

ZASTOSOWANIE ALGORYTMÓW SZTUCZNYCH SIECI NEURONOWYCH DO PROGNOZOWANIA ZUŻYCIA ENERGII ELEKTRYCZNEJ

Mirosław WŁAS

Politechnika Gdańska, Wydział Elektrotechniki i Automatyki
tel: +48583472337 e-mail: miroslaw.wlas@pg.gda.pl

Streszczenie: W artykule przedstawiono algorytm przewidywania zużycia energii elektrycznej budynków mieszkalnych z wykorzystaniem informacji o produkcji i warunkach atmosferycznych. W artykule została zaproponowana własna metoda predykcji z wykorzystaniem wielowarstwowej jednokierunkowej sztucznej sieci neuronowej. W pracy zostały przedstawione podstawowe pojęcia z zakresu sieci neuronowych oraz testy działania programu prognozującego na podstawie rzeczywistych danych pomiarowych. Głównym zadaniem badawczym było sprawdzenie dokładności algorytmu predykcji do prognozowania zużycia energii elektrycznej. Ma to na celu uzyskanie programu, którego wyniki o charakterze ilościowym będą wykorzystywane do prognozowania potrzeb zakupowych na TGE (Towarowej Giełdzie Energii) przy udziale metody zakupu energii elektrycznej na Rynku Dnia Następnego.

Słowa kluczowe: prognozowanie zużycia energii, sztuczne sieci neuronowe.

1. WPROWADZENIE

1.1. Rynek energii

W Polsce od momentu wejście w życie w kwietniu 1997 roku ustawy Prawo energetyczne rozpoczął się proces tworzenia rynku energii elektrycznej. Od tej chwili energia elektryczna przestała być traktowana jako dobro powszechne, stała się towarem. Na rynku hurtowym energię można kupować w kontraktach bilateralnych, na giełdach i na internetowych platformach obrotu. W chwili obecnej w Polsce funkcjonują dwie giełdy energii: Towarowa Giełda Energii S.A. (TGE) oraz Rynek Energii Giełdy Papierów Wartościowych (POEE), z których bardziej płynna jest TGE [1]. Rynek energii jest więc podzielony na zasadnicze segmenty:

- rynek kontraktowy, gdzie handel energią odbywa się na podstawie kontraktów pomiędzy wytwórcami energii, a firmami handlującymi energią oraz klientami finalnymi,
- rynek giełdowy, obejmujący handel na Towarowej Giełdzie Energii S.A. Handel energią odbywa się głównie na tzw. Rynku Dnia Następnego (Day-Ahead Market), będącym rynkiem TGE, który umożliwia uczestnikom rynku wstępne zbilansowanie swoich pozycji kontraktowych [2]. Notowania na Rynku Dnia Następnego odbywają się codziennie w sesjach o godz. 8:30 i 10:30. Na podstawie zleceń kupna i sprzedaży energii elektrycznej powstaje krzywa popytu dla 1-godzinnych okresów rozliczeniowych,
- rynek bilansujący, który jest specyficznym obszarem rynku energii, na którym następuje bilansowanie różnic pomiędzy transakcjami zawartymi między poszczególnymi uczestnikami rynku, a rzeczywistym zapotrzebowaniem na energię elektryczną.

W roku 2013 handel energią wyniósł ponad 176 TWh, co oznacza, że obroty na parkiecie Towarowej Giełdy Energii stanowiły ponad 108 proc. krajowej produkcji i ponad 111 proc. zużycia prądu w Polsce [2]. Głównym założeniem zadania badawczego było opracowanie oraz zbadanie dokładności predykcji algorytmu do prognozowania zużycia energii elektrycznej. Ma to na celu uzyskanie programu, którego wyniki o charakterze ilościowym będą wykorzystywane do prognozowania potrzeb zakupowych na TGE przy udziale metody zakupu energii elektrycznej na Rynku Dnia Następnego. W tej sytuacji problem prognozowania zapotrzebowania na energię elektryczną jest zagadnieniem aktualnym i mającym duże znaczenie praktyczne [6].

1.2. Metody prognozowania


Do prognozowania krótkoterminowego można wykorzystać takie metody jak: metoda naiwna, metoda średniej ruchomej, metoda wygładzenia wykładniczego, metoda liniowa Holta [3,4,5,6]. W niniejszej pracy rozpatrzono metodę wykorzystującą algorytmy sztucznych sieci neuronowych, która została wykorzystana do predykcji zużycia energii elektrycznej w budynku mieszkalnym zasilanym ze stacji transformatorowej SN/nn, zlokalizowanej w Gdańsku. Na wstępie dane pomiarowe podzielono na dwie grupy danych z 41 dni służy do uczenia sieci. W dalszej części artykułu, wybrany algorytm prognozowania wraz z odpowiednio dobranymi współczynnikami, został przetestowany na większym, bo dwumiesięcznym, zestawie danych (62 dni pomiarowe). Jako horyzont prognozowania wybrano prognozowanie krótkoterminowe z wyprzedzeniem 1 dnia na kolejną godzinę doby. Do prognozowania użyto informacji o prognozie temperatury zewnętrznej na kolejny dzień pomiarowy. Informacje tę pobierano z serwerów pogodowych, które udostępniają takie dane z podziałem na godziny.

2. BUDOWA ALGORYTMU PROGNOZOWANIA


2.1. Sztuczne sieci neuronowe

W ramach niniejszej pracy zbudowano model sieci neuronowej składający się z neuronów z sigmoidalną funkcją aktywacji jak to pokazano na rys. 1. Chcąc dokładnie odwzorować prawo przyczynowe i współlistnienia możemy potraktować zużycie energii elektrycznej jako funkcję zależną od różnych parametrów (Tab. 1). W ten sposób określając czynniki wpływające na jej wielkość możemy zbadać ich udział w kreowaniu wyniku. Model sieci neuronowej zakłada jej wcześniejszą naukę w celu aproksymacji funkcji, tak aby błąd wynikający z różnicy pomiędzy jej odpowiedzią, a

rzeczywistym wynikiem był jak najmniejszy. W tym celu należy gromadzić dane historyczne na temat wartości wejść, przewidywanego wyniku i rzeczywistej wartości. Sieć neuronowa jest strukturą składającą się z neuronów. Podstawową architekturą sieci, użytą w niniejszej pracy, jest jednokierunkowa sieć (Rys 2). Większa ilość warstw ukrytych pozwala na dokładniejsze zamodelowanie wieloargumentowych funkcji. W niniejszej pracy użyto sieci trójwarstwowej: dwie warstwy ukryte (tab. 2) i jeden neuron wyjściowy.



Rys. 1. Schemat neuronu



Rys. 2. Schemat sieci neuronowej dwuwarstwowej

Tab. 1. Czynniki wpływające na zużycie energii elektrycznej

Odbiorca	Główny czynnik
Hotele	liczba zajmowanych pokoi temperatura zewnętrzna powietrza
Zakłady produkcyjne	uruchomione linie produkcyjne godziny pracy zakładu
Centra handlowe	godziny otwarcia temperatura zewnętrzna powietrza

2.2. Uczenie sieci neuronowych

Elementem który można modyfikować w sieci neuronowej jest tablica wartości współczynników wagowych. To wagi odpowiadają za obliczenia sieci, a ich modyfikacja pozwala na dostosowanie odpowiedzi udzielanej przez sieć. Zestawienie ich wartości nazywane jest pamięcią sieci. Proces zmiany wartości wag nazywany jest uczeniem sieci neuronowej. Zazwyczaj wagi przy tworzeniu sieci są dobierane losowo, a następnie przy pomocy odpowiedniego algorytmu są modyfikowane wg. wzoru (1):

$$w_{ij}(k+1) = w_{ij}(k) + \Delta w_{ij} \quad (1)$$

Dużym problemem przy zmianie wartości wag w celu minimalizacji błędów średniokwadratowych jest wejście w obszar, w pobliżu którego kolejna zmiana nie zmniejsza znacząco wartości błędów. Obszar taki może być minimum lokalnym, a celem algorytmu uczącego jest osiągnięcie minimum globalnego. Rozwiązaniem takiego problemu jest metoda momentu, gdzie do ogólnego wzoru na zmianę wartości wagi (1) dodaje się dodatkowy człon zależny od wartości zmiany tej samej wagi w poprzednim cyklu:

$$\Delta^{\mu} w_{ij}(k) = [\eta \cdot f'(\varphi_j^{\mu}) \cdot (y z_j^{\mu} - y_j^{\mu}) \cdot x_i^{\mu}] + \alpha \cdot \Delta^{\mu} w_{ij}(k-1) \quad (2)$$

gdzie: η jest współczynnikiem szybkości uczenia, α jest współczynnikiem momentu, którego wartością oscyluje wokół jedności.

Zdefiniowanie wag początkowych polega na dobraniu losowych wartości z przedziału otwartego (0,1). Dane wejściowe są wykorzystywane przy obliczaniu odpowiedzi sieci, a wyjściowe przy określaniu wartości błędów. Na podstawie wyliczonych błędów kolejnych warstw następuje modyfikacja wag. Cykl uczenia przy którym następuje zmiana wag jest powtarzany dla wszystkich wektorów uczących podlegających podziałowi. Wektory uczące stnowi 41 dni pomiarowych. Jeśli po wykonaniu obliczeń dla wszystkich wektorów uczących, błąd średniokwadratowy sieci dla wszystkich wektorów jest większy od zadanego, cały cykl jest powtarzany. Algorytm uczenia (Rys. 6) różni się od algorytmu douczania (Rys. 7) tym, że na początku sam dobiera losowe wartości wag, podczas gdy przy douczaniu są one wczytywane z uprzednio przygotowanych plików konfiguracyjnych. Douczenie odbywa się na danych testowych, po każdym dniu pomiarowym, dla 62 dni pomiarowych.

3. BADANIA EKSPERYMENTALNE

Badania eksperymentalne wykonano dla przygotowania prognozy zużycia energii w budynku mieszkalnym wielorodzinnym wyposażonym w ciepłownię z pompą ciepła. Do zbierania i transmisji danych pomiarowych wykorzystano system z koncentratorem danych IED (Intelligent Electronic Devices), którego schemat przedstawiono na rys. 8. Dane wejściowe do sieci neuronowej zostały znormalizowane: (dzień roku, zakres 1 – 366, dzień tygodnia, zakres 0 (poniedziałek) – 6 (niedziela), godzina (zakres 0 – 23), temperatura otoczenia i przedstawione na rys. 3. Do badań użyto sieci trójwarstwowej o następujących parametrach:

- liczba warstw ukrytych – 2, 1 neuron wyjściowy
- liczba neuronów warstw ukrytych – Tab. 2,
- wartość błędów średniokwadratowych, poniżej którego można uznać sieć za nauczoną - 0,008 (1,6kWh),
- maksymalna liczba epok obliczania wartości wag dla neuronów,
- wartość współczynnika momentu uczenia,
- wartość współczynnika szybkości uczenia sieci,
- dobór algorytmu uczenia.

Każdą z opisanych w Tab. 2 konfiguracji sieci sprawdzono w następujących parametrach uczenia:


A) moment uczenia=0,5, szybkość uczenia=0,5, zakończenie uczenia gdy błąd średniokwadratowy spadnie poniżej 0,00005,

B) moment uczenia=0,2, szybkość uczenia=0,5, zakończenie uczenia gdy błąd średniokwadratowy spadnie poniżej 0,00005,

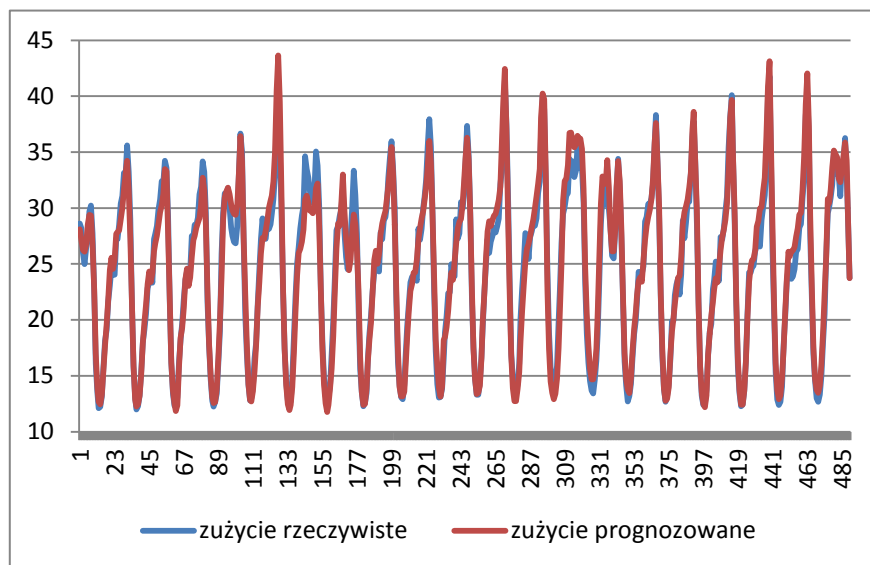
C) moment uczenia=0,5, szybkość uczenia=0,2, zakończenie uczenia gdy błąd średniokwadratowy spadnie poniżej 0,00005,

D) moment uczenia=0,2, szybkość uczenia=0,2, zakończenie uczenia gdy błąd średniokwadratowy spadnie poniżej 0,00005,


E) moment uczenia=0,5, szybkość uczenia=0,5, zakończenie uczenia gdy błąd każdego z wektorów uczących wyniesie mniej niż 0,008.



Rys. 3. Fragment znormalizowanych danych uczących (oś odciętych – kolejne godziny)



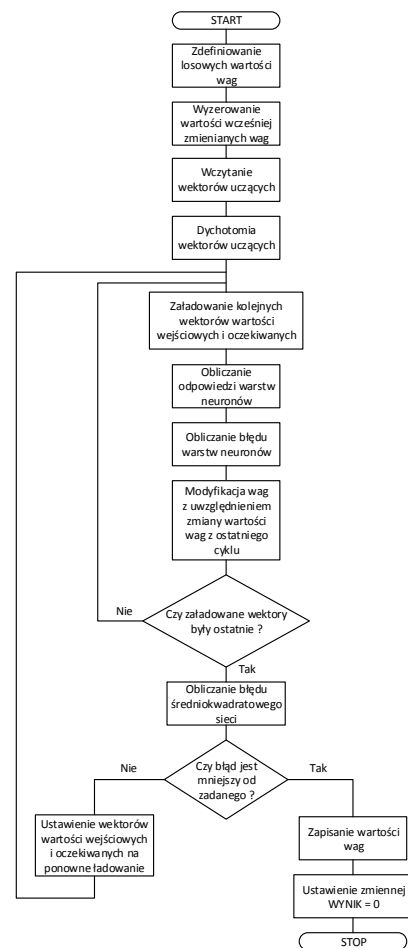
Rys.4. Porównanie rzeczywistego i prognozowanego zużycia energii, oś x – kolejne godziny



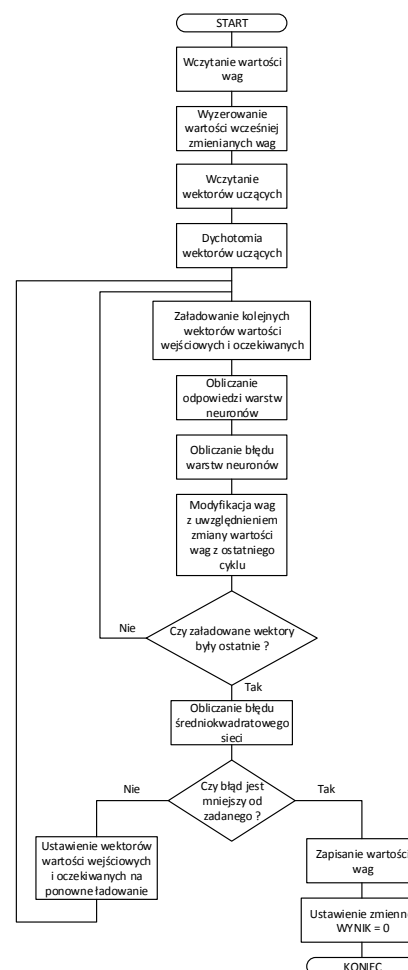
Rys.5. Względny błąd prognozy, oś x – kolejne godziny dla testowych dni pomiarowych

Tab. 2. Konfiguracje sieci neuronowych


	Liczba neuronów w pierwszej warstwie	Liczba neuronów w drugiej warstwie
Konfiguracja 1	5	10
Konfiguracja 2	10	10
Konfiguracja 3	10	100
Konfiguracja 4	30	100




Rys. 6. Algorytm uczenia



Rys. 7. Algorytm douczania



Rys. 8. System zbierania danych pomiarowych



Rys. 9. Uczenie sieci neuronowej konfiguracja 1D

Na rys. 9 przedstawiono wykres obrazujący uczenie się sieci wraz z upływającymi epokami. Został na nim pokazany przebieg dwóch zmiennych: „MSE” – (mean square error) jest to bieżąca wartość błędu średniokwadratowego, jaki towarzyszył procesowi uczenia, „l.błędów” przedstawia bieżącą liczbę neuronów, których wynikowy błąd jest większy od zadanej wartości dla wszystkich wektorów uczących. Wynik przeprowadzonych testów został przedstawiony w poniższej tabeli (Tab. 3). W komórkach zostały zawarte dwie wartości:

- górna wartość: łączny błąd średniokwadratowy obliczony podczas testu gotowej sieci (po uczeniu),
- dolna wartość: liczba wektorów uczących, których błąd podczas uczenia był większy od zadanej wartości.

Tab. 3. Wyniki uczenia sieci

	Konfiguracja 1	Konfiguracja 2	Konfiguracja 3	Konfiguracja 4
A	6,4 334	5,08 337	4,44 306	6,68 294
B	5,92 335	3,68 330	4,48 322	3,6 298
C	4,04 335	3,64 344	3,88 340	3,72 324
D	4,92 312	3,48 330	3,56 337	3,8 326
E	7,56 267	3,08 193	2,48 193	1,32 83

Podczas testów stwierdzono, że wraz z wzrostem liczby neuronów, wzrasta tendencja do zmniejszania się liczby

APPLICATION ARTIFICIAL NEURAL NETWORKS FOR ELECTRICITY PREDICTION

This paper presents a flexible approach to forecasting of energy consumption in residential buildings, using time series analysis and neural networks. Our goal is to develop a one day-ahead forecasting model based on an artificial neural network using information about temperature of air. The article has been proposed neural network prediction method using a multi-layered feed-forward artificial neural network with the backpropagation training algorithm. Experimental results have showed that the proposed neural network can faithfully reproduce the curve of daily energy consumption with a percentage error less than 3.74%.

Keywords: forecasting energy consumption, artificial neural network.

błędów popełnianych przez sieć. Testowanie sieci przeprowadzono na danych pomiarowych z 62 dni. Wyniki przedstawiono na rys. 4 i rys. 5. Względny średni błąd prognozy wynosił około 3,74%.

4. WNIOSKI KOŃCOWE

W artykule wykazano możliwość wykorzystania sieci neuronowych do prognozowania zużycia energii elektrycznej. Wyjątkowość metody predykcji polegała na doborze wektora uczącego tj. wzięto pod uwagę prognozę temperatury zewnętrznej (serwery pogodowe) oraz dzień tygodnia i dzień roku jako wejście do sieci. Dane prognozowane mogą być wykorzystane przez Sprzedawcę Energii lub Operatora Systemu Dystrybucyjnego. OSD zna obciążenie systemu i może przewidzieć problemy z dostawą energii, zaś Sprzedawca Energii zamawia ją na giełdzie TGE na następny dzień w korzystnych cenach. Niestety jeżeli popełni błąd, to wyrównanie różnic (zakup lub odsprzedaż) na rynku bilansującym, nie jest korzystne finansowo. Posiadając możliwość zarządzania swym rzeczywistym zapotrzebowaniem na energię, może zmniejszać powstałe różnice pomiędzy zamówieniem a faktycznym zużyciem. A to z kolei ogranicza jego straty finansowe. Dalsze badania przewidują wykorzystanie pompy ciepła (rys. 8) do sterowania rzeczywistym zużyciem, aby dostosować się do prognozy.

5. BIBLIOGRAFIA

1. Rynek Energii Elektrycznej i Gazu W Polsce. Stan na 31 marca 2016 r. Raport Towarzystwa Obrótu Energią 20 kwietnia 2016 r. [dostęp on-line dnia 21.09.2016: www.toe.pl]
2. „Rynek energii elektrycznej,” 4 Listopada 2014r. [dostęp on-line: <http://www.rynek-energii-elektrycznej.cire.pl/>]
3. K. Zajac, „Zarys metod statystycznych”, Warszawa: PWE, 1988.
4. T. Rubanowicz: „Metody predykcji produkcji mocy parku wiatrowego” Zastosowanie Komputerów w Nauce i Technice’ 2008”, Referat nr 33, Zeszyty Naukowe Wydziału Elektrotechniki i Automatyki PG, ISSN 1425-5766, Nr 25/2008, Gdańsk.
5. Qu Shilin, Sun Zhifeng: “BP Neural Network for the Prediction of Urban Building Energy Consumption Based on Matlab and its Application” Computer Modeling and Simulation, 2010. ICCMS '10. Second International Conference on (Volume:2). Sanya, Hainan: IEEE, 2010. Str. 263 - 267.
6. Szmit A.: „Prognozowanie zapotrzebowania na energię elektryczną studium empiryczne dla Regionu Łódzkiego”, Zastosowanie metod statystycznych w badaniach naukowych III, Statsoft Polska 2008 http://www.statsoft.pl/portals/0/Downloads/Prognozowanie_zapotrzebowania.pdf