

Tomasz JEŻYK*
Andrzej TOMCZEWSKI*

KRÓTKOTERMINOWE PROGNOZOWANIE ZUŻYCIA ENERGII ELEKTRYCZNEJ Z WYKORZYSTANIEM SZTUCZNEJ SIECI NEURONOWEJ

W artykule przedstawiono zagadnienie wykorzystania sztucznej sieci neuronowej do rozwiązania zadania krótkoterminowego prognozowania zużycia energii elektrycznej. Bazując na archiwalnych danych pomiarowych mocy chwilowych odbiornika (centrum handlowe) sieć neuronową typu NAR poddano procesowi nauki, a następnie wykorzystano do wyznaczenia krótkoterminowej prognozy poboru energii elektrycznej. Model zaproponowanej sieci opracowano w środowisku MATLAB. Do oceny jakości uzyskanych prognoz zaproponowano użycie błędów: procentowego względnego błędu prognozy oraz błędu procentowego MAPE (ang. Mean Average Percent Error). Zamieszczono wyniki przykładowych obliczeń oraz porównanie z danymi pomiarowymi.

SŁOWA KLUCZOWE: sieci neuronowe, prognoza krótkoterminowa, środowisko MATLAB

1. WPROWADZENIE

Wzrost zapotrzebowania na energię elektryczną jest ściśle powiązany z rozwojem technicznym społeczeństw i przemysłu oraz coraz większą liczbą urządzeń elektrycznych w gospodarstwach domowych (odbiorników). Bez modernizacji systemu energetycznego oraz dokładnej analizy dobowych i rocznych obciążeń systemu istnieje zagrożenie czasowymi przerwami w dostawie energii. Prognozowanie (predykcja) zużycia energii elektrycznej jest próbą odpowiedzi na pytanie jak będzie kształtował się pobór energii w przyszłości. Oprócz funkcji informacyjnej proces prognozowania zmniejsza zagrożenia związane z ewentualnym deficytem energii elektrycznej. Wyniki analiz pobudzają często do działań decydujących o kształcie systemu energetycznego, wspomagają plany wyłączeń i zarządzanie produkcją w zakładach przemysłowych, a także indywidualnych odbiorców.

Zagadnienie prognozowania zużycia energii elektrycznej jest jednym z problemów z zakresu elektroenergetyki, jaki można rozwiązać z wykorzystaniem sieci neuronowych. Metoda należy do szerokiej grupy metod sztucznej inteligencji, a w związku z rozwojem komputerów jest coraz popularniejsza w rozwiązaniu zagadnień technicznych.

* Politechnika Poznańska.

Prognozowanie polega na ustaleniu zależności opisującej zachowanie zmiennej prognozowanej opisującej rozwój pewnego zdarzenia w przyszłości. Pełnoprawna weryfikacja predykcji może nastąpić dopiero po osiągnięciu pewnego punktu w przyszłości, będącego granicą dokonanej prognozy. Badania zatem nad nowymi modelami sieci neuronowej ewentualnie nowymi metodami w wymienionym obszarze powinny być prowadzone w kierunku poprawy jakości prognoz, wydłużenia długości prognoz oraz poprawy szybkości uzyskiwania wyników.

2. PROGNOZOWANIE Z WYKORZYSTANIEM SZTUCZNEJ SIECI NEURONOWEJ

2.1. Prognozowanie krótkoterminowe

Mianem prognozy określa się sąd informujący „o zajściu pewnego zjawiska, w określonym momencie w przyszłości, taki, że jego wartość logiczna (prawda lub fałsz) nie jest znana w momencie formułowania (prognozy)” [3]. Posiada on następujące cechy:

- podczas jego formułowania wykorzystuje się dorobek nauki,
- dotyczy ściśle określonej przyszłości,
- jest empirycznie weryfikowalny,
- jest niepewny, ale akceptowalny.

Podstawowym podziałem prognoz jest rozróżnienie na prognozy ilościowe (dotyczące wartości mierzalnych) i jakościowe (dotyczące zmiennych niemierzalnych). Podział prognoz na krótko-, średnio- i długookresowe nie jest zdefiniowany poprzez arbitralnie ustalone kryteria. Najczęściej określenie rodzaju kategorii odbywa się z użyciem pojęcia zasięgu ekstrapolacji (horyzontu prognozy). Jest to liczba jednostek czasu (godzin, dni, miesiące, itd.), z którą prognoza wybiega w przyszłość. Kolejnym rozróżnieniem rodzaju prognozy jest określenie zależności między długością horyzontu prognozy a ilością informacji, od której zależy proces prognozowania. Przykładowo, jeśli prognoza dotyczy kilku jednostek czasu, to w przypadku dużej liczby danych wejściowych można określić ją jako krótkoterminową [5]. Kolejnym kryterium stosowanym przy podziale prognoz jest występowanie zmian ilościowych i jakościowych w okresie ekstrapolacji. Jako zmianę ilościową określa się zmianę wartości zmiennej prognozowanej podlegającą pewnej prawidłowości. Zmianą jakościową jest natomiast odejście od dotychczasowej prawidłowości, wynikająca ze zmiany istotnych cech prognozowanego zjawiska. Gdy w horyzoncie prognozy wyróżnia się jedynie zmiany ilościowe, to prognoza jest krótkookresowa. Prognoza jest wyznaczana poprzez ekstrapolację dotychczasowych trendów lub związków oraz przy wykorzystaniu inercji zmiennej [1].

Zadanie krótkoterminowej prognozy poboru energii elektrycznej charakteryzuje się brakiem zmian jakościowych w horyzoncie prognozy

(relatywnie krótkim w stosunku do okresu jaki wykorzystano do opracowania prognozy) oraz wykorzystaniem inercji zmiennej prognozowanej w celu ekstrapolacji wykrytego trendu.

2.2. Sztuczne sieci neuronowe i obszary ich zastosowań w elektroenergetyce

Podstawową częścią sieci neuronowej jest neuron, element o wielu wejściach i jednym wyjściu reagujący na bodźce zgodnie z przyjętym wektorem wag synaptycznych. Strukturę powstałą w wyniku połączenia kilku sztucznych neuronów nazywa się sztuczną siecią neuronową. Najmniej złożona jest sieć jednowarstwowa, w której sygnały wejściowe są zazwyczaj doprowadzane do wszystkich neuronów. W sieciach wielowarstwowych neurony warstwy poprzedniej przekazują sygnały do warstwy następnej, a jakiegokolwiek połączenia między neuronami tej samej warstwy są niedozwolone. Warstwa wejściowa to warstwa, do której dostarczane są sygnały wejściowe, zaś z warstwy wyjściowej wyprowadzane są sygnały wyjściowe. Struktury znajdujące się między nimi to warstwy ukryte.

Sieci jednokierunkowe to sieci jedno- i wielowarstwowe, w których można wyróżnić tylko jeden kierunek rozplywu informacji. Sieci neuronowe o połączeniach powrotnych z wyjść neuronów to sieci rekurencyjne. Moc obliczeniowa takiej sieci jest porównywalna do mocy obliczeniowej maszyny Turinga [2].

Sztuczne sieci neuronowe mogą w czasie rzeczywistym przetwarzać informacje w sposób równoległy wzorowany na procesach neurologicznych mających miejsce w ludzkim mózgu. Rozwiązania tradycyjne w zakresie programowania nie są w stanie odwzorować takiego procesu. Przeszkodą w szerokim stosowaniu sztucznych sieci neuronowych w zagadnieniach techniki, w tym elektroenergetyki był, przez wiele lat, brak wystarczającego zaplecza sprzętowego zapewniającego równoległe przetwarzanie informacji w czasie rzeczywistym. Możliwości wykorzystania sieci neuronowych ogranicza w wielu przypadkach, również niewystarczająca liczba danych pomiarowych sieci elektroenergetycznych, zwłaszcza średniego i niskiego napięcia [4]. Obecnie dzięki możliwości wykorzystania procesorów wielordzeniowych, a szczególnie jednostek graficznych (np. technologia CUDA), znacznie rozszerzono potencjał stosowania obliczeń z zastosowaniem sieci neuronowych pracujących w czasie rzeczywistym.

Zastosowania sieci neuronowych obejmują obecnie: diagnostykę układów elektronicznych, prognozowanie (np. sprzedaży, giełdowe, cen, postępów w nauce), optymalizację, sterowanie procesami produkcyjnymi, planowanie remontów maszyn, monitorowanie i diagnostykę pracy systemów elektroenergetycznych, detekcję i identyfikację uszkodzeń i wiele innych [4].

Prognozowanie wartości mocy, energii, obciążenia itp. jest kluczowe dla planowania eksploatacji, rozwoju i modernizacji systemu elektroenergetycznego. Sztuczne sieci neuronowe dzięki dobrej jakościowo predykcji i swobodzie w doborze czynników decydujących o prognozie są przydatne szczególnie w

przypadku prognoz krótkoterminowych. Posiadają zdolność do wykrycia powiązania między danymi wejściowymi i wyjściowymi bez znanej zależności między nimi. Istotne jest także, że sztuczne sieci neuronowe dzięki zdolności do generalizacji mogą pracować z niedokładnymi, a nawet niekompletnymi danymi.

3. DOBÓR SIECI NEURONOWEJ DO ZADANIA PROGNOZOWANIA ENERGII ELEKTRYCZNEJ

3.1. Wybór struktury sztucznej sieci neuronowej

Proces poprawnego doboru sieci neuronowej do postawionego zadania wymaga określenia charakteru prognozowanej zmiennej oraz stosunku między zasięgiem ekstrapolacji a ilością informacji, na których oparto proces prognozowania. Informacje te ułatwiają wybór typu sieci neuronowej, liczby neuronów w warstwie ukrytej, algorytmu nauki sieci neuronowej, momentu jej zakończenia w zależności od wielkości błędu estymacji oraz sposobu wyliczania tego błędu.

Środowisko MATLAB jest wyposażone w narzędzie Neural Network Toolbox ułatwiające tworzenie i korzystanie ze sztucznych sieci neuronowych. Na podstawie analizy realizowanego zagadnienia dokonano wyboru nieliniowej autoregresyjnej sieci neuronowej NAR (ang. Nonlinear Autoregressive Neural Network). Prognoza sprowadza się do określenia składowej systematycznej szeregu czasowego, jakim jest wielkość poboru energii elektrycznej. Sieć NAR jest w stanie rozpoznawać jedynie zmiany ilościowe (jedna zmienna prognozowana w oparciu o jej wartości poprzednie), niewykonalne jest więc, z jej użyciem, prognozowanie długookresowe.

Struktura wykorzystanej sztucznej sieci neuronowej jest zaprojektowana na maksymalnie 5 neuronów w warstwie ukrytej (liczba neuronów jest uzależniona od długości horyzontu prognozy oraz stopnia skomplikowania trendu opisującego pobór energii elektrycznej). Wybór niewielkiej liczby neuronów wynika z dążenia do uzyskania możliwie ogólnej aproksymacji trendu szeregu czasowego. Pozwala to ograniczyć ryzyko wystąpienia błędów związanych z tzw. „nauką na pamięć”, a prognozowany przebieg poboru energii elektrycznej jest zbliżony do rzeczywistego w określonym horyzoncie czasowym.

Według przeprowadzonych badań testowych odpowiednią metodą treningu sieci neuronowej NAR jest algorytm Lavenberga-Marquardta. Jest to algorytm iteracyjny często wykorzystywany jako metoda optymalizacji nieliniowej. Łączy w sobie cechy metody najszybszego spadku i Gaussa-Newtona [5]. O wyborze algorytmu jako metody treningu sieci zdecydował fakt, że w zadaniach typowych jest to najszybszy algorytm nauki jednokierunkowej sieci neuronowej (od 10 do 100 razy szybszy niż w przypadku zastosowania metody gradientów).

Stosowanie algorytmu Lavenberga-Marquardta podlega trzem zasadniczym ograniczeniom:

- jego stosowanie nie jest możliwe w procesie nauki sieci o liczbie neuronów w warstwie wyjściowej większej niż jeden (sieć NAR wykorzystywana do rozwiązania realizowanego zadania posiada tylko jeden neuron wyjściowy odpowiadający za prognozę zużycia energii elektrycznej);
- funkcja błędu musi być wyrażona w postaci sumy kwadratów odchyłeń. Algorytm znajduje więc zastosowanie w zagadnieniach regresyjnych. Pobór energii elektrycznej jest szeregiem czasowym, może być więc zdekomponowany z użyciem regresji liniowej w celu dokonania jego dalszej estymacji - jest to więc zagadnienie regresyjne;
- rozległe sieci wymuszają wykorzystanie dużych nakładów pamięciowych (proporcjonalnych do kwadratu liczby parametrów), co znacząco wydłuża proces nauki. Sieć zastosowana w aplikacji do prognozowania poboru energii elektrycznej jest przewidziana na maksymalnie 5 neuronów w warstwie ukrytej. Jest to więc struktura stosunkowo nierozbudowana [5].

W obszarze realizowanego zadania żadne z wymienionych ograniczeń nie zostało naruszone. Wybrana struktura sieci NAR spełnia przyjęte założenia.

Zakończenie procesu nauki sieci neuronowej następuje, gdy na wyjściu sieci neuronowej pojawia się sygnał równy (z dokładnością do niewielkiego ustalonego błędu) oczekiwanemu sygnałowi. W MATLAB dla sieci jednokierunkowej za wymieniony błąd przyjmuje się najczęściej błąd średniokwadratowy MSE (ang. Mean Square Error).

3.2. Badanie parametrów sieci neuronowej

W celu osiągnięcia jak najlepszej jakości predykcji otrzymanej z wykorzystaniem sztucznej sieci neuronowej należy określić jej parametry. Parametrami pomocnymi w ocenie przydatności otrzymanej prognozy są różnego rodzaju błędy. Pierwszym z nich jest procentowy względny błąd prognozy (całkowity procentowy błąd prognozy), określony wzorem:

$$PWBP = \left(\sum_{i=1}^n \frac{|y_i - y_p|}{y_i} \right) \cdot 100\% \quad (1)$$

gdzie: y_p jest wartością przewidywaną dla kolejnej jednostki czasowej w horyzoncie prognozy, y_i wartością rzeczywistego obciążenia odpowiadającą próbie y_p , n liczbą jednostek czasu w horyzoncie czasowym prognozy.

Drugim typem błędu służącym do oceny jakości prognozy jest błąd procentowy MAPE (ang. Mean Absolute Percent Error). Informuje on o poprawności odwzorowania kształtu przebiegu prognozowanego i wyrażany jest wzorem [4]:

$$MAPE = \frac{1}{n} \left(\sum_{i=1}^n \frac{|y_i - y_p|}{y_i} \right) \cdot 100\% \quad (2)$$

gdzie: y_p to wartość przewidywana dla kolejnej jednostki czasowej w horyzoncie prognozy, y_i to rzeczywista wartość odpowiadająca próbce y_p , n jest natomiast liczbą próbek w zasięgu ekstrapolacji.

W celu określenia optymalnych parametrów sieci porównano wielkości zdefiniowanych powyżej błędów - zależności (1) i (2) - dla różnych parametrów sieci NAR. W tabeli 1 przedstawiono wyniki wymienionych badań dla trzech różnych horyzontów prognozy: 24 h, 7 dni i 30 dni oraz od jednego do pięciu neuronów w warstwie ukrytej.

Tabela 1. Wyniki badań parametrów sieci neuronowej NAR (kolorem jasnoszarym oznaczono maksymalne wartości poszczególnych błędów dla różnych horyzontów czasowych prognoz, ciemnoszarym zaś ich minimalne wartości)

		Liczba neuronów									
		1		2		3		4		5	
Długość prognozy	Wartości	Całkowity Proc. Błąd Prognozy	MAPE	Całkowity Proc. Błąd Prognozy	MAPE	Całkowity Proc. Błąd Prognozy	MAPE	Całkowity Proc. Błąd Prognozy	MAPE	Całkowity Proc. Błąd Prognozy	MAPE
24h	Min	0,144	6,874	0,040	5,402	0,243	4,569	0,407	6,336	0,201	5,08877
	Max	7,275	23,306	2,882	14,934	7,003	16,180	8,895	18,671	10,558	15,145
	Średnia	1,390	9,739	1,178	8,032	2,129	8,546	2,148	9,604	2,579	8,332
7 dni	Min	-	-	0,436	8,352	9,427	1,795	0,402	8,488	0,256	9,368
	Max	-	-	13,128	14,311	18,137	17,062	23,823	23,777	22,860	22,457
	Średnia	-	-	5,210	10,814	12,283	7,096	8,115	13,388	8,735	14,574
30 dni (w oparciu o codzienne pobory energii elektrycznej)	Min	-	-	1,561	10,941	2,625	11,160	0,068	10,862	1,101	12,990
	Max	-	-	127,263	136,081	22,219	23,486	24,031	30,526	27,064	29,927
	Średnia	-	-	16,329	23,213	9,242	15,594	9,158	16,924	13,472	19,881
30dni (w oparciu o dzienny pobór energii lektrycznej)	Min	-	-	0,560	4,381	1,803	5,197	1,132	4,078	0,072	4,440
	Max	-	-	12,057	12,870	22,596	29,053	12,735	13,620	22,103	22,843
	Średnia	-	-	5,818	7,895	7,627	9,556	5,910	7,943	5,200	7,857


Na podstawie uzyskanych wyników, do realizacji zadania prognozowania zużycia energii elektrycznej, wybrano sieć o 2 neuronach w warstwie ukrytej. Wynika to z faktu, że dla tej liczby neuronów w warstwie ukrytej wartości maksymalne całkowitego procentowego błędu prognozy i błędu procentowego MAPE były najniższe dla każdego horyzontu czasowego prognozy. Średnie wartości tych błędów dla tej liczby neuronów nie odbiegały znacząco od najmniejszej osiągniętej wartości dla innych liczb neuronów, co dodatkowo zdecydowało o wyborze właśnie dwóch neuronów w warstwie ukrytej sztucznej sieci neuronowej.

4. ANALIZA KRÓTKOTERMINOWYCH PROGNOZ ZUŻYCIA ENERGII ELEKTRYCZNEJ

Z zastosowaniem wybranej struktury sieci neuronowej (NAR), liczby neuronów w warstwie ukrytej (dwa), metody uczenia sieci (Lavenberga-Marquardta) oraz dokonaniu selekcji i przebadaniu wpływu parametrów na jakość predykcji wykonano badania w zakresie prognoz poboru energii elektrycznej dla rozdzielni centrum handlowo-usługowego.

Ustalono interesujący, w realizowanym zadaniu, zasięg ekstrapolacji o długości: doby, tygodnia i 30 dni. Dane archiwalne, które wykorzystano do predykcji pochodzą odpowiednio z 14, 90 i 366 dni bezpośrednio poprzedzających rozpatrywany okres prognozy.

Ze względu na wybór prostej struktury sieci neuronowej nakłady obliczeniowe konieczne do przeprowadzenia prognozy są niewielkie. Wykonanie prognozy dla więcej niż jednej jednostki czasu w przyjętym horyzoncie czasowym wymaga jednak, po zakończeniu procesu nauki sieci neuronowej, utworzenia połączenia powrotnego z neuronu warstwy wyjściowej do neuronów warstwy ukrytej. Na rysunku 1 przedstawiono schemat sieci neuronowej do prognozowania dobowego zużycia energii elektrycznej. Model opracowano z zastosowaniem Toolbox Neural Network środowiska MATLAB i wzbogacono o własne elementy (interfejs graficzny, import i eksport danych do pliku arkusza kalkulacyjnego, automatyczne generowanie wykresów danych archiwalnych i otrzymanych prognoz) opracowane w języku wewnętrznym środowiska.



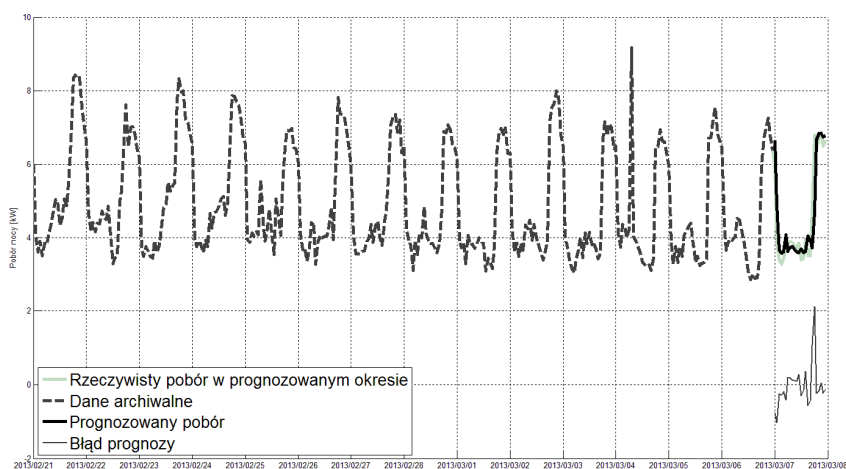
Rys.1. Schemat sieci NAR przystosowanej do prognozowania wartości poboru energii elektrycznej dla wszystkich jednostek czasowych w dobowym horyzoncie prognozy

Zrealizowane przykłady obliczeniowe obejmują trzy przypadki.

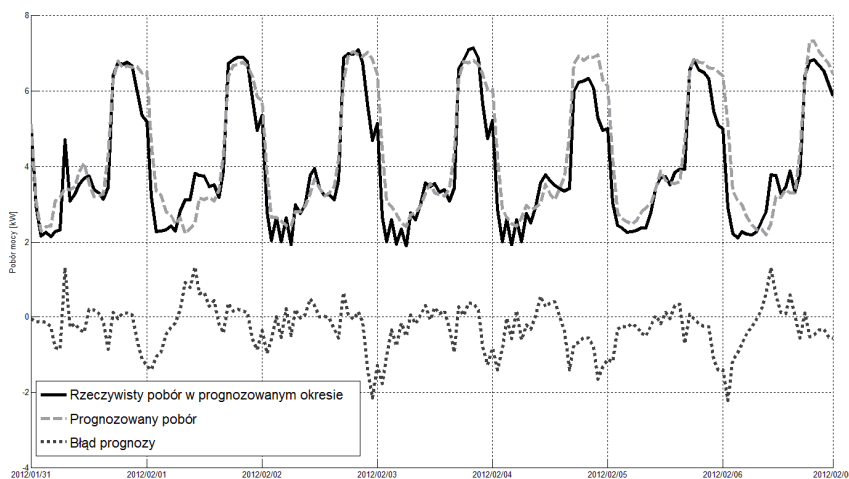
Pierwszy dotyczy prognozy dobowej przeprowadzonej dla dnia 07.03.2013. Całkowity prognozowany pobór energii w ustalonym okresie wyniósł 113,3 kWh, natomiast w rzeczywistości przyjmuje on wartość 108,5 kWh. Błąd prognozy wyniósł zatem 4,8 kWh, procentowy względny błąd prognozy 4.4%, natomiast

błąd procentowy MAPE 8.9%. Na rysunku 2 przedstawiono wyniki prognozy dobowej dla opisanego powyżej przykładu.

Drugi przykład prognozy dotyczy okresu ekstrapolacji wynoszącego 7 dni (okres od 31.01.2012 do 6.02.2012). Rzeczywisty pobór energii w prognozowanym okresie wyniósł 677,9 kWh, podczas gdy wartość wyliczona (prognozowana) 705.8 kWh. Bezwzględny całkowity błąd prognozy wyniósł w tym wypadku 27,9 kWh, co daje procentowy względny błąd prognozy 4,1%, oraz MAPE 11,8%. Szczegółowe wyniki przeprowadzonych analiz zamieszczono na rysunku 3.

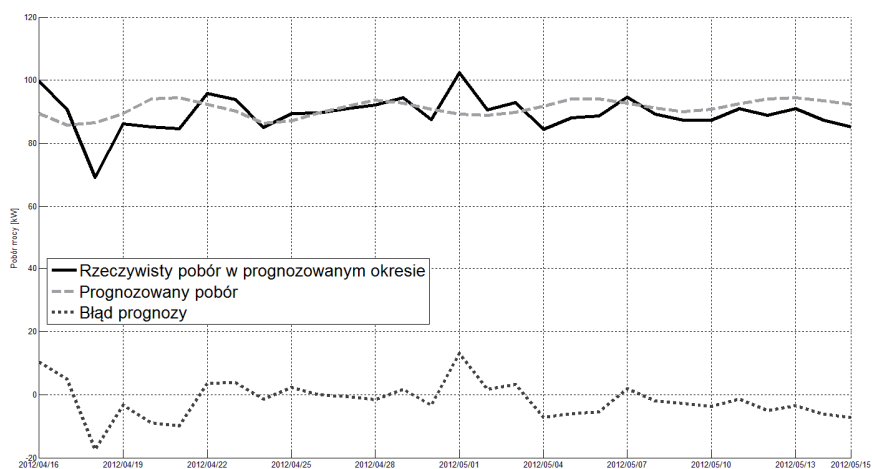


Rys. 2. Rzeczywisty oraz prognozowany przebieg poboru energii elektrycznej w przyjętym okresie prognozowania - jeden dzień (07.03.2013), błąd prognozy oraz dane archiwalne - przykład 1



Rys. 3. Rzeczywisty oraz prognozowany przebieg poboru energii elektrycznej w prognozowanym okresie (31.01.2012 do 6.02.2012) 7 dni wraz z błędem prognozy - przykład 2

W przykładzie trzecim horyzont prognozy ustalono na 30 dni (okres od 16.04.2012 do 15.05.2012). Rzeczywisty całkowity pobór energii w prognozowanym okresie wyniósł 2682,6 kWh, natomiast wartość wyliczona (prognozowana) 2819,6 kWh. Bezwzględny całkowity błąd prognozy to 137,0 kWh, procentowy względny błąd prognozy 5,1%, zaś błąd procentowy MAPE 6.8%. Szczegółowe wyniki predykcji dla analizowanego przykładu przedstawiono na rysunku 4.



Rys. 4. Rzeczywisty oraz prognozowany przebieg poboru energii elektrycznej w okresie 30 dni (od 16.04.2012 do 15.05.2012) wraz z błędem prognozy - przykład 3

5. PODSUMOWANIE

Środowisko MATLAB umożliwia tworzenie różnych typu modeli sztucznych sieci neuronowych, których struktury umożliwiają wykorzystanie do zagadnienia prognozowania zużycie energii elektrycznej. Dodatkowo istnieje możliwość rozbudowy i modyfikacji struktur standardowych z zastosowaniem programowania w języku wewnętrznym środowiska. Daje to znaczną przewagę co do szybkości tworzenia aplikacji w porównaniu ze stosowaniem klasycznych środowisk programistycznych.

Badania przeprowadzone w celu określenia optymalnej liczby neuronów w warstwie ukrytej sieci typu NAR wykazały, że im mniej złożona sieć, tym mniejsze błędy prognozy. Sieć o niewielkiej liczbie neuronów w warstwie ukrytej tworzy ogólny i uśredniony obraz przebiegu zmiennej prognozowanej. Rozbudowane sieci skupiają się na jak najdokładniejszym odwzorowaniu przebiegu tej zmiennej. Każde odstępstwo od dokładnej i sztywno wyznaczonej prognozy wprowadza więc błąd i znacząco obniża jej jakość. Wykorzystany w procesie nauki algorytm Lavenberga-Marquardta, w zakresie prowadzonych badań, spełnił swoje zadanie i w efektywny sposób umożliwił szybkie zakończenie procesu nauki sztucznej sieci neuronowej.

Prognoza uzyskana z wykorzystaniem zastosowanego modelu sieci ma charakter prognoz ilościowych. Zmiany jakościowe (awaria rozdzielni, urządzeń podłączonych do niej, jak również podłączenie nowych urządzeń) nie mogą zostać przewidziane, a ich wpływ na jakość prognozy jest uzależniony od miejsca wystąpienia (w ciągu danych) i trwałości tych zmian. Jeżeli zmiana jakościowa zachodzi na końcu tego okresu prognozowania, to jej wpływ na jakość prognozy nie może być pominięty, a prognoza otrzymana na podstawie takich danych archiwalnych jest więc praktycznie bezużyteczna dla zastosowań inżynierskich.

Przeprowadzone na potrzeby referatu badania świadczą o przydatności sieci neuronowych w dziedzinie prognozowania szeregów czasowych, w których nie zachodzą znaczące zmiany jakościowe np. pobór energii elektrycznej. Cechą wyróżniającą tak otrzymaną prognozę jest jej brak jej powtarzalności spowodowany losowością procesu nauki sztucznej sieci neuronowej. Powstałe w ten sposób różnice między prognozami są jednak na tyle niewielkie, że w zakresie rozwiązań inżynierskich spełniają całkowicie stawiane wymagania.

Dla zamieszczonych w referacie przykładów prognozy o horyzoncie czasowym prognozy równym odpowiednio 1 dzień, 7 dni i 30 dni uzyskano zadowalające rezultaty, procentowe względne błędy prognozy całkowitego poboru energii wyniosły co najwyżej 5,1%, zaś błędy procentowe MAPE 11,8%.

LITERATURA

- [1] Cieślak M., Prognozowanie gospodarcze. Metody i zastosowania, Wydawnictwo Naukowe PWN, Warszawa, 2002.
- [2] Flasiński M., Wstęp do sztucznej inteligencji, Wydawnictwo Naukowe PWN, Warszawa, 2011.
- [3] Guzik B., Appenzeller D., Jurek W., Prognozowanie i symulacje. Wybrane zagadnienia, Wydawnictwo Akademii Ekonomicznej w Poznaniu, Poznań, 2005.
- [4] Helt P., Parol M., Piotrowski P., Metody sztucznej inteligencji w elektroenergetyce, Oficyna Wydawnicza Politechniki Warszawskiej, Warszawa, 2000.
- [5] Krzyśko M., Wołyński W., Górecki T., Skorzybut M., Systemy uczące się, Wydawnictwo Naukowo-Techniczne, Warszawa, 2008.

SHORT TERM FORECASTING OF ELECTRICITY CONSUMPTION BY USING AN ARTIFICIAL NEURAL NETWORK

The article presents the problem of the use of artificial neural network to solve the task of short term forecasting of electricity consumption. Based on archival data of instantaneous power measurement of load (shopping center), the neural network of NAR type was learned and then used to determine short term forecast of electricity consumption. Proposed network model was developed in MATLAB environment. To evaluate the quality of the forecasts, the error usage was proposed: percentage of forecast error and the relative percentage error MAPE (Mean Average Percent called Error). The results of sample calculations and comparison with measurement data was presented.