

DOI 10.21008/j.1897-0737.2020.104.0005

Jerzy TCHÓRZEWSKI*, Dariusz RUCIŃSKI**

MODEL SYMULACYJNY SYSTEMU TOWAROWEJ GIEŁDY ENERGII ELEKTRYCZNEJ Z WYKORZYSTANIEM WSPOMAGANEJ EWOLUCYJNIE ORAZ INSPIROWANEJ KWANTOWO SZTUCZNEJ SIECI NEURONOWEJ

Utworzono wspomaganą ewolucyjnie oraz inspirowaną kwantowo Sztuczną Sieć Neuronową, którą zaimplementowano w Simulinku na bazie danych Rynku Dnia Następnego Towarowej Giełdy Energii Elektrycznej. Dane wejściowe, wagi i biały poddano kwantyzacji. Kwantowe obliczenia quasi-równoległe przeprowadzono na bazie 100 wygenerowanych kwantowych liczb mieszanych za pomocą metody kwantyzacji na bazie stanów czystych $|0\rangle$ i $|1\rangle$, a uzyskane w wyniku obliczeń kwantowe liczby mieszane poddano dekwantyzacji za pomocą Sztucznej Sieci Neuronowej (SSN). Model symulacyjny składający się ze wspomaganej ewolucyjnie oraz kwantowo inspirowanej Sztucznej Sieci Neuronowej, oprócz badań symulacyjnych, umożliwia przeprowadzanie badań komparatystycznych uzyskiwanych sygnałów z danymi rzeczywistymi oraz z danymi wyjściowymi z perceptronowej Sztucznej Sieci Neuronowej. Wyniki badań wskazują na wysoką dokładność przeprowadzanego eksperymentu.

SŁOWA KLUCZOWE: badania komparatystyczne, badania symulacyjne, obliczenia kwantowe, sztuczne sieci neuronowe, towarowa giełda energii elektrycznej.

1. WPROWADZENIE

1.1. Założenia dotyczące eksperymentu

Do zaprojektowania i nauczenia modelu Sztucznej Sieci Neuronowej (modelu neutralnego MN) wybrano dwa rodzaje wielkości opisujących system Towarowej Giełdy Energii Elektrycznej (TGEE), to jest na wejściu – łączny wolumen energii elektrycznej (ee) dostarczonej i sprzedanej na TGEE w każdej godzinie doby [MWh] oraz na wyjściu – średnią ważoną wolumenem jednostkowej ceny sprzedanej ee uzyskanej w każdej godzinie doby [PLN/MWh].

Na podstawie tak zbudowanego modelu przeprowadzone zostały badania, które polegały na nauczeniu SSN modelu systemu rzeczywistego, co okazało się możliwe i pozwoliło na uzyskanie bardzo dokładnego modelu neuralnego TGEE na

* Uniwersytet Przyrodniczo-Humanistyczny w Siedlcach

** Doktorant Uniwersytet Przyrodniczo-Humanistyczny w Siedlcach

podstawie danych notowanych na Rynku Dnia Następnego (RDN), co zostało opublikowane m. in w pracach autorów [13–14, 19–22].

Do modelowania wykorzystane zostały dane liczbowe notowane na Rynku Dnia Następnego (wolumen ee oraz średnia ceny ważonej wolumenem ee) Towarowej Giełdy Energii S.A. (TGE S.A.) w okresie od 01.01.2015 r. do 30.06.2015 r., na której przyjęto, że Towarowa Giełda Energii Elektrycznej funkcjonuje jako podsystem [9, 23]. Dla celów implementacji modelu TGEE zbudowano perceptronową SSN (z jedną warstwą ukrytą) przyjmując metodę uczenia wstecznej propagacji błędu oraz funkcję aktywacji dla warstwy ukrytej – $\text{tansig}()$ oraz dla warstwy wyjściowej - funkcję liniową ($\text{purelin}()$). Stopień i jakość nauczania modelu systemu mierzone były za pomocą błędu średniokwadratowego (ang. Mean Squere Error - MSE) [2–3. 11, 15, 18].

1.2. Wspomaganie ewolucyjne i inspiracja kwantowa

Otrzymane w wyniku uczenia SSN wagi i biasy zostały poprawione za pomocą Algorytmu Ewolucyjnego (AE) [1, 10, 15], po czym jeszcze dostrojono je za pomocą inspirowanego kwantowo AE [4–6, 8, 16–17, 24]. Pewną nową propozycją prowadzenia obliczeń kwantowych jest tutaj kwantowe zdefiniowanie wartości sumatorów dla poszczególnych neuronów wyjściowych z poszczególnych warstw SSN, tzn. net_i^k , będących sumami iloczynów wektora wartości wag połączonych z danym neuronem (w_{ij}) oraz transponowanego wektora wartości wejściowych u_i^j . Tak wyznaczona wartość net_i^k jest podawana jako argument funkcji aktywacji $\text{tansig}(\text{net}_i^k)$ w warstwie ukrytej i $\text{purelin}(\text{net}_i^k)$ w warstwie drugiej [19–20]. W celu wyznaczenia wartości funkcji aktywacji macierz kwantową otrzymaną w wyniku mnożenia dwóch liczb kwantowych (wagi przez wejścia) poddano dekwantyzacji. Zaproponowano w tym przypadku nowatorskie rozwiązanie wykorzystujące perceptronową Sztuczną Sieć Neuronową, w której wejściem do sieci są elementy macierzy kwadratowej net_i^k będące stanami mieszanymi wyrażającymi odpowiednio quasi-splątane moduły prawdopodobieństwa α i β stanów czystych $\text{ket } 1$ oraz $\text{ket } 0$, a na wyjściu stany zapisane w postaci liczb dziesiętnych występujących w nauczanej modelu SSN (wartości rzeczywiste poszczególnych sumatorów net_i^k).

2. INSPIROWANY KWANTOWO ORAZ WSPOMAGANY EWOLUCYJNIE MODEL SYMULACYJNY TGEE

2.1. Projekt i implementacja hybrydowego modelu symulacyjnego

Zaprojektowany i zaimplementowany hybrydowy model systemu TGEE składa się zatem z modelu neuronowego, ze zmodyfikowanymi wagami i biasami za pomocą inspirowanej kwantowo SSN (model neuronalno-kwantowy, MNK) oraz poprawionymi wartościami wag za pomocą AE inspirowanego kwantowo.

Modelowanie neuronalne i symulacyjne oraz badania symulacyjne oraz komparatystryka modeli neuronalnych, a w następstwie też modeli neuronalno-ewolucyjnych oraz modeli neuronalno-ewolucyjno-kwantowych zostały przeprowadzone z wykorzystaniem języka Matlab i środowiska Simulink na przykładzie systemu TGEE z wykorzystaniem danych liczbowych notowanych na RDN.

A zatem zbudowano i nauczono model systemu SSN z wykorzystaniem danych liczbowych notowanych na TGEE RDN oraz skonstruowano kwantowo inspirowaną oraz ewolucyjnie wspomaganą SSN – kwantowy model ewolucyjno-neuronalny (KMN), który zaimplementowano w j. Matlab oraz zamodelowano w Simulinku.

Przeprowadzono kwantyzację wszystkich wartości wejściowych (macierze 24×181) oraz dwie macierze wag (macierze 24×24) oraz dwa wektory biasów (24×1) z wykorzystaniem 100 wygenerowanych kwantowanych liczb mieszanych na podstawie stanów czystych $|0\rangle$ i $|1\rangle$ odpowiadających stanom binarnym liczb rzeczywistych.


Natomiast w celu dekwantyzacji została skonstruowana SSN, którą nauczono generowania liczb rzeczywistych, w oparciu o wartości macierzy kwantowych otrzymanych dla każdego neuronu (kwadratowe macierze o splątanych wartościach kwantowych) jako danych wejściowych.

Dane wejściowe w postaci quasi-splątanych kwantowych liczb mieszanych zostały zdekwantyzowane i jako liczby rzeczywiste zostały wykorzystane jako argumenty w funkcji aktywacji \tanh . Podobny proces przeprowadzono także dla drugiej warstwy SSN, z funkcją aktywacji purelin .

2.2. Badania symulacyjne i komparatystyczne

W celu przeprowadzenia badań symulacyjnych i porównawczych skonstruowano odpowiedni schemat blokowy w Simulinku (rys. 1), który umożliwia badania symulacyjne, a także porównawcze kwantowo inspirowanej i ewolucyjnie wspomaganą SSN z perceptronową SSN oraz z danymi rzeczywistymi notowanymi na RDN TGEE.

Wybrane wyniki dla godzin: 24–01, 08–09 i 17–18 uzyskane w procesie porównywania sumatora net_i z perceptronowej SSN oraz kwantowo inspirowanej i ewolucyjnie wspomaganą SSN przedstawiono w tabeli 1. Można zauważyć, że SSN dokonująca dekwantyzacji wiernie odtworzyła rzeczywiste dane w badanej pierwszej warstwie neuronów, więc można je przyjąć do dalszego badania jako metodę dekwantyzacji quasi-splątanych liczb kwantowych.

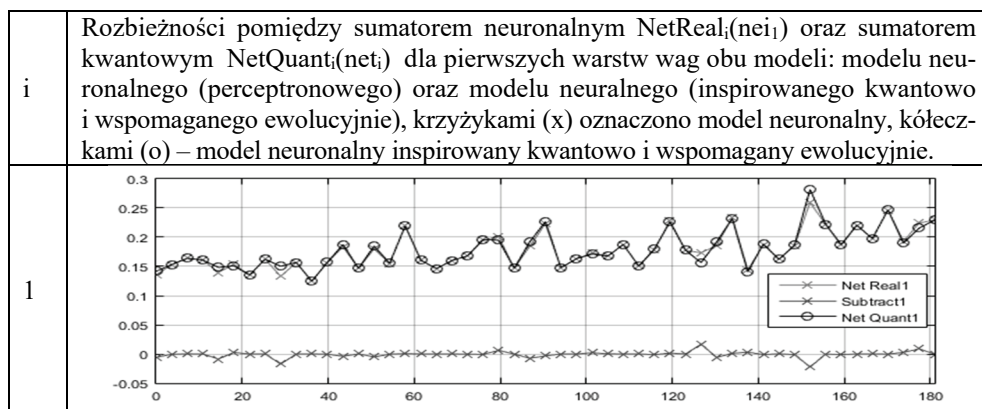


Rys. 1. Hybrydowy model symulacyjny TGEE złożony z modelu neuralnego inspirowanego kwantowo, którego parametry zostały poprawione ewolucyjnie z inspiracją kwantową z odniesieniem komparatystycznym do danych rzeczywistych i neuronowych. Oznaczenia w tekście. Źródło: Opracowanie własne w środowisku MATLAB-a i Simulink-a [12-14, 19-22]

Wskaźnik regresji dla pierwszej warstwy wyniósł 0,999137202244422, co jest wynikiem bardzo dokładnym, a więc SSN nauczona dekwantyzacji może zostać wykorzystana w modelu symulacyjnym do wspomagania ewolucyjnego oraz inspirowania kwantowego w celu zwiększania dokładności modelu neuronowego TGEE. W przypadku modelu dekwantyzacji drugiej warstwy wartości net_i uzyskane dla pierwszej warstwy aktywowano za pomocą funkcji aktywacji $purelin()$, a następnie zdekwantyzowano w taki sam sposób, jak dla pierwszej warstwy (tabela 2). Następnie na podstawie uzyskanej SSN przeprowadzono analizę porównawczą dokładności sumatora net_i dla drugiej warstwy. Uzyskane wyniki kwantowe zostały porównane z danymi wyjściowymi modelu neuronowego oraz rzeczywistymi danymi zarejestrowanymi na RDN, opublikowane m.in. w pracach autorów [13–14, 19–22].

Można zauważyć na wykresach zestawionych w tabeli 3, że algorytm kwantowy odzwierciedlił własności modelu neuralnego z większym opóźnieniem niż klasyczny model SSN nauczony modelu systemu TGEE dla danych RDN.

Tabela 1. Wyniki badań symulacyjnych i porównawczych pomiędzy sumatorem neuronalnym (perceptronowym) $NetReal_i(net_i)$, a sumatorem neuronalnym (inspirowanym kwantowo oraz wspomaganym ewolucyjnie) $NetQuant_i(net_i)$ dla ukrytej warstwy neuronów. Oznaczenia: i – i -ta godzina doby, $NetReal_i$ – i -ta wartość neuronalna (rzeczywista) na wyjściu z i -tego neuronu (net_i) dla warstwy ukrytej, $NetQuant_i$ – i -ta wartość neuronalna (kwantowo inspirowana i wspomaganą ewolucyjnie) na i -tym wyjściu (neuronie) dla warstwy ukrytej, $Subtract_i$ – i -ta różnica pomiędzy i -tym wyjściem kwantowym a i -tym wyjściem neuronalnym (różnica pomiędzy i -tymi sumatorami net_i dla warstwy ukrytej). Opracowanie własne w środowisku Simulink-a [12–14, 19–22].






Tabela 2. Wybrane wyniki badań komparatystycznych pomiędzy neti dla sumatora kwantowego a sumatorem neuronalnym dla warstwy wyjściowej neuronów. Oznaczenia: sumator net_i z warstwy wyjściowej dla rzeczywistych danych, Net Quant – wyjście net_i z ukrytej warstwy, dla danych kwantowych, Rozbieżność – różnica pomiędzy danymi kwantowymi a danymi rzeczywistymi dla warstwy wyjściowej dla Rynku Dnia Następnego. Opracowanie własne w środowisku Simulink-a [12–14, 19–22].

h	<p>Rozbieżności pomiędzy sumatorem neuronalnym NetReali (nei_i) oraz sumatorem kwantowym NetQuanti (net_i) dla drugich warstw wag obu modeli: modelu neuronalnego (rzeczywistego) oraz modelu neuralnego (inspirowanego kwantowo i wspomaganego ewolucyjnie), krzyżykami (x) oznaczono model neuronalny, kółeczkami (o) – model neuronalny inspirowany kwantowo wspomagany ewolucyjnie.</p>
---	---





Tabela 3. Wybrane przebiegi wielkości wyjściowych dla wybranych godzin uzyskane przy wykorzystaniu modelu symulacyjnego (rys.1) dla wszystkich 24 wielkości wyjściowych (średnia cena energii elektrycznej w godz. 0-24 w okresie od 01.01.2015 r. do 30.06.2015 r.. MN – Model Neuralny, KMNE – Kwantowy Model Neuralno-Ewolucyjny (oznaczony x). Opracowanie własne w Simulink-u [12-14, 19-22].



3. WNIOSKI I UWAGI KOŃCOWE

W przeprowadzonym eksperymencie została zaprojektowana SSN i nauczona modelu systemu TGEE z wykorzystaniem danych notowanych na RDN TGEE. Następnie zaproponowano wspomaganie algorytmem ewolucyjnym SSN w celu uzyskania poprawy modelu neuralnego. Wreszcie z wykorzystaniem nowej metody zaproponowano ewolucyjnie wspomaganą oraz inspirowaną kwantowo SSN.

Z jej wykorzystaniem uzyskano najlepsze wyniki od -0.04% do 0,05% w stosunku do wspomaganej ewolucyjnie SSN: od -0,11% do 0,12%, co wskazuje na duży stopień poprawy modelu neuralnego TGEE, dla którego błąd wyniósł: od -0,17% do 0.18%. Badania symulacyjne i komparatystyczne dotyczyły sprawdzenia stopnia poprawy parametrów modelu oraz dokładności generowania cen przez poszczególne modele TGEE w środowisku MATLAB-a i Simulink-a. Okazało się, że SSN inspirowana kwantowo oraz wspomagana AE inspirowanym kwantowo poprawiła błąd MSE o rząd wielkości z zakresu: od -0,17% do 0,18% do zakresu: od -0,04% do 0,05%, a więc o rząd wielkości, pomijając sam fakt, iż błędy te i tak były niewielkie [12-14, 19-22].

LITERATURA

- [1] Arabas J., Wykłady z Algorytmów Ewolucyjnych. WNT Warszawa (2016).
- [2] Ciechulski T., Osowski S., Badanie jakości predykcji obciążeń elektroenergetycznych za pomocą sieci neuronowych SVM, RBF i MLP. Przegląd Elektrotechniczny, R. 90, nr 8, pp.148-151, (2014).
- [3] Dudek-Dyduch E., Tadeusiewicz R., Horzyk A., Neural network adaptation process effectiveness dependent of constant training data availability, Neurocomputing, Volume 72, Issues 13–15, pp. 3138-3149 (2019).
- [4] Giaro K., Kamiński M., Wprowadzenie do algorytmów kwantowych. AOW EXIT, Warszawa (2003).
- [5] Heller M., Elementy mechaniki kwantowej dla filozofów. Copernikus Center Press, Kraków (2016).
- [6] Hirvensalo M., Algorytmy kwantowe. WSiP, Warszawa (2004).
- [7] Kaczorek T., Dzieliński A., Dąbrowski W., Łopatka R., Podstawy teorii sterowania. WNT, Warszawa (2005).
- [8] Le Belac M., Wstęp do informatyki kwantowej. Wydawnictwo Naukowe PWN, Warszawa (2018).
- [9] Mielczarski W., Rynki energii Elektrycznej. Wybrane aspekty techniczne i ekonomiczne. ARE S.A. i Energoprojekt-Consulting S.A., Warszawa (2000).
- [10] Obuchowicz A., Algorytmy ewolucyjne z mutacją stabilną, OW EXIT, Warszawa (2013).
- [11] Osowski S., Sztuczne sieci neuronowe do przetwarzania informacji, OW PW, Warszawa (2013).
- [12] Ruciński D., Modelowanie neuronalne cen na Towarowej Giełdzie Energii Elektrycznej wspomagane algorytmem ewolucyjnym oraz inspirowane obliczeniami kwantowymi, rozprawa doktorska pod kierunkiem dr hab. inż. Jerzego Tchórzewskiego, prof. UPH w Siedlcach, IBS PAN, Warszawa (2018).
- [13] Ruciński D., The neural modeling in chosen task of Electric Power Stock Market. Studia Informatica. Systemy i technologie informacyjne, No 1-2/2017, pp. 1-22.
- [14] Ruciński D., Neural-evolutionary Modeling of Polish Electricity Power Exchange. Electrical Power Networks, XPlore Digital Library, Proceedings of Electric Power Networks, Szklarska Poręba (2016), pp. 1-6.

- [15] Rutkowska D., Piliński M., Rutkowski L., Sieci neuronowe, algorytmy genetyczne i systemy rozmyte. PWN, Warszawa (1997).
- [16] Sawerwain M., Wiśniewska J., Informatyka kwantowa. Wybrane obwody i algorytmy, PWN Warszawa (2015).
- [17] Susskind L., Friedeman A., Mechanika kwantowa. Teoretyczne minimum. Prószyński I S-ka, Warszawa (2016).
- [18] Tadeusiewicz R., Odkrywanie właściwości sieci neuronowych przy użyciu programów w języku C#. Polska Akademia Umiejętności, Kraków (2007).
- [19] Tchórzewski J., Ruciński D., Algorytm Ewolucyjny inspirowany informatyką kwantową do poprawy parametrów modelu neuralnego wyznaczania cen na Towarowej Giełdzie Energii Elektrycznej notowanych na RDN. Poznan University of Technology. Academic Journals Electrical Engineering, 100/2019, str. 121-135.
- [20] Tchórzewski J., Ruciński D., Model neuronalny wspomagany Algorytmem Ewolucyjnym inspirowanym obliczeniami kwantowymi do wyznaczania cen na Towarowej Giełdzie Energii Elektrycznej Rynku Dnia Następnego. ITM Web of Conferences 28, 01006 (2019), pp. 1-2.
- [21] Tchórzewski J., Ruciński D., Evolutionarily-Supported and Quantum-Inspired Neural Modeling Applied to the Polish Electric Power Exchange. IEEE Digital Library, Conference on Progress in Applied Electrical Engineering (PAEE), Koscielisko (2019), pp. 1-6.
- [22] Tchórzewski J., Ruciński D., Quantum inspired evolutionary algorithm to improve parameters of neural models on example of polish electricity power exchange. IEEE Digital Library, Proceedings of Electric Power Networks, Szklarska Poręba (2016).
- [23] Towarowa Giełda Energii S.A., www.tge.pl, last accessed 2020/01/21.
- [24] Wright J., Jordanov I., Quantum inspired evolutionary algorithms with improved rotation gates for real-coded synthetic and real world optimization problems. Integrated Computer-Aided Engineering, vol. 24/2017, no. 3, pp. 203-223.

SIMULATION MODEL OF THE POLISH POWER EXCHANGE SYSTEM USING EVOLUTIONALLY ASSISTED AND QUANTUM-INSPIRED ARTIFICIAL NEURAL NETWORK

An evolutionary-assisted and quantum-inspired Artificial Neural Network was created, which was implemented in Simulink on the Day-Ahead Market of the Polish Power Exchange. Input data, weights and bias were quantized. Quantum quasi-parallel calculations were carried out on the basis of 100 generated quantum mixed numbers using the quantization method based on pure states $|0\rangle$ and $|1\rangle$, and the resulting quantum mixed numbers were dequantized using another Artificial Neural Network. The implemented simulation model consists of evolutionarily assisted and quantum-inspired Artificial Neural Network, which in addition to simulation studies allows conducting comparative studies of obtained signals with real data and with output data from the perceptron Artificial Neural Network. The test results indicate the high accuracy of the experiment.

(Received: 04.02.2020, revised: 07.03.2020)