

Wiktorія GRYPAN
Zbigniew WRÓBLEWSKI

OCENA MODELOWANIA DYNAMICZNEGO JAKO NARZĘDZIA DO PROGNOZOWANIA ZUŻYCIA ENERGII ELEKTRYCZNEJ PRZEZ ODBIORCÓW INDYWIDUALNYCH

STRESZCZENIE *Prognozowanie zużycia energii elektrycznej jest narzędziem niezbędnym dla nowoczesnego zarządzania energią elektryczną. Umiejętność właściwego przewidywania przyszłych zachowań stanowi podstawę efektywnego zarządzania. Ze względu na dużą zmienność zużycia energii w czasie i brak możliwości jej długotrwałego magazynowania, szczególnie istotnym zagadnieniem jest wybór właściwych narzędzi prognostycznych, możliwie dokładnie określających zużycie energii w rozpatrywanym czasie. W artykule opisano modelowanie dynamiczne i przedstawiono wyniki prognostyczne dla modeli dynamicznych, opracowanych dla grupy odbiorców indywidualnych. Wyniki oceniono na podstawie danych o rzeczywistym zużyciu energii elektrycznej w tym okresie.*

Słowa kluczowe: modelowanie obciążeń, krzywe obciążeń, prognozowanie obciążeń

1. WSTĘP

Początkowo, planowanie i prognozowanie zużycia energii elektrycznej było głównie związane z zapewnieniem odpowiednich dostaw energii elektrycznej. Ze względu na specyficzny charakter energii elektrycznej, która nie może być trwale magazynowana, jej popyt i podaż powinny się równać. Pierwsze modele zużycia energii były więc ukierunkowane na prognozowanie popytu na energię.

Na początku modele tworzone były tylko przez przedsiębiorstwa energetyczne i miały formę prostych związków, formułowanych przez ekstrapolację trendu i proste modele ekonometryczne. W dłuższej perspektywie czasu, planowanie okazało się jednak zależne od wielu czynników i już w latach siedemdziesiątych XX wieku, w wyniku zmian gospodarczych niezbędna okazała się zmiana podejścia do problemu prognozowania w systemie elektroenergetycznym.

prof. dr hab. inż. Zbigniew WRÓBLEWSKI, dr inż. Wiktorія GRYPAN
e-mail: [zbigniew.wroblewski; wiktoria.grycan]@pwr.edu.pl

Politechnika Wroclawska, Katedra Energoelektryki
Politechnika Wroclawska, Wyb. Wyspiańskiego 27, 50-370 Wroclaw

PRACE INSTYTUTU ELEKTROTECHNIKI, zeszyt 272, 2016

Punktem wyjścia do analizy stał się odbiorca końcowy, który określa popyt [1]. Nowe podejście pozwoliło na stworzenie modeli o lepszym dopasowaniu, ale skomplikowało ich formułowanie (tworzenie modeli, z punktu widzenia odbiorcy wprowadza do funkcji zużycia energii o wiele więcej czynników decydujących o krzywej zużycia).

Od początku lat dziewięćdziesiątych XX wieku badania zużycia energii nabrały nowego znaczenia [2]. Polityka światowa, a w szczególności polityka Unii Europejskiej, koncentruje się na zagrożeniach środowiskowych, które są wynikiem rozwoju gospodarczego XX wieku. Nowoczesne systemy zasilania są zobowiązane nie tylko do zaspokojenia zapotrzebowania na energię, ale także do spełnienia standardów, procedur oraz stosowania nowoczesnych technologii, w celu zminimalizowania szkodliwego wpływu wytwarzania energii na środowisko naturalne.

Polska, jako członek Unii Europejskiej, stoi w obliczu wyzwań takich jak: wzrost uzależnienia gospodarki od energii elektrycznej, potrzeba łagodzenia zmian klimatycznych i przeciwdziałanie kryzysowi gospodarczemu [3, 4]. Polityka energetyczna Polski jest uwarunkowana zaleceniami Unii Europejskiej, wyrażonymi przez dyrektywy i komunikaty. Europejska polityka zielonej energii i zmniejszenia emisji CO₂ i gazów cieplarnianych do atmosfery to prawdziwe wyzwanie dla Polski, której gospodarka opiera się na stosunkowo łatwo dostępnym i tanim węglu [3]. W ciągu ostatniej dekady przynależności do UE, zrobiono wiele, aby poprawić efektywność energetyczną i podnieść świadomość w zakresie racjonalnego użytkowania energii elektrycznej [5, 6]. Udział odnawialnych źródeł energii w Polsce wzrósł sześciokrotnie, a w 2010 r. osiągnął 9,5% zamiast oczekiwanego 8,8% [6, 7]. Zostały także spopularyzowane zachowania pro oszczędnościowe, takie jak: zastąpienie tradycyjnych źródeł światła przez energooszczędne, wybór urządzenia lub mieszkania ze względu na jego klasę energetyczną. Coraz częściej wykonywane są też w przedsiębiorstwach audyty energetyczne, które pozwalają minimalizować straty energii elektrycznej. Świadomość, dotycząca oszczędności energii, wzrosła na poziomie organów sądowych i przeciętnych użytkowników, a zarządzanie energią stało się ważną kwestią. Dla prawidłowego zarządzania energią, ilość zużycia energii, a także czynniki, które określają zużycie muszą być stale monitorowane, analizowane i planowane na poziomie kraju, firm i klientów indywidualnych.

W ramach wsparcia monitoringu energii rozwijane są „inteligentne” technologie, które są dobrym narzędziem w procesie zarządzania, ze względu na ich komunikację. Zebranie dwukierunkowej informacji może być podstawą do określenia zużycia energii w zależności od czynników zewnętrznych, na przykład w postaci modeli matematycznych, a następnie do opracowania prognoz i scenariuszy w przyszłych okresach.

Problem prognozowania jest problemem szerokim, który może być rozpatrywany w zależności od horyzontu prognozy, posiadanych danych ale również dokładności i błędów prognozowanych danych.

2. MODELOWANIE I PROGNOZOWANIE ZUŻYCIA ENERGII

Ze względu na zastosowanie, modele używane w gospodarce energetycznej można podzielić na dwie podstawowe grupy. Grupę modeli analityczno-prognostycznych oraz grupę modeli prognostycznych. Takie rozróżnienie szczegółowo przedstawia rysunek 1.



Rys. 1. Metody modelowania obciążeń elektroenergetycznych

Wśród modeli, które doskonale spełniają funkcje prognostyczne, jednocześnie nie informując o strukturze i przyczynowości zjawiska, znajdują się, szczególnie rozwijane w ostatnich latach, modele oparte na sztucznej inteligencji, a w tym modele oparte na teorii chaosu zdeterminowanego [8], sztuczne sieci neuronowe [9], systemy ekspertowe [10] czy logika rozmyta [11].

Jedną z największych zalet metod opartych na sztucznej inteligencji jest ich zdolność do rozwiązywania zawiłych, słabo zdefiniowanych problemów, które mogą być obciążone dużymi błędami. Inne modele często nie rozwiązują tak skomplikowanych zagadnień lub czas ich realizacji jest za długi. Metody sztucznej inteligencji, które często są algorytmami heurystycznymi, nie zawsze pozwalają na uzyskanie oczekiwanego wyniku, niemniej niejednokrotnie są najbardziej efektywnym rozwiązaniem problemu. Algorytmy oparte na sztucznej inteligencji uczą się na podstawie przykładów, z dużą łatwością generalizują cechy problemu i wychwytyują wzorce w problemach nieliniowych. Ponadto zdolne są do radzenia sobie z szumami, zakłóceniami i niekompletnością danych wejściowych. Największą chyba zaletą metod sztucznej inteligencji jest to, że opracowany i nauczony model może być następnie wielokrotnie wykorzystywany w różnych sytuacjach bez konieczności modyfikacji [12].

Wadą tego typu modeli jest jednak to, iż nie niosą ze sobą informacji o przyczynowości problemów. Trudno na ich podstawie określić, który z czynników najsilniej oddziałuje na kształt obciążenia. O ile więc, sprawnie przewidują przyszłość, to niespecjalnie sprawdzają się jako narzędzie ułatwiające procesy decyzyjne. Wśród modeli, które dobrze sprawdzają się jako modele analityczne, znajdują się modele regresji prostej i wielorakiej [13], modele procesów ekonomicznych [14] takich jak trend i sezonowość, szeregi czasowe [15] oraz statyczne i dynamiczne modele ekonometryczne [16].

Modelowanie w energetyce można też podzielić ze względu na sposób doboru danych do modelu. Obserwuje się w tym przypadku dwa podejścia, tzw. modelowanie „z góry w dół” i „z dołu w górę” [17]. Metoda „z dołu w górę” polega na przejściu od modelu szczególnego do ogólnego. Proces zaczyna się od stworzenia teorii będącej znacznym uproszczeniem rzeczywistości. Formułuje się bardzo prostą zależność reprezentującą tę teorię i szacuje równania regresji na podstawie dostępnych danych. Istnieje jednak ryzyko niewłaściwego sformułowania modelu, szczególnie w sytuacji ograniczonej liczby parametrów. Następnie przeprowadza się testy kilku podstawowych założeń, np. autokorelacji Durбина-Watsona. W oparciu o otrzymane wyniki następuje korekta modelu i jego ponowne oszacowanie. Podejście to wg E. Hendry’ego [18] ma trzy podstawowe wady:

- każdy test jest warunkowy względem założeń, które są testowane później, a jeśli nie są spełnione, wcześniejsze wyniki są nieaktualne,
- poziomy istotności pozbawionej struktury sekwencji przeprowadzonych testów są nieznanne,
- nie zawsze udaje się osiągnąć najlepszy model przy zastosowaniu procedury iteracyjnej, ponieważ zastosowane testy mogą być mylące lub dokonano niewłaściwego wyboru testów weryfikacyjnych [18].

Odmienne, zaproponowane przez Hendry’ego [18] podejście do problemu to celowe zawyżanie liczby parametrów oraz stopniowe upraszczanie modelu na podstawie danych, tzw. podejście „z góry w dół”, które rozpoczyna się analizą bardzo ogólnego modelu dynamicznego o celowo zawyżonej liczbie parametrów, tj. uwzględniającego więcej opóźnień, niż jest to konieczne. W kolejnych krokach model jest upraszczany poprzez właściwe testy upraszczające. Zaletą tego podejścia jest znajomość poziomów istotności dla j -tego testu. Według Hendry’ego podejście takie pozwala na testowanie teorii ekonomicznych, ponieważ „dopóki model nie charakteryzuje procesu generowania danych, próby weryfikacji hipotez dotyczących teorii ekonomicznych wydają się raczej bezcelowe” [18].

Mając na uwadze zróżnicowane poglądy ekspertów należy każdorazowo przy budowie modelu, po określeniu jego celu i przydatności, dobrać właściwy sposób, który z jednej strony będzie charakteryzował się wymaganym stopniem wiarygodności, ale jednocześnie nie dostarczy więcej pracy.

3. MODELOWANIE ZGODNE

Podejście do modelowania, które zostało wykorzystane do badań prezentowanych w artykule, to modelowanie zgodne. Zostało ono przedstawione przez prof. Zygmunta Zielińskiego z Uniwersytetu Mikołaja Kopernika w Toruniu w 1984 roku i odnosi się do budowania dynamicznych modeli ekonometrycznych. Koncepcja ta, jak również podejście „top-down”, odnosi się zarówno do związków przyczynowych jak i wewnętrznej struktury procesów. „Model jest zgodny według Zielińskiego, jeśli struktura harmoniczna w procesie zależnym Y_t jest taka sama jak wspólnej struktury harmonicznej procesów objaśniających X_{it} $i = (1, 2, \dots, k)$ oraz procesów reszkowych, niezależnych od procesów objaśniających. Model, dla którego wszystkie procesy mają własności białego szumu jest zawsze zgodny” [19]. Model ten ma formę:

$$\varepsilon_{yt} = \sum_{i=1}^k \rho_i \varepsilon_{x_{it}} + \varepsilon_t \quad (1)$$

gdzie:

ε_{yt} , $\varepsilon_{x_{it}}$, ε_t – biały szum.

Model (1) jest zgodny, ponieważ struktura harmoniczna po obu stronach równania jest równa (widma tych procesów są równoległe do osi częstotliwości).

Jeśli Y_t i X_{it} $i = (1, 2, \dots, k)$ oznaczają kolejno proces endogeniczny i wektor procesów objaśniających, to modele opisujące składniki niestacjonarne i modele autoregresyjne można zapisać [19, 20]:

$$Y_t = P_{yt} + S_{yt} + \eta_{yt}, \quad B(u)\eta_{yt} = \varepsilon_{yt}, \quad (2)$$

$$X_{it} = P_{x_{it}} + S_{x_{it}} + \eta_{x_{it}}, \quad A_i(u)\eta_{x_{it}} = \varepsilon_{x_{it}}, \quad (3)$$

gdzie:

P_{yt} , $P_{x_{it}}$ – wielomianowe funkcje zmiennej t ,

S_{yt} , $S_{x_{it}}$ – sezonowy składnik o stałej lub zmiennej amplitudzie wahań,

η_{yt} , $\eta_{x_{it}}$ – stacjonarne procesy autoregresyjne dla poszczególnych procesów,

ε_{yt} , $\varepsilon_{x_{it}}$ – „białe szumy” dla odpowiednich procesów,

$B(u)$, $A_i(u)$ – stacjonarne autoregresyjne operatory, dla których wszystkie pierwiastki równania $|B(u)| = 0$ i $|A_i(u)| = 0$ leżą poza okręgiem jednostkowym.

Zgodny dynamiczny model ekonometryczny może być zbudowany przez zastąpienie ε_{yt} i ε_{xt} w modelu (1) równaniami modeli (2), (3). Po podstawieniu, ogólna postać zgodnego dynamicznego modelu ekonometrycznego to [19, 20]:

$$B(u)Y_t = \sum_{i=1}^k A_i^*(u)X_{it} + P_t + S_t + \varepsilon_t, \quad (4)$$

gdzie:

- P_t – wielomian zmiennej,
- S_t – składnik sezonowy o stałej lub zmiennej amplitudzie wahań,
- ε_t – biały szum (takie same właściwości jak biały szum ε_t w modelu (1)),
- $B(u), A_i^*(u)$ – stacjonarne autoregresyjne operatory przesunięcia.

W wersji liniowej:

$$Y_t = \sum_{i=1}^k \rho_i X_{it} - \sum_{i=1}^k \rho_i A_{i1}^*(u)X_{it} + B_1^* Y_t + \varepsilon_t \quad (5)$$

Sposób takiego modelowania został przedstawiony i opisany szczególnie w artykułach [20, 21]. Jak dotąd, nie był on wykorzystywany w analizie zużycia energii i jej prognozach.

Konstruując każdy model, należy ustalić jego cel i przydatność, a następnie dobrać metodę modelowania adekwatną do wymaganego stopnia dokładności i nie naruszającą dodatkowej pracy.

4. PRZYKŁADY MODELI I PROGNOZ

Dla jednego z Operatorów stworzono dynamiczne modele zgodne o postaci [22]:

$$\begin{aligned} E = & E_1 \cdot t - E_2 \cdot T + E_3 \cdot T_{t-1} - E_4 \cdot m_2 - E_5 \cdot m_4 - E_6 \cdot m_5 + \\ & - E_7 \cdot m_6 - E_8 \cdot m_7 - E_9 \cdot m_8 - E_{10} \cdot m_9 - E_{11} \cdot m_{11} + \\ & + E_{12} \cdot E_{t-1} + E_{13} \cdot E_{t-3} + E_{14} \end{aligned} \quad (6)$$

$$H = H_1 \cdot t^2 - H_2 \cdot t + H_3 \cdot m_1 + H_4 \cdot m_3 - H_5 \cdot m_{10} - H_6 \cdot H_{t-1} + H_7 \quad (7)$$

$$C1_A = -C_{11} \cdot T2_{t-3} + C_{12} \cdot T2_{t-4} + C_{13} \cdot m_1 + C_{14} \cdot m_2 + C_{15} \quad (8)$$

$$\begin{aligned} C1_B = & -C_{16} \cdot m_3 - C_{17} \cdot m_4 - C_{18} \cdot m_5 - C_{19} \cdot m_6 - C_{17} \cdot m_7 + \\ & - C_{18} \cdot m_8 - C_{19} \cdot m_9 - C_{110} \cdot m_{10} + C_{111} \end{aligned} \quad (9)$$

$$G = -G_1 \cdot T + G_2 \cdot G_{t-1} + G_3 \cdot G_{t-2} - G_4 \cdot m_2 - G_5 \cdot m_3 + \\ - G_6 \cdot m_4 - G_7 \cdot m_5 - G_8 \cdot m_6 + G_9 \quad (10)$$

$$A = A_1 \cdot t - A_2 T1_{t-4} - A_3 \cdot m_2 - A_4 \cdot m_6 - A_5 \cdot m_7 + \\ - A_6 \cdot m_{10} + A_7 \quad (11)$$

$$B = B_1 \cdot t - B_2 \cdot B_{t-1} + B_3 \cdot m_1 + B_4 \cdot m_2 + B_5 \cdot m_3 + \\ + B_6 \cdot m_{10} + B_7 \cdot m_{11} + B_8 \quad (12)$$

gdzie:

E – zużycie energii elektrycznej (w obszarach I, II, IV i V) dla danych miesięcznych, G , $C1_A$, $C1_B$ – zużycie energii elektrycznej przez użytkowników z grup taryfowych G , $C1$ – (indeks A – 2009–2010; indeks B – 2011–2012, w obszarach I, II, IV i V), H – zużycie energii elektrycznej przez przedsiębiorstwo produkcyjne H , PKB – krajowy produkt brutto, t , t^2 – funkcje trendu, T , $T1$, $T2$ – temperatura średnia, minimalna, maksymalna, m_1 , m_2, \dots, m_{12} – zmienne sezonowe dla miesięcy styczeń, luty, grudzień, E_1 , E_2, \dots, E_n , H_1 , H_2, \dots, H_n , C_{11} , C_{12}, \dots, C_n , G_1 , G_2, \dots, G_n – stałe.

Na podstawie opracowanych modeli stworzono miesięczne prognozy zużycia energii elektrycznej w okresie jednego roku. Wykresy przykładowych prognoz przedstawiono na rysunkach 2 – 5, a dokładności otrzymanych prognoz oraz stopień dopasowania danych do modelu przedstawia tabela 1.

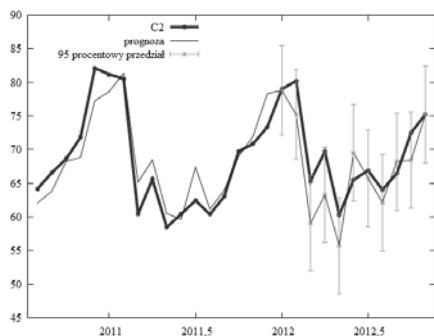

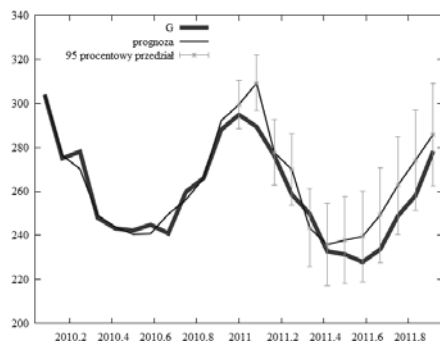

TABELA 1

Ocena prognozy modelu

Model	C2	G	B	A	H	E	C1
R^2	0,84	0,95	0,88	0,84	0,76	0,94	0,94
MAPE ¹⁾	4,7347	3,8679	74,269	5,2701	9,7681	2,9523	4,8097

¹⁾ Średni absolutny błąd procentowy prognoz ex post (mean absolute percentage error, MAPE) obliczonych na momenty/okresy $n + 1, \dots, T$ wg wzoru:

$$\varpi = \frac{1}{T-n} \sum_{i=n-1}^T \left| \frac{y_i - y_i^*}{y_i} \right| 100$$

Rys. 2. Prognoza zmiennej $C2$ Rys. 4. Prognoza zmiennej A Rys. 3. Prognoza zmiennej G Rys. 5. Prognoza zmiennej $C1$

5. PODSUMOWANIE

Modele wykonane z wykorzystaniem metody modelowania zgodnego charakteryzują się wysokim współczynnikiem dopasowania modelu do danych rzeczywistych (R^2). Na obniżenie współczynnika wpłynął przede wszystkim brak dostępu do danych. W przypadku pełnej dostępności współczynnik wynosił około $R^2 \approx 0,95$, natomiast w sytuacji danych niekompletnych $R^2 \approx 0,85$.

Dla modeli o stopniu dopasowania, co najmniej, 95%, błąd prognozy nie przekracza zazwyczaj 5%, co jest wynikiem pożądanym.

Co ciekawe wzrost dopasowania modelu niekoniecznie wpływa na poprawę dokładności prognozy, jak np. w przypadku modelu $C1$ i $C2$ (tab. 1). Dzieje się tak, ponieważ modele dynamiczne oprócz uwzględnienia odchyłek funkcji, zawierają też informację o jej ogólnym trendzie. Dlatego, w przypadku licznych, ale drobnych odchyłek model może mieć niższy współczynnik R^2 przy wyższym błędzie prognozy MAPE.

W przypadku procesu B błąd prognozy okazał się niedopuszczalny (74%). Wynik spowodowany był całkowitą zmianą procesu i niemal dwukrotnym zmniejszeniem zużycia energii elektrycznej w badanej grupie. Model nie mógł przewidzieć takiej sytuacji, ponieważ w zakresie wprowadzonych danych nie było sytuacji o podobnym charakterze. Na poprawę dokładności prognoz wpłynęłoby ujęcie większej liczby zmiennych w dłuższym okresie czasu.

6. WNIOSKI

Zaletą modelowania dynamicznego jest przede wszystkim jego struktura, która pozwala na określenie właściwości badanego zjawiska oraz czynników, które je warunkują. Niestety, jak w przypadku większości metod, liczba wcześniejszych informacji może wpływać na skuteczność prognozy, chociaż niekoniecznie znacząco. Większe znaczenia ma właściwy dobór zmiennych do modelu. Właściwe wykonanie modeli wymaga również szerokiej wiedzy z zakresu modelowania i statystyki, co może być przeszkodą w sprawnym i częstym wykorzystaniu tej metody.

Wskazaniem byłoby stworzenie aplikacji pozwalającej na proste opracowanie modelu, wykorzystującego teorię dynamicznego modelowania zgodnego, która sugerowałaby użytkownikowi rozwiązania i pozwalała na szybkie i proste opracowanie modelu. Dynamiczne modelowanie zgodne można uznać za skuteczną metodę średnioterminowego prognozowania zużycia energii.

LITERATURA

1. Malko J.: Wybrane zagadnienia prognozowania w elektroenergetyce – prognozowanie zapotrzebowania energii i mocy elektrycznej. Oficyna Wydawnicza Politechniki Wrocławskiej, Wrocław, 1995.
2. Weron R.: Modelling and Forecasting Loads and Prices in Deregulated Electricity Markets. Opublikowano przez ARE, Warszawa, 2006.
3. Stoczkiewicz M., Jędrasik I.: Understanding the Polish anti-climate crusade. <www.energypost.eu> (dostęp grudzień 2014).
4. Ćwiek-Karpowicz J., Gawlikowska-Fyk A., Westphal K.: German and Polish Energy Policies: Is cooperation Possible? Policy Paper of Polish Institute of International Affairs. <www.pism.pl> (dostęp: grudzień 2014).
5. Odysee-mure raport. Energy efficiency trends & policies summary, <<http://www.odyssee-mure.eu/publications/>> (dostęp: grudzień 2014).
6. Paska J., Surma T.: Electricity generation from renewable energy sources in Poland. Renewable Energy, nr 71, s. 286-294, 2014.
7. Eurostat baza danych. <http://epp.eurostat.ec.europa.eu/portal/page/portal/eurostat/home/> (dostęp grudzień 2014).
8. Trojanowska M.: Wykorzystanie teorii chaosu zdeterminowanego w prognozowaniu krokowym rocznego zużycia energii elektrycznej przez odbiorców wiejskich. Infrastruktura i Ekologia Terenów Wiejskich, nr 2, s. 121-128, 2005.

9. Ka Fei, Thang.: Implementation of Neural & Neuro-Fuzzy Approaches for Short-Term Electricity Demand Forecasting. Power System Technology Power Conference, 2004; 2, s. 1213-1218, 2004.
10. Ghanbari A., Ghaderi S.F., Azadeh A.: A Clustering based Genetic Fuzzy Expert System for Electrical Energy Demand Prediction. Computer and Automation Engineering ICCAE 2010, IEEE Conference publication; 5, s. 407-411, 2010.
11. Khotanzad A, Zhou E, Elragal H. A: Neuro-Fuzzy Approach to Short-Term Load Forecasting in a Price-Sensitive Environment. Power Systems, 17(4), s. 1273-1282, 2002.
12. Ściążko A.: Zastosowanie metod sztucznej inteligencji w energetyce. Pomiary, Automatyka, Robotyka; nr 7-8, s. 53-59, 2011.
13. Xinghua L.,: Multiple linear regression analysis of energy consumption in China. Journal of Science & Technology Economy Market, vol. 6, s. 45-47, 2011.
14. Sun Q., Beach A., Cotterell M.E., Wu Z.: An Economic Model for Distributed Energy Prosumers. System Sciences (HICSS), IEEE Conference publication; 2103-2112, 2013.
15. Shyh-Jier Huang, Kuang-Rong Shih.: Short-term load forecasting via ARMA model identification including non-Gaussian process considerations. IEEE Transactions on Power Systems, vol. 18, nr 2, s. 673-679, 2003.
16. Schmitt R.W., Ben Daniel D.J., Stewart P.J., Manne A.S.: An econometric analysis of energy over the next 75 years. IEEE Transactions on Power Apparatus and Systems, vol. 96, nr 4, s.1353-1361, 1977.
17. Capasso A., Grattieri W., Lamedica R., Prudenzi A.: A bottom-up approach to residential load modeling. Power Systems, vol. 9, nr 2, s. 957-964, 1994.
18. Hendry D.F.: Predictive failure and econometric modelling in macro-economic: The transactions demand for money. Economic Modelling, Heinemann. London 1979: 217-42. Reprinted in Hendry DF. Econometrics: Alchemy or Science? Oxford: Blackwell Publishers 1993 and Oxford University Press 2000.
19. Błażejowski M., Kufel P., Kufel T.: Automatic Procedure of Building Congruent Dynamic Model in Gretl. Econometrics with gretl, Conference publication, gretl Conference 2009, Bilbao, Spain; 75-91.
20. Kufel T., Kufel P.: The congruence Postulate at the Early Stage of Dynamic Econometric Modelling, Dynamic econometric Models 2008; 8:29-36.
21. Fung WY, Lam KS, Hung WT, Pang SW, Lee YL.: Impact of urban temperature on energy consumption of Hong Kong, Energy, vol. 31, nr14 , s. 2623-2637, 2006.
22. Grycan W., Wnukowska B., Wróblewski Z.: Modelowanie uwarunkowań zużycia energii elektrycznej regionu. Przegląd Elektrotechniczny, vol. 90, nr 2, s. 230-233, 2014.

ASSESSMENT OF DYNAMIC MODELLING
AS A TOOL FOR AN ELECTRICITY CONSUMPTION
FORECASTING FOR A GROUP OF INDIVIDUAL CUSTOMERS

Wiktoria GRYCAN, Zbigniew WRÓBLEWSKI

ABSTRACT *The forecasting of the electricity consumption is an indispensable tool for the modern electrical energy management. The ability of the prediction of future behaviours is the basis for the effective management. Due to the high variability of the energy consumption over time and the impossibility of its long-term storage, particularly important issue is the selection of appropriate tools for the forecasting and determining of the consumption as precisely as possible.*

The article describes the dynamic modelling and the results of predictive dynamic models developed for a group of individual customers. The results were evaluated on the basis of the actual consumption of the electric energy.

Keywords: *modelling of loads, load curves, load forecasting*

