

WYKORZYSTANIE SZTUCZNEJ SIECI NEURONOWEJ DO PRZEWIDYWANIA ZAPOTRZEBOWANIA NA MOC ELEKTRYCZNĄ

Autor: Łukasz Szablowski, Jarosław Milewski, Jerzy Kuta

(„Rynek Energii” – nr 1/2013)

Słowa kluczowe: sztuczne sieci neuronowe, zapotrzebowanie na energię elektryczną, predykcja

Streszczenie. Zaproponowano model sztucznej sieci neuronowej służący do przewidywania zapotrzebowania na moc elektryczną. Opracowana została odpowiednia architektura tej sieci pod względem ilości warstw jak również ilości neuronów w poszczególnych warstwach. Dane wejściowe do modelu stanowiły: obciążenie dobowe z dokładnością do 1 h oraz dzień tygodnia, którego to obciążenie dotyczyło. Natomiast na wyjściach sieci otrzymano przewidywane zapotrzebowanie na moc elektryczną dla dnia następnego. Sieć została nauczona na danych dotyczących obciążenia części Instytutu Techniki Ciepłej i Stołówki Centralnej Politechniki Warszawskiej z przedziału czasowego od 08.10.2011 do 15.10.2011 a przetestowana na danych z przedziału od 16.10.2011 do 23.10.2011.

1. WPROWADZENIE

Coraz bardziej popularne stają się zagadnienia związane z pracą źródła energii elektrycznej (i ciepłej) w rozproszonym systemie dystrybucji (ang. Distributed Generation), w którym to w przeciwieństwie do dużych klasycznych elektrowni [20] energia elektryczna jest produkowana bezpośrednio u odbiorcy przez małe lokale źródła. Małe źródła charakteryzują się znacznie korzystniejszymi wskaźnikami emisyjności [10]. Źródło pracujące w rozproszonym systemie dystrybucji energii elektrycznej muszą spełniać kilka wymagań, z których należy wymienić: wysoka sprawność wytwarzania energii elektrycznej oraz zapewnienie większości potrzeb energetycznych obiektu przy dostarczeniu możliwie małej ilości mediów (np. wyłącznie paliwa), praca w szerokim zakresie obciążeń, duża szybkość zmian obciążenia, szybki proces rozruchu/odstawienia, prosta obsługa (najlepszym rozwiązaniem byłaby tzw. bezobsługowość), wysoka trwałość.


Najczęściej rozważanym (i stosowanym) źródłem energetyki rozproszonej są silniki tłokowe [3]. Nie wszystkie źródła które są przewidywane do pracy w energetyce rozproszonej są w stanie elastycznie podążać za zmieniającym się obciążeniem. Do tego typu urządzeń zaliczyć można duże źródła przystosowane do spalania paliw stałych np. węgla czy biomasy. Przykładem tego typu źródeł może być układ ORC. Oprócz kwestii szybkości zmian obciążenia istnieje jeszcze jedno bardzo istotne zagadnienie związane z minimum technicznym urządzenia, po przekroczeniu którego możliwe jest jedynie odstawienie takiego źródła. Minimum te różnią się w zależności od typu źródła, przykładowo dla układu ORC minimum to może wynosić ok. 10% [8], dla ogniwa paliwowego SOFC—57% [25], a dla silnika tłokowego takie minimum praktycznie nie istnieje, gdyż może on pracować na tzw. biegu jałowym.

Sztuczne sieci neuronowe mogą być bardzo skuteczne jako narzędzia obliczeniowe w rozwiązywaniu takich zadań, z którymi typowe komputery i typowe programy sobie nie radzą (jak np. modelowanie ogniw paliwowych [9, 12, 19, 23]). W sztucznych sieciach neuronowych obliczenia są wykonywane równolegle, w związku z czym szybkość pracy sieci neuronowych może znacznie przewyższać szybkość obliczeń sekwencyjnych. Wykorzystując SSN występuje możliwość uzyskania rozwiązania problemu z pominięciem etapu konstruowania algorytmu rozwiązania problemu. Sieci nie trzeba programować, a wykorzystując istniejące metody uczenia i samouczenia uzyskuje się ich celowe i skuteczne działanie nawet w sytuacji, kiedy nie posiadamy wiedzy o algorytmie jakim jest rozwiązywane zagadnienie.

Dostępne dane literaturowe na temat wykorzystania sztucznych sieci neuronowych (SSN) do przewidywania zapotrzebowania na energię elektryczną sięgają wczesnych lat 90-tych. W [18] przedstawiono model (oparty o sztuczne sieci neuronowe) służący do przewidywania profilu obciążenia dla następnych 24 h oraz dla następnej godziny. Dane wejściowe do symulacji stanowiły profile obciążenia z dwóch poprzednich dni oraz przewidywana minimalna i maksymalna temperatura otoczenia. Model przetestowano dla danych z 1 roku z Greckiego systemu elektroenergetycznego (Greek interconnected power system). Otrzymany uśredniony błąd przewidywania dla tego okresu wynosił 2,66%. Z kolei w [21] zaprezentowano automatycznie dostosowujący się model służący również do przewidywania dziennego oraz tygodniowego zapotrzebowania na moc elektryczną. Błąd otrzymany w ten sposób wynosił od 2,5 do 5,1%. Z kolei autorzy [22] użyli sztucznych sieci neuronowych do przewidywania obciążenia w trybie online. Model ten sprawdzono we Włoszech na danych od 15 lutego do 31 lipca 1993r. w wyniku czego otrzymano średni błąd od 1,93% (dla maksymalnego obciążenia) do 2,65% (dla obciążenia minimalnego). W [15] przedstawiono dość obszerną ocenę wyników zastosowania sztucznych sieci neuronowych przez różne ośrodki do krótkoterminowego przewidywania obciążenia elektrycznego oraz zapotrzebowania na gaz. Natomiast autorzy [24] przedstawili korzyści z zastosowania połączenia Logiki Rozmytej (Fuzzy Logic—FL) ze sztuczną siecią neuronową w porównaniu do modelu do przewidywania obciążenia o nazwie ARMA (Autoregressive Moving Average). W [1] został porównany tzw. neuro-fuzzy system (połączenie sztucznej sieci neuronowej z EFuNN (fuzzy neural network)) z ARIMA (Box-Jenkins autoregressive integrated moving average), programem do przewidywania obciążenia używanym przez Giełdę Energii w Wiktorii (Victorian Power Exchange—VPX) oraz z samą sztuczną siecią neuronową. Wszystkie porównywane opcje testowane były na danych opisujących zapotrzebowanie na moc elektryczną w stanie Wiktorii w Australii. W wyniku tych porównań najlepszy okazał się neuro-fuzzy system. Nieco inną tematyką zajęli się autorzy [16], którzy skupili się na wykorzystaniu sztucznych sieci neuronowych do przewidywania szczytowego zapotrzebowania na moc elektryczną w Tajwanie. Nauka sieci odbywała się na podstawie danych od 1981 r. do 1997 r., natomiast testowanie—od 1997 r. do 2000 r.. W [7] zaproponowano model do przewidywania obciążenia na 24 h na podstawie danych pogodowych (temperatura, wilgotność względna, całkowite promieniowanie słoneczne). Model uczono na historycznych danych dla części sieci elektroenergetycznej w Palermo (Włochy) w okresie od 2001 do 2003 r. Średni błąd predykcji dla tego przypadku wynosił 1,97%. Z kolei w [6] pokazano zintegrowany algorytm genetyczny (GA) oraz sztuczną sieć neuronową do przewidywania zużycia energii elektrycznej w irańskim sektorze rolnym. Algorytm genetyczny był badany na danych od 1981 do 2005r., natomiast sztuczna sieć neuronowa została użyta od przewidzenia zużycia energii elektrycznej do roku 2008. W [5] przedstawiony został algorytm oparty o sztuczną sieć neuronową, służący do przewidywania miesięcznego zużycia energii w Iranie od marca 1994 do lutego 2005. Natomiast w [4] przedstawiony został hybrydowy model do przewidywania godzinowego obciążenia elektrycznego wykorzystujący transformację falową (wavelet transform—WT), sieć neuronową oraz algorytm ewolucyjny (evolutionary algorithm—EA). Tak stworzony model został przetestowany na danych dla Nowego Jorku z dnia 1 lipca 2004r., w wyniku czego otrzymano średni błąd przewidywania na poziomie 2,06%. W [17] zaprezentowano model wykorzystujący sztuczne sieci neuronowe do przewidywania zużycia energii elektrycznej w Turcji. Dane wejściowe do modelu stanowiły wskaźniki ekonomiczne takie jak: produkt narodowy brutto, populacja czy import i eksport. Druga wersja modelu posiadała na wejściu jedynie stosunek importu do eksportu oraz czas. Wynikiem tych prac było przewidzenie zużycia energii elektrycznej w Turcji do roku 2027 przy użyciu danych od 1975 r. do 2006 r. wraz z wymienionymi wcześniej współczynnikami ekonomicznymi. W przeciwieństwie do poprzednich przykładów w [2] sztuczna sieć neuronowa została wykorzystana do przewidzenia danych wejściowych (gross domestic product—GDP, temperatura, czas nasłonecznienia wilgotność) do modelu przewidującego szczytowe obciążenie elektryczne w Mauritiusie metodą NHGDP (non-homogeneous Gompertz diffusion process). W [11] zaprezentowano sieć neuronową w oparciu o adaptacyjną teorię rezonansu (adaptive resonance theory) inaczej distributed ART oraz HS-ARTMAP (Hyper-spherical ARTMAP network) do przewidywania obciążenia elektrycznego.

2. MODEL MATEMATYCZNY SZTUCZNEJ SIECI NEURONOWEJ


Model oparty o sieć neuronową jest modelem czarnej skrzynki, który generuje odpowiedź natychmiast po podaniu odpowiedniej konfiguracji danych wejściowych. Sztuczna sieć neuronowa składa się z neuronów, które to są odpowiednio ułożone w kolejne warstwy (rys. 1). Dane wejściowe są przetwarzane przez neurony pierwszej warstwy a następnie, przetworzona informacja jest przekazywana do kolejnej warstwy. Poza danymi wejściowymi do danego neuronu, stosowany jest jeszcze dodatkowo parametr aktywacyjny neuron (ang. bias).



Rys. 1. Model sztucznej sieci neuronowej

Po dostarczeniu danych wejściowych do danego neuronu, każda wartość jest mnożona przez odpowiadającą danemu wejściu wagę ($w_{k,i,j}$), następnie wszystkie te wielkości są sumowane ($s_{k,i}$). Do tej sumy dodawany jest tzw. bias ($x_{k,0}$). Wynik tego działania zostaje przetworzony przez funkcję aktywacji neuronu (patrz równanie 2). W ten sposób otrzymywana jest odpowiedź ($y_{k,i}$) danego neuronu na zadane wejścia. Wyjścia z warstwy poprzedzającej są wejściami warstwy następującej, poza jednym wyjątkiem tj. dla warstwy ostatniej, wyjścia poszczególnych neuronów są odpowiedziami całego modelu.

W obliczeniach odnośnie omawianego modelu przyjęto, iż funkcją aktywacji neuronu jest tangens hiperboliczny dla wszystkich neuronów poza warstwą ostatnią, oraz funkcja liniowa dla neuronów warstwy ostatniej (rys. 2).



Rys. 2. Schemat neuronu (a) wraz z jego matematycznym odpowiednikiem (b) [13]

W trakcie obliczeń informacje przechodzą kolejno od pierwszej aż do ostatniej warstwy sieci. Odpowiedzi neuronów w ostatniej warstwie są parametrami wyjściowymi modelu sztucznej sieci neuronowej (rys. 1).

Jako podstawowy algorytm uczenia została przyjęta metoda wstecznej propagacji błędów (ang. back-propagation), która jest uogólnionym sposobem nauczania sieci podanym przez Widrow'a i Hoff'a, stosowaną do sieci wielowarstwowych, o nieliniowych ale różniczkowalnych funkcjach aktywacji w neuronach. Szczegółowy opis procedury można znaleźć w [13]. Poniżej zostały podane główne równania tej procedury, tj.:

$$s_{k,i} = \sum_{j=0}^{N_{k-1}} w_{k,i,j} \cdot x_{k,j} \quad (1)$$

$$y_{k,i} = f(s_{k,i}) \quad (2)$$

$$\varepsilon_{L,i} = d_{L,i} - y_{L,i} \quad (3)$$

$$\delta_{k,i} = \varepsilon_{k,i} \cdot \frac{\partial f(s_{k,i})}{\partial (s_{k,i})} \quad (4)$$

$$\varepsilon_{k,i} = \sum_{m=1}^{N_{k+1}} \delta_{k+1,m} \cdot w_{k+1,m,i} \quad \text{dla } k = 1, 2, \dots, L-1 \quad (5)$$

$$w_{k,i,j}^{n+1} = w_{k,i,j}^n + 2 \cdot \eta \cdot \delta_{k,i} \cdot x_{k,j} + \alpha \cdot (w_{k,i,j}^n - w_{k,i,j}^{n-1}) \quad (6)$$

gdzie: η —współczynnik określający szybkość nauki, α —współczynnik określający zmianę wagi w stosunku do zmiany z poprzedniego kroku (ang. Momentum, reszta parametrów odpowiada oznaczeniom z rysunków 2 i 1.


Do obliczeń sieci neuronowych wykorzystano komercyjnie dostępne narzędzie [13] o nazwie MATLAB. W celu przyspieszenia procesu nauki zastosowany został algorytm Levenberg'a-Marquardt'a [13].

W przypadku wykorzystywania sztucznych sieci neuronowych uczonych na danych doświadczalnych występuje niebezpieczeństwo tzw. przetrenowania sieci (ang. overfitting). Oznacza to, iż sieć się nauczyła danych doświadczalnych z ponadprzeciętną dokładnością tak, że stała się wrażliwa na zakłócenia i błędy pomiaru. Oznacza to, iż sieć niejako nauczyła się na pamięć konkretnych danych doświadczalnych i nie potrafi generalizować zależności pomiędzy nimi występujące. W celu uniknięcia tego zjawiska zastosowano możliwie prostą strukturę sieci, tak aby ilość zastosowanych warstw i neuronów nie pozwalała sieci na przetrenowanie. Kolejnym sposobem jaki został wykorzystany w celu uniknięcia przetrenowania sieci, było zastosowanie odpowiedniego algorytmu generalizującego wyniki podczas procesu nauczania. W tym celu została wykorzystana automatyczna regulacja parametrów uczących Bayes'a. Szczegółowy opis tej procedury jak i algorytmu Levenberg'a-Marquardt'a można znaleźć w [14].

Podczas korzystania z algorytmu Levenberg'a-Marquardt'a z regulacją Bayes'a, ważne jest, aby pozwolić algorytmowi działać do czasu aż efektywna liczba parametrów osiągnie zbieżność. Trening zostanie zatrzymany przez komunikat "Maximum MU reached". Szczegółowe wyjaśnienie parametrów algorytmu uczącego można znaleźć w [13].

Architektura sieci oznaczana jest w następujący sposób: „ilość wejść–ilość neuronów w pierwszej warstwie–ilość neuronów w drugiej warstwie”; np. 9–7–1 oznacza, że dwuwarstwowa sieć zawiera dziewięć wejść, siedem neuronów w pierwszej warstwie i jeden neuron w warstwie drugiej (ilość neuronów w ostatniej warstwie jest równoznaczna z ilością wyjść). W oparciu o przeprowadzoną analizę wybrano najbardziej odpowiednią architekturę SSN, na którą składają się: jedna warstwa wejściowa, jedna warstwa ukryta oraz jedna warstwa wyjściowa. Ilość neuronów użytych zarówno w warstwie pierwszej jak i ostatniej zależy od ilości parametrów wejściowych i wyjściowych. Natomiast ilość neuronów w warstwie ukrytej została określona w trakcie procesu uczenia. Sieć posiada 25 wejść, z których 24 stanowi zapotrzebowanie na moc elek-

tryczną (z dokładnością do 1 h) dla dnia poprzedniego a jedno oznacza dzień tygodnia. Warstwa wyjściowa zawiera 24 neurony, które odzwierciedlają przewidywane zapotrzebowanie na moc elektryczną dla następnego dnia. Dla tych warstw zastosowano odmienne rodzaje funkcji aktywacji neuronów. Dla pierwszej i dla ukrytych warstw użyto tangens hiperboliczny, natomiast dla warstwy wyjściowej—funkcję liniową.




Rys. 3. Model sztucznej sieci neuronowej (25–2–24) w programie MATLAB

Ilość neuronów w warstwie ukrytej została wyznaczona metodą prób i błędów. Przetestowano sieci zawierające od 1 do 25 neuronów w warstwie ukrytej.

3. PRZEWIDYWANIE ZAPOTRZEBOWANIA NA MOC ELEKTRYCZNĄ PRZY POMOCY SZTUCZNEJ INTELIGENCJI


Rzeczywiste dane dla części budynku Instytutu Techniki Ciepłej i Stołówki Centralnej Politechniki Warszawskiej (zasilanych poprzez wspólny transformator) z przedziału czasowego od 08.10.2011 do 15.10.2011 zostały wykorzystane do nauki sieci neuronowej.

Sieć ta została przetestowana na danych, które nie zostały użyte do nauki (z innego przedziału czasowego). Po wprowadzaniu na wejścia sieci kolejno obciążeń (i związanych z nimi dni tygodnia) z przedziału od 16.10.2011 do 22.10.2011 otrzymano symulacje obciążeń dobowych dla przedziału czasowego od 17.10.2011 do 23.10.2011.



Rys. 4. Wyniki symulacji zapotrzebowania dla danych użytych do nauki sieci neuronowej w układzie 25–1–24


Na rysunku 4 przedstawiono wyniki symulacji dla danych, które były użyte do nauki sieci w układzie 25–1–24 (25 wejść, 1 neuron w warstwie ukrytej i 24 neurony w warstwie wyjściowej).



Rys. 5. Wyniki symulacji zapotrzebowania dla danych z innego przedziału czasowego niż dane użyte do nauki sieci w układzie 25–1–24

Symulacja ta całkiem dobrze odzwierciedla rzeczywiste zapotrzebowanie na moc elektryczną, jednakże w przypadku symulacji na danych z innego zakresu czasowego (nieużytego do nauki) sieć neuronowa w układzie 25–1–24 przestaje sobie radzić (rys. 5).


Z punktu widzenia danych użytych do nauki sieci neuronowej wyniki symulacji ulegają poprawie wraz ze zwiększającą się ilością neuronów w warstwie ukrytej aż do wariantu 25–6–24 (rys. 6), dla którego symulacja dokładnie pokrywa się z rzeczywistością.




Rys. 6. Wyniki symulacji zapotrzebowania dla danych użytych do nauki sieci neuronowej w układzie 25–6–24

Co nie oznacza tego, iż sieć neuronowa została zoptymalizowana, gdyż nie spowodowało to poprawy w przypadku danych nieużywanych do nauki (przykład na rysunku 7).

Najlepszą konfiguracją okazała się 25–14–24, ponieważ dała ona rozsądne wyniki przy możliwie małej liczbie zastosowanych neuronów (rys. 8). Dalsze zwiększanie liczby neuronów w warstwie ukrytej wydłużało proces uczenia się sieci nie powodując przy tym zauważalnej poprawy jej działania.



Rys. 7. Wyniki symulacji zapotrzebowania dla danych z innego przedziału czasowego niż dane użyte do nauki sieci w układzie 25–6–24



Rys. 8. Symulacja zapotrzebowania na moc elektryczną w porównaniu do jej rzeczywistych wartości

Jak widać na wspomnianym wykresie sztuczna sieć neuronowa całkiem dobrze odwzorowuje zapotrzebowanie na moc elektryczną. Cechą charakterystyczną dla tej symulacji jest to, iż pokazuje ona nieco „gładszy” profil zapotrzebowania od rzeczywistości zmierzonego.

4. PODSUMOWANIE

Zaproponowano model sztucznej sieci neuronowej służący do przewidywania zapotrzebowania na moc elektryczną. Opracowana została odpowiednia architektura tej sieci pod względem ilości warstw jak również ilości neuronów w poszczególnych warstwach. Dane wejściowe do modelu stanowiły: obciążenie dobowe z dokładnością do 1 h oraz dzień tygodnia, którego to obciążenie dotyczyło. Natomiast na wyjściach sieci otrzymano przewidywane zapotrzebowanie na moc elektryczną dla dnia następnego. Sieć została nauczona na danych dotyczących obciążenia części Instytutu Techniki Ciepłej i Stołówki Centralnej Politechniki Warszawskiej z przedziału czasowego od 08.10.2011 do 15.10.2011, a przetestowana na danych z przedziału od 16.10.2011 do 23.10.2011. SSN całkiem dobrze odwzorowuje zapotrzebowanie na moc elektryczną. Jednakże sieć nie jest w stanie przewidzieć nagłych, chwilowych skoków obciążenia, które jak wiadomo zależne są w głównej mierze od czynnika ludzkiego. Sztuczna sieć neuronowa dobrze sprawdza się w odwzorowywaniu procesów, które cechują się jakąkolwiek logiką, bez konieczności znajomości praw rządzących tymi procesami.

LITERATURA

- [1] Abraham, A. and Nath, B.: A neuro-fuzzy approach for modelling electricity demand in Victoria. *Applied Soft Computing* 1, 2001, 127–138.
- [2] Adam, N. B., Elahee, M. and Dauhoo, M.: Forecasting of peak electricity demand in mauritius using the non-homogeneous gompertz diffusion process. *Energy* 36, 2011, 6763–6769.
- [3] Ameri, M., Kiaahmadi, F. and Khanaki, M. M.: Comparison of a dual-fuel internal combustion engine performance for CNG and gasoline fuels. *Journal of Power Technologies* 92(4), 2012, 214–240.
- [4] Amjady, N. and Keynia, F.: Short-term load forecasting of power systems by combination of wavelet transform and neuro-evolutionary algorithm. *Energy* 34, 2009, 46–57.
- [5] Azadeh, A., Ghaderi, S. and Sohrabkhani, S.: A simulated-based neural network algorithm for forecasting electrical energy consumption in Iran. *Energy Policy* 36, 2008, 2637–2644.
- [6] Azadeh, A., Ghaderi, S., Tarverdian, S. and Saberi, M.: Integration of artificial neural networks and genetic algorithm to predict electrical energy consumption. *Applied Mathematics and Computation* 186, 2007, 1731–1741.
- [7] Beccali, M., Cellura, M., Brano, V. L. and Marvuglia, A.: Forecasting daily urban electric load profiles using artificial neural networks. *Energy Conversion and Management* 45, 2004, 2879–2900.
- [8] Bini, R., Prima, M. D. and Guercio, A.: Organic Rankine cycle (ORC) in biomass plants: an overview on different applications. *Turboden SRL*, 2010.
- [9] Bozorgmehri, S. and Hamed, M.: Modeling and optimization of anode-supported solid oxide fuel cells on cell parameters via artificial neural network and genetic algorithm. *Fuel Cells* 12(1), 2012, 11–23.
- [10] Budzianowski, W.: Negative net CO₂ emissions from oxy-decarbonization of biogas to H₂. *International Journal of Chemical Reactor Engineering* 8, 2010, A156.
- [11] Cai, Y., Zhou Wang, J., Tang, Y. and Chen Yang, Y.: An efficient approach for electric load forecasting using distributed art (adaptive resonance theory) & hs-artmap (hyper-spherical artmap network) neural network, *Energy* 36, 2011, 1340–1350.
- [12] Chaichana, K., Patcharavorachot, Y., Chutichai, B., Saebea, D., Assabumrungrat, S. and Arpornwichanop, A.: Neural network hybrid model of a direct internal reforming solid oxide fuel cell, *International Journal of Hydrogen Energy* 37(3), 2012, 2498–2508.
- [13] Demuth, H., Beale, M. and Hagan, M.: *Neural network toolbox™ 6 user's guide matlab*. Technical report.
- [14] Foresee, F. and Hagan, M.: Gauss-newton approximation to bayesian regularization. *Proceedings of the 1997 International Joint Conference on Neural Networks*.
- [15] Hobbs, B. F., Helman, U., Jitrapaikularn, S., Konda, S. and Maratukulam, D.: Artificial neural networks for short-term energy forecasting: Accuracy and economic value. *Neurocomputing* 23, 1998, 71–84.

- [16] Hsu, C.-C. and Chen, C.-Y.: Regional load forecasting in Taiwan-applications of artificial neural networks, *Energy Conversion and Management* 44, 2003, 1941–1949.
- [17] Kavaklioglu, K., Ceylan, H., Ozturk, H. K. and Canyurt, O. E.: Modeling and prediction of turkey's electricity consumption using artificial neural networks. *Energy Conversion and Management* 50, 2009, 2719–2727.
- [18] Kiartzis, S., Bakirtzis, A. and Petridis, V.: Short-term load forecasting using neural networks. *Electric Power Systems Research* 33, 1995, 1–6.
- [19] Kishor, N. and Mohanty, S.: Fuzzy modeling of fuel cell based on mutual information between variables. *International Journal of Hydrogen Energy* 35(8), 2010, 3620–3631.
- [20] Kotowicz, J. and Bartela, T.: Optimisation of the connection of membrane ccs installation with a super-critical coal-fired power plant. *Energy* 38(1), 2012, 118–127.
- [21] Paarmann, L. D. and Najar, M. D.: Adaptive online load forecasting via time series modeling. *Electric Power Systems Research* 32, 1995, 219–225.
- [22] Sforna, M. and Proverbio, F.: A neural network operator oriented short-term and online load forecasting environment. *Electric Power Systems Research* 33, 1995, 139–149.
- [23] Sisworahardjo, N., Yalcinoz, T., El-Sharkh, M. and Alam, M.: Neural network model of 100 w portable pem fuel cell and experimental verification. *International Journal of Hydrogen Energy* 35(17), 2010, 9104–9109.
- [24] Tamimi, M. and Egbert, R.: Short term electric load forecasting via fuzzy neural collaboration. *Electric Power Systems Research* 56, 2000, 243–248.
- [25] Veyo, S. E., Lundberg, W. L., Vora, S. D. and Litzinger, K. P.: Tubular sofc hybrid power system status. *ASME Conference Proceedings* 2003(36851), 649–655.

THE USE OF ARTIFICIAL NEURAL NETWORKS TO PREDICT THE ELECTRICAL DEMAND

Key words: artificial neural networks, the demand for electricity, prediction

Summary. Proposed artificial neural network model is used to predict the demand for electric power. Appropriate architecture has been developed that network in terms of number of layers and number of neurons in each layer. Inputs to the model included: daily charge in 1 hour and day of the week, which is related to the load. However, the network received the outputs of the expected demand for electric power for the next day. The network was taught to load the data from the Institute of Thermal Technology and Warsaw University of Central Canteens of the time period from 08.10.2011 to 15.10.2011 and tested on data from a range of 10/16/2011 to 10/23/2011

Łukasz Szablowski, doktorant na Wydziale Mechanicznym Energetyki i Lotnictwa Politechniki Warszawskiej. Autor i współautor 9 publikacji z zakresu energetyki rozproszonej, wykorzystania sztucznych sieci neuronowych oraz magazynowania energii. Zajmuje się również instalacjami energetycznymi wykorzystującymi turbiny gazowe. E-mail: lukasz.szablowski@itc.pw.edu.pl.

Jarosław Milewski, doktor nauk technicznych, wykładowca na Wydziale Mechanicznym Energetyki i Lotnictwa Politechniki Warszawskiej. Autor i współautor ponad 90 publikacji i 2 patentów. Główne aspekty jego działalności naukowej to zagadnienia modelowania matematycznego urządzeń energetycznych zarówno tych klasycznych jak i uznawanych za przyszłościowe (np. ogniów paliwowych). E-mail: milewski@itc.pw.edu.pl.

Jerzy Kuta, doktor nauk technicznych, wykładowca na Wydziale Mechanicznym Energetyki i Lotnictwa Politechniki Warszawskiej. Autor i współautor ponad 10 publikacji, główne aspekty jego działalności naukowej to m.in. programowanie, układy sterowania i regulacji, modelowanie matematyczne oraz zagadnienia baz danych. E-mail: jerzy.kuta@itc.pw.edu.pl.