

doi:10.15199/48.2017.01.74

Ultrakrótkoterminowe prognozy 15-minutowych wartości zapotrzebowania na energię elektryczną dla odbiorców nn z wykorzystaniem wybranych modeli statystycznych oraz sztucznych sieci neuronowych

Streszczenie. W artykule przedstawiono zagadnienia związane z wykonywaniem ultrakrótkoterminowych prognoz 15-minutowych wartości zapotrzebowania na energię elektryczną odbiorców nn. Dokonano analizy statystycznej danych i dobrano zmienne do modeli. Wykonano przykładowe prognozy i sformułowano wnioski końcowe.

Abstract. This paper presents issues related to very short-term 15-minute load forecasts of low voltage consumers. Statistical analysis of data have been made and input variables for prediction models have been chosen. Examples of predictions have been executed and final conclusions have been presented. (*Very short-term 15-minute load forecasts of low voltage consumers using chosen statistical models and artificial neural networks*).

Słowa kluczowe: prognozy ultrakrótkoterminowe, zapotrzebowanie na energię elektryczną, sztuczne sieci neuronowe

Keywords: very short-term forecasting, electric energy demand, statistical forecasting methods, artificial neural networks

Wstęp

Instrumenty pomiarowe używane przez elektroenergetyków pozwalają na stwierdzenie, jakie jest bieżące zapotrzebowanie na energię elektryczną. W dobie generacji rozproszonej wiedza ta jest niewystarczająca. W celu optymalnego zbilansowania energii w systemie oprócz wartości planowanej generacji energii przez źródła odnawialne potrzebna jest również informacja nt. planowanego zapotrzebowania na energię przez odbiorców w najbliższych kilkunastu minutach.

Tego typu prognozy ultrakrótkoterminowe mogą być wykonywane przy użyciu różnych metod prognostycznych zależnie od liczby i typu dostępnych danych historycznych. Do najczęściej stosowanych metod zaliczyć należy: modele AR, ARIMA, SARIMA, ARMAX, model Holta, model Wintersa i model Kalmana oraz sztuczne sieci neuronowe [1]. Tematyka ultrakrótkoterminowych prognoz zapotrzebowania na energię elektryczną została przedstawiona m. in. w [2-10]. Prognozy ultrakrótkoterminowe (wyprzedzenie 5-15 minut) wykonuje się również do predykcji generacji energii elektrycznej przez odnawialne źródła energii. np. farmy wiatrowe, elektrownie słoneczne, wodne oraz biogazownie [1].

Wartości poboru energii elektrycznej pojedynczego odbiorcy nn są bardzo zróżnicowane w poszczególnych okresach doby. Na skokowe zmiany zapotrzebowania na energię odbiorcy domowego wpływają głównie czasowo załączane odbiorniki o dużym poborze energii np.: kuchenki elektryczne, suszarki, pralki, odkurzacze, czajniki elektryczne, płyty indukcyjne, itp. Ponadto, pory dnia, częstotliwość i czas załączeń urządzeń AGD i RTV zależą również od pory roku, typu dnia, temperatury powietrza oraz opadów. Składnik losowy szeregu czasowego zapotrzebowania na energię jest więc znaczący u odbiorcy domowego.

Biorąc pod uwagę grupę odbiorców jako całość widać pewne prawidłowości, które Operatorzy Sieci Dystrybucyjnych udostępniają do wiadomości publicznej w postaci standardowych profili zużycia energii. Profile takie zawierają Instrukcje Ruchu i Eksploatacji Sieci Dystrybucyjnej każdego OSD w Polsce.

Profile zużycia wyznaczone są dla różnych grup odbiorców ze względu na wybraną taryfę oraz są różnicowane w zależności od dnia tygodnia oraz pory roku (miesiąca). Profile podawane są w jednostkach względnych w postaci tabel dla kolejnych godzin doby. Oprócz taryfy

jednostrefowej spółki dystrybucyjnej oferują taryfę dwustrefową G12, w której określają przedziały czasowe w ciągu doby, w których cena energii jest niższa (zwykle 13:00-15:00 oraz 22:00-6:00), a w których wyższa (pozostałe godziny doby).

Z punktu widzenia systemu elektroenergetycznego taryfy wielostrefowe są jednym z programów reakcji strony popytowej (ang. Demand Side Response). Dostarczają one bodźców do ograniczenia zużycia energii w szczytach obciążenia i korzystania w okresach doliny obciążenia, gdy ceny są niższe.

W artykule dokonano analizy statystycznej danych w celu wstępnego wyboru właściwych zmiennych objaśniających oraz przedstawiono przykładowe prognozy 15-minutowych wartości zapotrzebowania na energię elektryczną pojedynczego odbiorcy nn taryfy G12.

Analiza statystyczna danych

Analizie poddane zostały 15-minutowe wartości zapotrzebowania na energię elektryczną jednego odbiorcy taryfy G12 z okresu od 1 czerwca 2013 do 5 października 2013. Do prognoz "ex post" użyto danych z 10 dni (26 września 2013 – 5 października 2013) dla odbiorcy zasilanego przez jedną z krajowych spółek dystrybucyjnych. Taryfa G12 umożliwia w tym przypadku rozliczanie ze stawką pozaszczytową od godziny 22:00 do 6:00 oraz od godziny 13:00 do 15:00. Stawka szczytowa obowiązuje w pozostałych 14 godzinach doby.

Podstawowe statystyki szeregu czasowego zapotrzebowania na energię elektryczną odbiorcy z grupy taryfowej G12 zawarto w tabeli 1. Testy Shapiro-Wilka oraz Kołmogorowa-Smirnowa wykazały, że szereg czasowy nie ma rozkładu normalnego. Kurtoza (miara spłaszczenia rozkładu szeregu czasowego, dla rozkładu normalnego wynosi 0) ma małą wartość ujemną co oznacza, że wartości szeregu czasowego są nieco mniej skoncentrowane niż przy rozkładzie normalnym. Współczynnik skośności (przyjmujący wartość zero dla rozkładu symetrycznego) jest dodatni czyli występuje rozkład o prawostronnej asymetrii (występuje więcej wartości szeregu czasowego większych niż wartość średnia). Duża wartość współczynnika zmienności (40,27%) sugeruje potencjalne trudności w uzyskaniu wysokiej jakości prognoz.

Obliczono współczynniki korelacji liniowej Pearsona pomiędzy zmienną objaśnianą oraz potencjalnymi

zmiennymi objaśniającymi. Wyniki przedstawiono w tabeli 2. Weryfikacja istotności współczynników korelacji z tabeli 2, wykazała we wszystkich przypadkach ich istotność z $p < 0,01$ (1% poziom istotności).

Tabela 1. Podstawowe statystyki szeregu czasowego zapotrzebowania na energię elektryczną odbiorcy z grupy tariffowej G12

Miara statystyczna	
Średnia [Wh]	3986,39
Mediana [Wh]	3600
Odchylenie standardowe [Wh]	1605,22
Wariancja	2576717
Kurtoza	-0,13
Skośność	0,73
Rozstęp [Wh]	7800
Wartość minimalna [Wh]	1500
Wartość maksymalna [Wh]	9300
Współczynnik zmienności [%]	40,27

Tabela 2. Współczynniki korelacji pomiędzy 15-minutowymi wartościami zapotrzebowania na energię elektryczną z innymi danymi potencjalnie wartościami z punktu widzenia prognozowania

Potencjalna zmienna objaśniająca	Współczynnik korelacji
$E(t-15, d)$	0,943
$E(t-30, d)$	0,905
$E(t-45, d)$	0,876
$E(t-60, d)$	0,850
$E(t-75, d)$	0,813
$E(t-90, d)$	0,770
$E(t-105, d)$	0,729
$E(t, (d-1))$	0,814
$E(t, (d-2))$	0,775
$E(t, (d-3))$	0,732
$E(t, (d-1)_{\text{typ dnia}})$	0,799
$E(t, (d-2)_{\text{typ dnia}})$	0,789
$E(t, (d-3)_{\text{typ dnia}})$	0,768
średnia ($E(t, (d-1)_{\text{typ dnia}})$, $E(t, (d-2)_{\text{typ dnia}})$, $E(t, (d-3)_{\text{typ dnia}})$)	0,822
$E_{\text{wzgl. profil}}(t, d)$	0,676
średnia ($E(t-15, d)$, $E(t-30, d)$)	0,937
średnia ($E(t-15, d)$, $E(t-30, d)$, $E(t-45, d)$)	0,930
średnia ($E(t-15, d)$, $E(t-30, d)$, $E(t-45, d)$, $E(t-60, d)$)	0,922

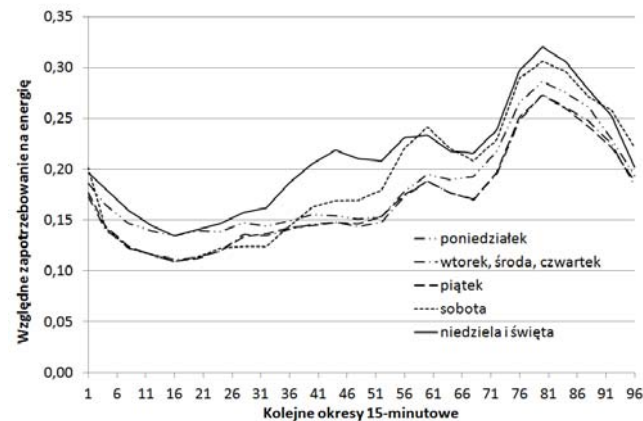
gdzie: $E(t, d)$ – zapotrzebowanie na energię elektryczną w 15-minutowym okresie czasu t w dniu d , $t - 15$ – 15-minutowy okres prognozy, $(t-15)$ – okres 15 minut wcześniejszy niż t d – dzień prognozy, $(d-1)$ – dzień poprzedni w stosunku do dnia prognozy, $(d-1)_{\text{typ dnia}}$ – poprzedni dzień z tej samej kategorii dni, co dzień d , $E_{\text{wzgl. profil}}(t, d)$ – względna wartość zapotrzebowania na energię elektryczną w okresie 15-minutowym dla danego typu dnia i miesiąca na podstawie dobowych profili udostępnionych przez spółkę dystrybucyjną dla okresu czasu t i dnia d

Przebieg zmienności zapotrzebowania na energię elektryczną badanego odbiorcy wykazuje silną okresowość i duże zróżnicowanie w zależności od dnia tygodnia. Wszystkie szeregi czasowe mają wyraźnie zarysowany szczyt wieczorny oraz dolinę nocną. W spółce dystrybucyjnej, która zasila odbiorcę profile dobowe podzielone są na 5 następujących grup: 1 – poniedziałek, 2 - wtorek, środa, czwartek, 3 – piątek, 4 – sobota, 5 – niedziela oraz dni świąteczne.


Wartości względne zapotrzebowania na energię z profili dobowych dla kolejnych godzin zaproksymowano do wartości 15-minutowych. Na rysunku 1 przedstawiono przygotowane w ten sposób profile dla października.

Analizując dane z tabeli 2 oraz rysunek 2 przedstawiający wykres autokorelacji szeregu czasowego

15-minutowych wartości zapotrzebowania na energię w okresie do 7 dni wstecz, można zauważyć znaczące korelacje zużycia energii z pięcioma poprzednimi wartościami 15-minutowego zapotrzebowania (ponad 0,8). Silną korelację wykazują również wartości średnie dwóch, trzech oraz czterech ostatnich pomiarów. Ponadto, na wykresie autokorelacji widoczne są duże wartości korelacji z wartościami zapotrzebowania na energię sprzed wielokrotności 24 godzin. Znaczącą korelację wykazuje również średnia 15-minutowych wartości zapotrzebowania na energię sprzed 3 ostatnich dób. Dość znaczący współczynnik korelacji występuje również z wartością zużycia odczytaną z profilu dobowego stosowanego w spółce dystrybucyjnej.



Rys. 1. Aproxymowane do wartości 15-minutowych profile dobowe zużycia energii elektrycznej dla października dla odbiorcy taryfy G12



Rys. 2. Wykres autokorelacji szeregu czasowego 15-minutowych wartości zapotrzebowania na energię elektryczną w okresie do 7 dni wstecz

Na rysunku 3 przedstawiono zapotrzebowanie na energię elektryczną z zakresu danych prognostycznych (10 dni) oraz profil dobowy. Poza pierwszymi dwoma dniami (piątek i sobota) oba przebiegi mają zbliżony kształt.

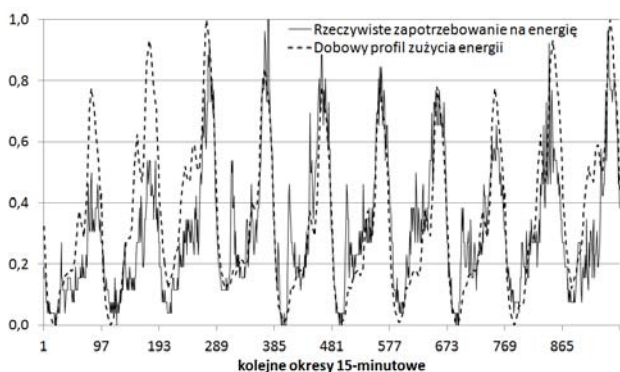
Porównanie wyników prognoz

Prognozy przeprowadzono za pomocą następujących metod: metoda naiwna, metoda średniej ruchomej prostej, metoda średniej ruchomej ważonej, regresja wieloraka, sztuczna sieć neuronowa typu perceptron wielowarstwowy oraz metoda "stat_fusion".

Prognozy metodą naiwną stanowią punkt wyjścia do porównania skuteczności pozostałych, bardziej złożonych modeli prognostycznych. Badania tą metodą przeprowadzono w trzech wariantach, przyjmując jako prognozę:

- wariant 1 - wartość w okresie prognozowanym t jest równa wartości z okresu poprzedniego $t-15 \text{ min}$,
- wariant 2 - wartość w okresie prognozowanym t w dniu d jest równa wartości z okresu t dnia poprzedniego $d-1$,
- wariant 3 - wartość w okresie prognozowanym t w dniu d jest równa wartości z okresu t poprzedniego dnia tego samego typu $(d-1)_{\text{typ dnia}}$.

Najlepsze rezultaty uzyskano dla wariantu pierwszego (błąd MAPE 10,48%), w którym błąd MAPE i błąd maksymalny były około dwukrotnie mniejsze niż w 3 najgorszym wariantach (błąd MAPE 22,15%).



Rys. 3. Wykres porównawczy znormalizowanych wartości 15-minutowych rzeczywistego zapotrzebowania na energię elektryczną badanego odbiorcy taryfy G12 oraz profili dobowych dostarczonych przez operatora sieci dystrybucyjnej


Prognozy wykonane metodą średniej ruchomej prostej oraz średnią ruchomą ważoną wykonano przyjmując jako wartość prognozowaną średnią wartość 2, 3, lub 4 ostatnich wartości zużycia energii. W przypadku średniej ruchomej ważonej, właściwe wagi zostały dobrane metodą optymalizacyjną Newtona-Raphsona (minimalizacji podlegał błąd MAPE). Wartości współczynników korelacji wskazały, że jedyną istotną wartością zapotrzebowania na energię jest wartość sprzed 15 minut (0,9999). Wartość sprzed 30 minut uzyskała wagę 0,0001, a pozostałe wagę 0, co sprawia, że metoda średniej ważonej daje rezultaty niemal identyczne jak metoda naiwna w wariancie 1.

Prognozy metodą regresji wielorakiej wykonano w programie ekonometrycznym GRETL. Jako zmienne objaśniające przyjęto wartości zużycia energii z 7 15-minutowych okresów wstecz oraz wartość 15-minutową z dnia poprzedniego oraz dnia poprzedniego tego samego typu. Jako zmienną objaśniającą przyjęto również estymowany do wartości 15-minutowych dobowy profil zapotrzebowania na energię elektryczną. Zbadano wpływ poszczególnych zmiennych objaśniających na jakość prognoz. Stwierdzono, że brak którejkolwiek ze zmiennych objaśniających powodował wzrost błędu MAPE. Przykładowo usunięcie wartości 15-minutowej zapotrzebowania na energię z dnia poprzedniego oraz dnia poprzedniego tego samego typu co dzień prognozy spowodowało wzrost błędu MAPE o 10,4% w stosunku do wariantu najlepszego.


Prognozy zapotrzebowania na energię wykonano przy użyciu sieci neuronowej typu MLP, wykorzystując algorytm uczenia - propagacja wsteczna błędów. Doborowi podlegała liczba neuronów w warstwie ukrytej oraz liczba epok treningowych. Dane wejściowe zawierały wartości zapotrzebowania na energię z 7 ostatnich okresów 15-minutowych, estymowany do wartości 15-minutowych dobowy profil zużycia energii dostarczony przez operatora sieci dystrybucyjnej, zapotrzebowanie na energię w badanym okresie czasu w poprzedniej dobie oraz w poprzedniej dobie tego samego typu. Trening sieci neuronowej przebiegał z użyciem automatycznego doboru współczynnika uczenia oraz współczynnikiem momentu o wartości 0,9. Nie wykorzystywano techniki tasowania faktów treningowych. Badania rozpoczęto od sieci z jedną warstwą ukrytą z 3 neuronami (przybliżenie pierwiastka z iloczynu danych wejściowych i wyjściowych (odpowiednio 10 i 1)) i stopniowo zwiększano ich liczbę. Testowano sigmoidalną

oraz liniową funkcję aktywacji w warstwie ukrytej oraz warstwie wyjściowej sieci neuronowej. Testom podlegały również sieci z 2 warstwami ukrytymi (dodanie drugiej warstwy ukrytej zwiększało błąd MAPE prognoz o około 30-40%).

Najlepszą jakość prognoz uzyskano dla sieci neuronowej z jedną warstwą ukrytą składającą się z 8 neuronów i sigmoidalnych funkcji aktywacji w warstwie ukrytej oraz warstwie wyjściowej. Zmiana funkcji aktywacji neuronów w warstwie ukrytej oraz wyjściowej na liniową funkcję aktywacji powodowała znaczący wzrost błędu MAPE. Przykładową prognozę wykonaną siecią neuronową dla jednej doby przedstawiono na rysunku 4.



Rys. 4. Prognoza wykonana siecią neuronową dla środę 1 października



Rys. 5. Prognoza wykonana „zespołem 2 metod” dla środę 1 października

Wykorzystana w prognozach metoda „stat_fusion” bazuje na kilku istotnych elementach mających najczęściej wysoką korelację z prognozą zużycia energii i stanowi połączenie metody autoregresji oraz metody ekonometrycznej [1]. Do modułu prostego ekonometrycznego wchodzi następujące czynniki objaśniające: względna wartość zużycia energii elektrycznej w okresie t , wynikająca z dobowego profilu obciążeń, średnia wartość zużycia energii w okresie t , obliczona dla 3 ostatnich dni tego samego typu co dzień prognozy oraz średnia wartość zużycia energii w okresie $t-1$, obliczona dla 3 ostatnich dni tego samego typu co dzień prognozy. Człon autoregresyjny wykorzystywał 4 ostatnie wartości zużycia energii sprzed okresu prognozy. Właściwe parametry wszystkich modeli były ustalane z wykorzystaniem optymalizacji metodą Newtona oraz metodą DEPS (ang. Differential Evolution and Particle Swarm Optimization), która wykorzystuje dwa niezależne algorytmy optymalizacyjne. Optymalizacja metodą DEPS była minimalnie korzystniejsza (błąd MAPE prognoz „ex post” oraz błąd maksymalny obniżyły się nieznacznie).

Do metody „zespół 2 metod” wybrano 2 metody z najmniejszymi wartościami błędów MAPE w zakresie estymacji parametrów modeli. Prognoza końcowa stanowiła sumę prognoz najlepszego modelu regresji wielorakiej oraz prognoz siecią neuronową typu MLP, z wagami ustalonymi w wyniku optymalizacji (wartości wag odpowiednio 0,63 oraz 0,37). Do doboru właściwych wag wykorzystano

algorytm optymalizacyjny Newtona, w którym minimalizacji podlegał błąd MAPE obliczany dla prognoz z wagami z zakresu estymacji. Próba wykorzystania jako trzeciej metody „stat_fusion” była nieudana – waga przypisywana do metody w wyniku optymalizacji była niemal równa zero i wynosiła 0,001. Przykładową prognozę dla jednej doby wykonaną zespołem 2 metod przedstawiono na rysunku 5.

W tabeli 3 przedstawiono wybrane wyniki prognoz „ex post” uzyskane każdą z badanych metod.

Tabela 3. Zestawienie wyników prognoz „ex post” dla różnych metod prognostycznych

Metoda prognostyczna	Błąd średni MAPE [%]	Współ. korelacji	Błąd maksymalny [%]
Zespół 2 metod (regresja wieloraka i sieć neuronowa)	9,91	0,952	46,20
Regresja wieloraka; zmienne objaśniające: $E(t-15, d) - E(t-105, d)$, $E(t, (d-1))$, $E(t, (d-1))_{\text{typ dnia}}$, $E_{\text{wzgl.profil}}(t, d)$	10,04	0,953	50,96
Sieć neuronowa typu MLP (architektura warstw: wejście(10) - ukryta (8) - wyjście(1))	10,30	0,948	51,17
Metoda „stat_fusion”, (funkcja celu – błąd MAPE), właściwe parametry: $\beta_0=2,72$, $\phi_1=1,76$, $\phi_2=0,88$, $\phi_3=0,03$, $\phi_4=-0,01$, $\alpha_1=-1,24$, $\alpha_2=-1,67$	10,45	0,947	58,62
Metoda średniej ruchomej ważonej, $k=4$ z optymalizacją wartości wag (funkcja celu – błąd MAPE); wagi: $w_1=0,9999$, $w_2=0,0001$, $w_3=0$, $w_4=0$	10,48	0,946	60,00
Metoda naiwna, wariant 1, $E(t,d) = E(t-15,d)$	10,48	0,946	60,00
Metoda średniej ruchomej prostej, $k=2$	10,87	0,940	66,67
Metoda naiwna, wariant 3, $E(t,d) = E(t,d-1)_{\text{typ dnia}}$	22,15	0,722	142,9

Podsumowanie i wnioski końcowe

Metoda „zespół 2 metod” uzyskała błąd MAPE o 1,29% mniejszy niż najlepsza pojedyncza metoda – regresja wieloraka. Z uwagi na wykorzystywanie 2 różnych metod uzyskuje się uśrednienie prognoz – spodziewać można się większej stabilności prognoz przy porównywaniu wyników prognoz na wielu szeregach czasowych. Różnica pomiędzy „zespołem 2 metod” oraz metodą regresji wielorakiej jest na tyle mała (1,3% na korzyść „zespołu 2 metod”), że trudno wskazać jednoznacznie jedną metodę preferowaną. Warto jednak zwrócić uwagę na fakt, że „zespół 2 metod” uzyskał o prawie 10% mniejszy błąd maksymalny niż metoda regresji wielorakiej.

Z pojedynczych metod najmniejszy błąd MAPE uzyskała metoda regresji wielorakiej (lepsza o 2,06% od sieci neuronowej typu MLP oraz o 3,93% od metody „stat_fusion”). Wśród zmiennych objaśniających największe znaczenie miała wartość zapotrzebowania na energię z okresu $t-15$ minut.

Prognozowany okres czas był dość zróżnicowany pod względem dynamiki zużycia energii. Nie we wszystkich dniach występował wyraźny szczyt poranny, wieczorny oraz typowy dla taryfy G12 - popołudniowy.

Uzyskany dla najlepszej metody błąd MAPE wynoszący niecałe 10%, jest na tyle nieduży, że tego typu krótkoterminowa prognoza może być przydatna do

procesów sterowania pracą systemu, szczególnie w sieciach smart grid. Warto jednak podkreślić, że uzyskane wyniki dla najlepszej metody (pomimo wykorzystania w nich dodatkowych zmiennych objaśniających) są niewiele lepsze (niecałe 5,5%) niż metoda naiwna stanowiąca metodę odniesienia. Problem prognoz ultrakrótkoterminowych dla pojedynczych odbiorców energii elektrycznej jest więc trudny i należy nadal poszukiwać metod pozwalających jeszcze bardziej zmniejszyć błąd MAPE w stosunku do metody naiwnej. Dane wykorzystane w badaniach obejmowały okres tylko nieco ponad 4 miesiące (tylko takie dane były dostępne). Zapewne wykorzystanie szeregu czasowego z okresu 2-3 lat pozwoliłoby na uzyskanie nieco mniejszych błędów MAPE. W najbliższej przyszłości (kilka najbliższych lat) masowy montaż cyfrowych liczników energii elektrycznej na terenie Polski może umożliwić szersze analizy danych i dokładniejsze prognozy dzięki dostępowi do obszerniejszych baz danych odczytanych z liczników cyfrowych.

Autorzy: mgr inż. Andrzej Grzyb, Politechnika Warszawska, Instytut Elektroenergetyki, ul. Koszykowa 75, 00-662 Warszawa, E-mail: andrzej.grzyb@ien.pw.edu.pl;
dr hab. inż. Paweł Piotrowski, Politechnika Warszawska, Instytut Elektroenergetyki, ul. Koszykowa 75, 00-662 Warszawa, E-mail: pawel.piotrowski@ien.pw.edu.pl

LITERATURA

- [1] Piotrowski P., Prognozowanie w elektroenergetyce w różnych horyzontach czasowych. *Oficyna wydawnicza Politechniki Warszawskiej*, Warszawa 2013
- [2] Dobrzańska I., Dąsal K., Łyp J., Poptawski T., Sowiński J., Prognozowanie w elektroenergetyce. Zagadnienia wybrane. *Wydawnictwo Politechniki Częstochowskiej*, Częstochowa 2002
- [3] Parol M., Piotrowski P. Very Short-term Forecasting for Optimum Control in Microgrids. *Pendrive Proceedings of the Second Int. Youth Conf. on Energetics*, June 4-6 2009, Budapest, Page(s): 5
- [4] Parol M., Piotrowski P., Prognozy zapotrzebowania na energię elektryczną o horyzoncie 15 minut na potrzeby sterowania w sieciach niskich napięć ze źródłami generacji rozproszonych, *Przegląd Elektrotechniczny*, 86 (2010), nr 12, 303-309
- [5] Shamsollahi P., Cheung K. W., Quan Chen, Germain E. H.: A neural network based very short term load forecaster for the interim ISO New England electricity market system”. *Proc. 2001 Power Industry Computer Applications Conf.*, May, 2001, Sydney, Australia, 217 – 222
- [6] Chen H., Huang K., Chang L., Application of Neural Networks for Very Short-Term Load Forecasting in Power Systems w: *Advances in Neural Networks – ISNN 2005, Second International Symposium on Neural Networks*, Chongqing, China, May 30 - June 1, 2005, Proceedings, Part III
- [7] Yu-Hsiang Hsiao, Very-Short-Term Load Forecast for Individual Household Based on Behavior Pattern Induction, *Advanced Materials Research Vol. 918 (2014)*
- [8] De Andrade L. C. M., Oleskovicz M., Santos A.Q., Coury D.V., Very Short-Term Load Forecasting Based on NARX Recurrent Neural Networks, *PES General Meeting | Conference & Exposition, 2014 IEEE*
- [9] Quilumba F.L., Lee W.J., Huang H., Wang D.Y., Szabados R.L., Using Smart Meter Data to Improve the Accuracy of Intraday Load Forecasting Considering Customer Behavior Similarities, *IEEE Transactions on Smart Grid (Volume:6, Issue: 2)*
- [10] Loewenstern Y., Katzir L., Shmilovitz D., The effect of system characteristics on very-short-term load forecasting, *XII International School on Nonsinusoidal Currents and Compensation, ISNCC 2015, Łagów, Poland*