

Zastosowanie sieci neuronowych Kohonena do prognozowania obciążeń elektroenergetycznych

Streszczenie. Praca przedstawia analizę zastosowania różnych algorytmów uczących Kohonena w prognozowaniu profili obciążeń w małym systemie elektroenergetycznym w Polsce. W badaniach numerycznych, przeprowadzonych w środowisku programistycznym MATLAB, wzięły udział algorytmy WTA, CWTA, gaussowski WTM oraz algorytm gazu neuronowego WTM. Prognozowanie przeprowadzane zostało na podstawie uśrednionych wag neuronów zwyciężających w przeszłości dla danego typu dnia tygodnia.

Abstract. The paper shows the application of self-organizing methods in Kohonen network for prediction of the profiles of load in a small power system in Poland. Four learning methods were used: WTA, CWTA, Gaussian WTM and neural gas. The prediction of power consumption has been limited to the profile of load. The vector profile prognosis is equal to the average of vectors of the winning neurons in the appropriate days of the week and month. **The application of self-organizing methods in Kohonen network for prediction of the profiles of load in a small power system**

Słowa kluczowe: prognozowanie obciążeń, sieci neuronowe Kohonena, algorytmy uczące, uczenie samoorganizujące ze współzawodnictwem.

Keywords: electric load forecast, neural Kohonen network, learning algorithms, unsupervised learning.

Wstęp

Praca przedstawia zastosowanie sieci samoorganizujących, w szczególności sieci Kohonena, do prognozowania obciążeń w małym systemie elektroenergetycznym. Przeanalizowane zostały różne algorytmy samoorganizacji (WTA, CWTA, gaussowski WTM, algorytm gazu neuronowego WTM [5]) pod kątem ich zdolności do minimalizacji wartości oczekiwanej zniekształcenia, czyli błędu kwantyzacji. Algorytm uczący, przy użyciu którego uzyskuje się najniższy błąd kwantyzacji, został użyty do prognozowania rozkładu czasowego obciążeń elektroenergetycznych. Praca przedstawia i analizuje wyniki statystyczne prognozowania.

Dekompozycja obciążenia na składową stałą i zmienną

Obciążenie elektroenergetyczne każdej doby zawiera pewne statystyczne i regularnie powtarzające się prawidłowości tworzące wzorzec godzinny obciążenia elektroenergetycznego systemu, który podlega cyklicznym zmianom [1,3,7,9]. Aby wyeliminować wpływ tych zmian, specyficznych dla danego dnia roku, wyodrębniono część zmienną obciążenia dla każdej godziny analizowanego dnia, pozostającej po odjęciu średniego obciążenia badanej doby. W ten sposób powstaje tak zwany profil godzinny obciążenia zmiennego dla dnia j-tego, który wyraża się wzorem

$$(1) \quad p(j, h) = P_{rz}(j, h) - P_m(j)$$

gdzie: $h = 1, 2, \dots, 24$ – kolejne godziny doby; $p(j, h)$ – wektor obciążeń zmiennych (profilowych) dnia j-tego, $p_j = [p(j, 1), p(j, 2), \dots, p(j, 24)]$; $P_{rz}(j, h)$ – rzeczywisty pobór mocy w systemie elektroenergetycznym o godzinie h w dniu j-tym; $P_m(j)$ – obciążenie średnie systemu w dniu j-tym.

Profil ten będzie poddany prognozowaniu przy użyciu sieci Kohonena [5]. W badaniach eksperymentalnych użyto danych z małego systemu elektroenergetycznego obejmujących osiem lat: od 2000 do 2007 roku (łącznie 2922 dni). Zbiór ten podzielony został na podzbiór uczący oraz weryfikujący (zbiór testujący nie uczestniczący w uczeniu służący sprawdzeniu wytrenowanego systemu predykcji). W skład zbioru danych uczących wchodziło 6 lat z okresu 2000–2005 (czyli 2192 dni), natomiast w skład

zbioru danych testujących wchodzi 2 lata: 2006–2007 (czyli 730 dni).

Metody badawcze

Celem uczenia w sieciach samoorganizujących poprzez konkurencję jest minimalizacja błędu kwantyzacji, który wyraża się wzorem [5]

$$(2) \quad E_q = \frac{1}{p} \sum_{i=1}^p \|x_i - w_{w(i)}\|^2$$

gdzie: x_i – wektor wejściowy; p – liczba danych (wektorów wejściowych) podlegających samoorganizacji; $w_{w(i)}$ – waga neuronu zwyciężającego przy prezentacji wektora x_i .

Proces uczenia neuronów samoorganizujących dokonujących grupowania danych w przestrzeni wielowymiarowej może być definiowany na wiele sposobów. W pracy zastosowano adaptację wag neuronów w trybie on-line, w którym każdy neuron jest modyfikowany po pojedynczej k -tej prezentacji wzorca wejściowego x według odpowiedniego algorytmu. Zastosowano cztery odmiany algorytmów samoorganizacji poprzez konkurencję: algorytm WTA, CWTA, WTM gaussowski i gazu neuronowego.

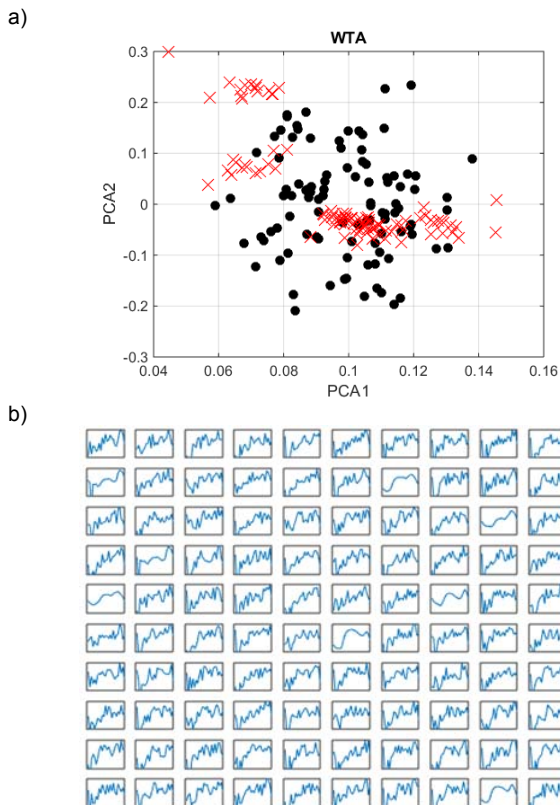
Algorytm WTA

Pierwszym algorytmem użytym w badaniach był zwykły algorytm WTA (Winner Takes All). Dąży się w nim do minimalizacji odległości wektora x od wektora wagowego neuronu zwycięskiego lub do maksymalizacji iloczynu skalarnego wektora uczącego x oraz wektora wag w : $x^T w \rightarrow \max$. W ten sposób wyłania się neuron zwycięzca. Zwycięski neuron adaptuje swoje wagi w kierunku wektora x według wzoru (3), w którym η oznacza współczynnik uczenia o wartości malejącej liniowo w kolejnych iteracjach. Pozostałe neurony nie adaptują swoich wag [6].

$$(3) \quad w_w \leftarrow w_w + \eta(x - w_w)$$

W toku badań symulacyjnych w środowisku MATLAB [5], wymiary macierzy neuronów ustalono na 10×10 (liczba neuronów równa 100). Użyto ciągłych zmian sąsiedztwa według funkcji gaussowskiej. Na rysunku 1 przedstawiono odwzorowanie danych przez sieć Kohonena z użyciem

algorytmu WTA. Rysunek 1a prezentuje wynik rzutowania PCA [5] na dwa najważniejsze składniki główne, a rys. 1b kolejne wartości 24-elementowych wektorów wagowych 100 neuronów Kohonena ukształtowane w wyniku procesu uczonego. Widoczne są znaczne różnice w lokalizacji wzorca wag (●) poszczególnych neuronów zwycięzców od położenia danych testujących (×). Wektor wagowy zwycięzców nie reprezentuje odpowiednio wiernie położenia wektora rzeczywistych obciążeń energetycznych. Na rys. 1b przedstawiono rozkład obciążeń profilowych przypisanych 100 neuronom sieci Kohonena dla algorytmu WTA. Zaobserwować można znaczną różnicę w kształcie obciążeń profilowych 24-godzinnych przypisanych 100 neuronom w porównaniu do typowego dobowego profilu obciążenia.



Rys.1. Odwzorowanie: a) dwuwymiarowe danych uczących przez algorytm WTA sieci Kohonena za pomocą przekształcenia PCA wraz z danymi testującymi, b) obciążenia profilowe przypisane 100 neuronom sieci

Przy 100 neuronach biorących udział w obliczeniach, uzyskano błąd kwantyzacji $E_q = 0,1343$.

Algorytm CWTA

Zastosowany algorytm uczący zwany jest w skrócie CWTA (Conscience Winner Takes All). Zgodnie z tym algorytmem, podobnie jak w WTA, tylko zwycięski neuron ma prawo adaptacji swoich wag. Dla uniknięcia przypadku, w którym pewne neurony nie mają żadnych szans wygrać z neuronami najsilniejszymi na skutek niefortunnej inicjalizacji losowej wag, wprowadzony został tzw. mechanizm sumienia (ang. conscience).

Podczas uczenia metodą CWTA wyznaczany jest w pierwszej kolejności neuron zwycięski. Neuron zwycięski to taki, którego wagi synaptyczne są najbardziej zbliżone do przyłożonego wektora danych wejściowych z uwzględnieniem liczby dotychczasowych zwycięstw, zgodnie ze wzorem [5]

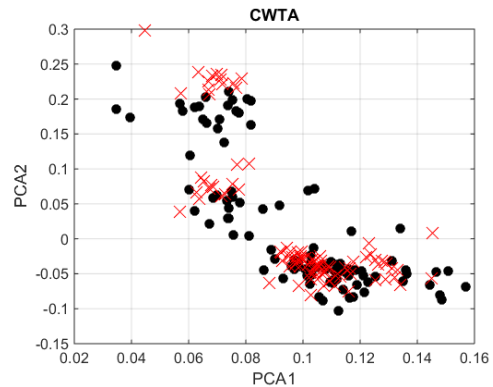
$$d(x, w_w) = \min_{\substack{1 \leq i \leq N \\ P_i \geq P_{\min}}} N_i \cdot d$$

(4)


gdzie: N_i – liczba zwycięstw i -tego neuronu; wartość startowa $N_i = 1$, $d = \|x - w_i\|$ – norma wektorowa określająca odległość wektora x od wag neuronu w_i .

Następnie modyfikowane są wagi neuronu zwycięskiego w_w w kierunku zadeklarowanego wektora wejściowego x .

a)



b)



Rys.2. Odwzorowanie: a) danych uczących przez algorytm CWTA sieci Kohonena za pomocą przekształcenia PCA wraz z danymi testującymi, b) obciążenia profilowe przypisane 100 neuronom sieci

Norma d może być normą Euklidesową lub definiowaną w postaci iloczynu skalarnego. Neuron zwycięski podlega w trakcie uczenia adaptacji wag według reguły Kohonena zgodnie ze wzorem (5). Pozostałe neurony przegrywające konkurencje pozostają przy swoich dotychczasowych wartościach wag.

$$(5) \quad w_i(k+1) = w_i(k) + \eta_i(k)[x - w_i(k)]$$

gdzie η oznacza współczynnik uczenia, malejący w trakcie kolejnych iteracji do zera.

Na rysunku 2a przedstawiono odwzorowanie dwuwymiarowe danych uczących stanowiących wektory wagowe neuronów sieci Kohonena (●) przy wykorzystaniu algorytmu uczącego CWTA przekształconych za pomocą PCA wraz z danymi testującymi (×). Zaobserwować można znaczną poprawę wierności odwzorowania lokalizacji danych testujących przez wektory wagowe zwycięzców (obszar danych wejściowych i wag neuronów zwycięskich jest znacznie bardziej spójny niż w przypadku algorytmu WTA).

Na rysunku 2b przedstawiono rozkład obciążeń profilowych przypisanych 100 neuronom sieci Kohonena dla algorytmu CWTA. W tym przypadku również widać

poprawę, gdyż kształt obciążeń przypisany neuronom jest zbliżony do typowego dobowego profilu obciążenia.

Przy 100 neuronach błąd kwantyzacji dla algorytmu CWTA wyniósł $E_q = 0,0603$. Względem algorytmu WTA jest to znaczący spadek wartości błędu o około 55%.

Algorytm gaussowski WTM

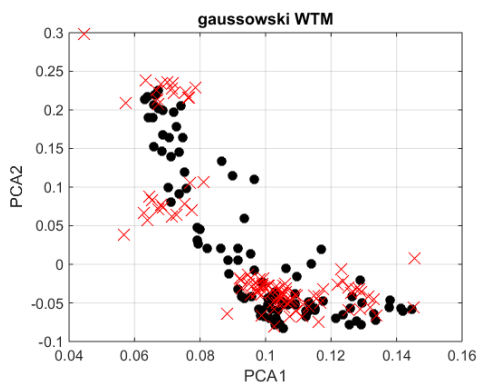
Kolejnym zbadanym algorytmem jest WTM (Winner Takes Most). Różni się on od poprzednich tym, że nie tylko zwycięski neuron ma prawo adaptować swoje wagi, ale również neurony z jego sąsiedztwa. Im większa odległość danego neuronu od zwycięzcy, tym mniejsza jest zmiana wartości wag tego neuronu. Adaptacja wag neuronów przebiega według wzoru Kohonena [5].

$$(6) \quad w_i \leftarrow w_i + \eta G(i, \mathbf{x}) [\mathbf{x} - w_i]$$

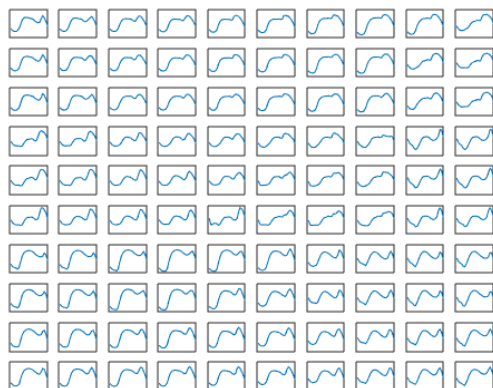
gdzie: i – neurony należące do sąsiedztwa zwycięzcy; η – współczynnik uczenia; $G(i, \mathbf{x})$ – funkcja gaussowska sąsiedztwa.

W szczególnym przypadku przyjmując funkcję sąsiedztwa w postaci $G(i, \mathbf{x}) = 1$ dla $i = \mathbf{w}$ oraz $G(i, \mathbf{x}) = 0$ dla $i \neq \mathbf{w}$ otrzymuje się klasyczny algorytm WTA.

a)



b)



Rys.3. Odwzorowanie: a) danych wejściowych przez algorytm gaussowski WTM sieci Kohonena za pomocą przekształcenia PCA, b) obciążenia profilowe przypisane 100 neuronom sieci

Na rysunku 3a przedstawiono odwzorowanie danych uczących uzyskane w wyniku uczenia wektorów wag (●) sieci Kohonena z wykorzystaniem algorytmu gaussowskiego WTM i funkcji sąsiedztwa gaussowskiego przekształconych za pomocą PCA (dane systemu elektroenergetycznego oznaczone symbolem ×). Zbieżność odwzorowania danych poprzez wektory wagowe neuronów jest gorsza niż w przypadku CWTA.

Rysunek 3b przedstawia porównawczo rozkład obciążeń profilowych przypisanych 100 neuronom sieci

Kohonena dla algorytmu gaussowskiego WTM. Przy 100 neuronach biorących udział w uczeniu błąd kwantyzacji wyniósł $E_q = 0,0790$. Jest to zatem wartość o ponad 31% większa niż ta, uzyskana metodą CWTA.

Algorytm gazu neuronowego WTM

Algorytm gazu neuronowego jest pewną odmianą algorytmu WTM. Wszystkie neurony podlegają sortowaniu w każdej iteracji w zależności od odległości neuronów od wektora \mathbf{x} . W kolejnym kroku neurony są sortowane w porządku narastających odległości zgodnie ze wzorem [5]

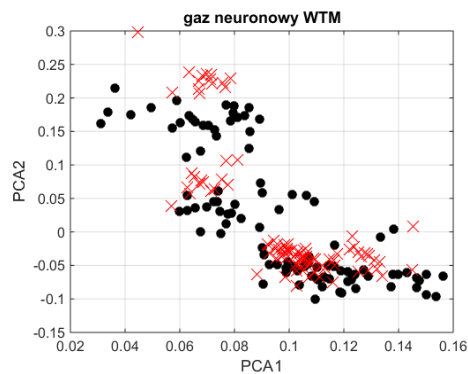
$$(7) \quad d_0 < d_1 < d_2 < \dots < d_{n-1}$$

W algorytmie tym funkcja sąsiedztwa $G(i, \mathbf{x})$ jest definiowana według wzoru


$$(8) \quad G(i, \mathbf{x}) = \exp\left(-\frac{m(i)}{\lambda}\right)$$

gdzie: $m(i)$ – kolejność neuronów posortowanych ($m(i) = 0, 1, 2, \dots, n-1$); λ – parametr malejący w funkcji czasu.

a)



b)



Rys.4. Odwzorowanie: a) danych uczących przez algorytm gazu neuronowego WTM sieci Kohonena za pomocą przekształcenia PCA, b) obciążenia profilowe przypisane 100 neuronom sieci

Jeśli $\lambda = 0$, wtedy adaptacji wag podlega wyłącznie neuron-zwycięzca, a więc otrzymujemy algorytm WTA. Jeżeli natomiast $\lambda \neq 0$, wtedy wagi wielu neuronów podlegają adaptacji, a jej intensywność zależy od aktualnej, zmieniającej się w czasie wartości funkcji sąsiedztwa $G(i, \mathbf{x})$.

Na rysunku 4a przedstawiono położenia wektorów wagowych (●) sieci Kohonena z wykorzystaniem metody gazu neuronowego WTM, przekształconych za pomocą PCA oraz danych uczących (×). Dokładność odwzorowania jest zbliżona do tej, uzyskanej za pomocą metody CWTA.

Na rysunku 4b przedstawiono rozkład obciążeń profilowych przypisanych 100 neuronom sieci Kohonena dla algorytmu gazu neuronowego WTM.

Uzyskano błąd kwantyzacji $E_q = 0,0610$. Jest to błąd tylko około 1,1% większy niż błąd kwantyzacji w metodzie CWTA.

Spośród czterech przebadanych algorytmów uczących, najmniejszy błąd kwantyzacji występuje w przypadku użycia w uczeniu algorytmu CWTA i wynosi 0,0603. Wyniki porównawcze błędów kwantyzacji odpowiadające różnym algorytmom uczącym przedstawiono w tabeli 1.

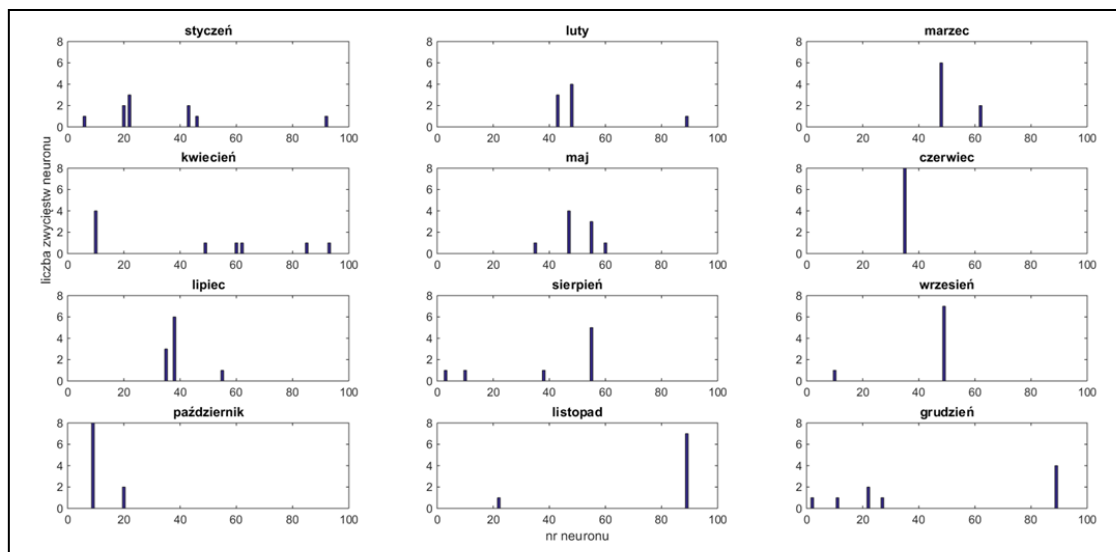
Tabela 1. Zestawienie błędów kwantyzacji dla różnych algorytmów uczących

Badany algorytm	Błąd kwantyzacji E_q
CWTA	0,0603
WTA	0,1343
gaussowski WTM	0,0790
gaz neuronowy WTM	0,0610

Najlepszym dopasowaniem obciążeń profilowych 100 neuronów odznacza się algorytm CWTA (rys. 2a,b),

Tabela 2. Zestawienie liczby zwycięstw neuronów dla poniedziałków w każdym miesiącu w ciągu dwóch lat

miesiąc	nr neuronu (liczba zwycięstw)					
styczeń	6 (1)	20 (2)	22 (3)	43 (2)	46 (1)	92 (1)
luty	43 (3)	48 (4)	89 (1)			
marzec	48 (6)	62 (2)				
kwiecień	10 (4)	49 (1)	60 (1)	62 (1)	85 (1)	93 (1)
maj	35 (1)	47 (4)	55 (3)	60 (1)		
czerwiec	35 (8)					
lipiec	35 (3)	38 (6)	55 (1)			
sierpień	3 (1)	10 (1)	38 (1)	55 (5)		
wrzesień	10 (1)	49 (7)				
październik	9 (8)	20 (2)				
listopad	22 (1)	89 (7)				
grudzień	2 (1)	11 (1)	22 (2)	27 (1)	89 (4)	



Rys.5. Rozkład zwycięstw neuronów dla poniedziałków przy prognozie obciążeń w kolejnych miesiącach w ciągu dwóch lat

Dla każdego miesiąca, w ciągu dwóch lat, wykonany został histogram zwycięstw neuronów. Istnieją pewne zależności charakterystyczne dla konkretnych pór roku, np. w miesiącach jesiennych (listopad i grudzień) często zwyciężał neuron nr 89 (11 zwycięstw dla dwóch miesięcy) oraz neuron nr 22 (3 zwycięstwa). Z kolei w miesiącach najcieplejszych (lipiec i sierpień) często zwyciężał neuron nr 38 (7 zwycięstw dla dwóch miesięcy) oraz neuron nr 55 (6 zwycięstw).

W tabeli 2 wyszczególniono przykładowo numery neuronów zwyciężających w poniedziałki każdego miesiąca z okresu dwóch lat oraz podano ich liczbę zwycięstw (wartość w nawiasie).

natomiast najmniejszą dokładność odwzorowania uzyskuje się stosując algorytm WTA (rys. 1a,b). Stąd algorytm CWTA zostanie użyty do badań prognostycznych w sieci elektroenergetycznej.

Prognozowanie obciążeń

Do badań użyto sieci Kohonena o następujących parametrach: algorytm uczący – CWTA, wymiary sieci: 10×10 , stała początkowa uczenia $\alpha = 0,5$ zmieniająca się liniowo do zera w kolejnych iteracjach, losowa inicjalizacja wartości wag sieci. Dla ustalenia przewidywanego obciążenia na określony dzień roku w pierwszej kolejności utworzona została tablica rozkładów zwycięstw poszczególnych neuronów sieci Kohonena dla danego dnia tygodnia. Na rysunku 5 przedstawiony został przykładowo rozkład zwycięstw neuronów dla poniedziałków z dwóch lat (2006–2007).


Aby określić przewidywany profil obciążenia energetycznego dla konkretnego dnia (np. poniedziałku) w określonym roku, należy przyjąć uśrednione wartości wag neuronów będących zwycięzcami, do których przynależał w przeszłości dany dzień tygodnia [3,6,9,10]. Prognozowany wektor profilowy dnia j -tego oblicza się według wzoru (9):

$$\hat{p}_j = \frac{\sum_{i=1}^n k_{ji} w_i}{\sum_{i=1}^n k_{ji}} \quad (9)$$

gdzie: i – numer neuronu; j – numer dnia podlegającego prognozowaniu; k_{ji} – liczba zwycięstw i -tego neuronu w dniu j -tym w badanym okresie czasu; w_i – wektor wag zwycięskiego neuronu w dniu j -tym z przeszłości.

Na rysunku 6 przedstawiono graficzne porównanie obciążenia dobowego z wartościami prognozowanymi w wybranym dniu (poniedziałek 23.01.2006 roku).

Linia przerywana odwzorowuje przebieg znormalizowanego obciążenia dobowego po dodaniu do wartości prognozowanej wartości średniej obciążenia w tym dniu (przyjęto wartość średnią poniedziałku z poprzedniego tygodnia), natomiast linia ciągła wartości rzeczywiste. Kształt obu linii pokrywa się znacząco dla poszczególnych godzin doby. Błąd MAPE wyniósł dla tego przypadku 2,01%. Największe rozbieżności pomiędzy obciążeniem a prognozą można zaobserwować dla godzin szczytu wieczornego od godz. 16 do godz. 20. Najlepsze dopasowanie obu charakterystyk występuje dla godzin porannych od godz. 5 do godz. 10 oraz dla godzin nocnych od godz. 21 do godz. 24.



Rys.6. Charakterystyka obciążenia dobowego dla wybranego dnia w roku (poniedziałek 23.01.2006 rok) wraz z prognozą

Tabela 3. Statystyka błędów testowych MAPE dla poszczególnych dni tygodnia na przestrzeni 2 lat

Dzień tygodnia	Liczba dni	MAPE±std [%]
Poniedziałek	105	4,94±0,06
Wtorek	104	2,38±0,02
Środa	104	2,21±0,02
Czwartek	104	1,84±0,01
Piątek	104	4,26±0,03
Sobota	104	3,29±0,02
Niedziela	105	5,18±0,04
Średnio	-	3,44±0,03

W tabeli 3 przedstawiono wyniki statystyczne błędu MAPE obciążeń dobowych dla wszystkich dni tygodnia uzyskane tą metodą dla dwu lat biorących udział w testowaniu. Średni błąd prognozy dla wszystkich dni tygodnia w testowanym okresie 2 lat wyniósł 3,44%.

Wnioski

W pracy przebadane zostały algorytmy uczące sieci samoorganizacyjnej poprzez konkurencję neuronów w zastosowaniach prognostycznych profilu obciążenia elektroenergetycznego. W pierwszej kolejności porównano jakość czterech algorytmów samoorganizacji pod względem błędu kwantyzacji w odwzorowaniu obciążeń 24-godzinnych w małym systemie elektroenergetycznym. Najmniejszym błędem kwantyzacji odznaczała się metoda CWTA, zaś największy błąd kwantyzacji występuje przy użyciu metody WTA. Bardzo zbliżona wartość błędu kwantyzacji względem

algorytmu CWTA występuje dla metody gazu neuronowego WTM.

Do potrzeb prognozowania profili obciążeń użyty został najlepszy algorytm CWTA. Właściwa prognoza obciążeń oparta została o analizę liczby zwycięstw poszczególnych neuronów w przeszłości dla określonego dnia tygodnia i miesiąca. Liczba zwycięstw neuronu i -tego przekłada się bezpośrednio na uzyskany wektor profilowy, będący efektem prognozy. Wyniki numeryczne eksperymentów zostały zaprezentowane w postaci błędu MAPE dla poszczególnych dni tygodnia z okresu 2 lat poddanych testowaniu. Błąd średni MAPE obciążeń w najgorszym przypadku (niedziela, dane testujące z 2 ostatnich lat) osiągnął wartość 5,18%. Najlepszy wynik statystyczny uzyskano dla czwartku, dla którego błąd MAPE wyniósł 1,84%. Średni wynik prognozy liczony dla wszystkich dni tygodnia wyniósł 3,44%.

Zaletą metody jest łatwa możliwość jej przystosowania do prognozowania średnioterminowego (z wyprzedzeniem licznym w tygodniach i miesiącach) lub nawet długoterminowego (z wyprzedzeniem licznym w latach). Wynika to z faktu, że prognoza profilu jest niezależna od wyprzedzenia i może być przeprowadzona z dowolnym wyprzedzeniem. O dokładności prognozy decydować będzie wówczas prognoza wartości średnich obciążeń dziennych, które z roku na rok mogą podlegać istotnym zmianom.

Autorzy: mgr inż. Tomasz Ciechulski, Wojskowa Akademia Techniczna, Instytut Systemów Elektronicznych, Zakład Systemów Informacyjno-Pomiarowych, ul. Kaliskiego 2, 00-908 Warszawa, E-mail: tomasz.ciechulski@wat.edu.pl;
prof. dr hab. inż. Stanisław Osowski, Politechnika Warszawska, Instytut Elektrotechniki Teoretycznej i Systemów Informacyjno-Pomiarowych, ul. Koszykowa 75, 00-661 Warszawa oraz Wojskowa Akademia Techniczna, Instytut Systemów Elektronicznych, Zakład Systemów Informacyjno-Pomiarowych, ul. Kaliskiego 2, 00-908 Warszawa E-mail: sto@iem.pw.edu.pl.

LITERATURA

- [1] T. Ciechulski, S. Osowski S, *Badanie jakości predykcji obciążeń elektroenergetycznych za pomocą sieci neuronowych SVM, RBF i MLP*, Przegląd Elektrotechniczny 2014, nr 8, pp. 148-151.
- [2] P. Demartines, F. Blayo, *Kohonen self-organizing maps: is the normalization necessary?*, Complex Systems 6 (1992), pp. 105-123.
- [3] A. Lendasse, M. Cottrell, V. Wertz, M. Verleysen, *Prediction of electric load using Kohonen maps – application to the Polish Electricity Consumption*, Proceedings of the American Control Conference, Anchorage, 2002, pp. 3684-3689.
- [4] MathWorks, *Matlab manual user's guide*, Mathworks, Natick, 2014.
- [5] S. Osowski, *Sieci neuronowe do przetwarzania informacji*, OWPW, Warszawa 2006.
- [6] S. Osowski, K. Siwek, *The self-organizing neural network approach to load forecasting in the power system*, 1999. IJCNN '99 Conference, Washington, pp. 3401-3404.
- [7] A. Sorjamaa, J. Hao, N. Reyhani, Y. Li, A. Lendasse, *Methodology for long-term prediction of time series*, Neurocomputing, vol. 70, 2007, pp. 2861-2869.
- [8] T. Ciechulski, S. Osowski, *Ocena wpływu wyodrębnienia składowej stałej na jakość prognozy obciążeń elektroenergetycznych*, Przegląd Elektrotechniczny, R. 91, Nr 10/2015, pp. 197-200.
- [9] G. Simon, A. Lendasse, M. Cottrell, M. Verleysen, *Long-term time series forecasting using self-organizing maps: the double vector quantization method*, Proc. ANNPR'2003-Artificial Neural Networks in Pattern Recognition, 2003, pp. 8-14
- [10] M. Martin-Merino, J. Roman, *Electricity load forecasting using self organizing maps*, Proc. ICANN, 2006, pp. 709-716.