

The paper presents selected results of research on the modeling of neuronal development of the power system. It was noted that in neuronal modeling using artificial neural networks are designed, not programming system development. It is shown that among the various types of architecture of artificial neural networks and various learning rules, there is no such that directly correspond to the nature of the development of SEE. Attention was drawn to the network properties perceptron network, ontogeny network and self-evaluating network that are possible to be used in the design and development model SEE learning.