

Małgorzata Trojanowska
Katedra Energetyki Rolniczej
Jerzy Małopolski
Katedra Inżynierii Rolniczej i Informatyki
Uniwersytet Rolniczy w Krakowie

WYKORZYSTANIE LINIOWYCH MODELI ROZMYTYCH DO PROGNOZOWANIA DOBOWEGO ZAPOTRZEBOWANIA ODBIORCÓW WIEJSKICH NA ENERGIĘ ELEKTRYCZNĄ

Streszczenie

Zbudowano modele predykcyjne dla wszystkich dni tygodnia, oddzielnie modelując profil dnia, wartość średnią mocy dobowej oraz odchylenie standardowe przebiegu dobowego obciążenia. Średnie godzinowe zapotrzebowanie na energię elektryczną w ciągu doby oraz odchylenie standardowe tego zapotrzebowania zamodelowano opracowując rozmyte modele z wnioskowaniem typu Takagi-Sugeno. Analiza błędów prognoz wyznaczonych zgodnie z zaproponowaną metodą wykazała jej przydatność do lokalnego prognozowania krótkoterminowego.

Słowa kluczowe: energia elektryczna, prognozowanie krótkoterminowe, modele rozmyte

Wprowadzenie

Prognozowanie zapotrzebowania na energię elektryczną stanowi jeden z najważniejszych obszarów badań w elektroenergetyce. Przedsiębiorstwa trudniące się przesyłem i dystrybucją energii opracowują lokalne prognozy zarówno dla krótkich wyprzedzeń czasowych (godzinowych, dobowych) jak i prognozy długoterminowe nawet na 15 lat naprzód. Wraz z rozwojem mechanizmów wolnorynkowych i konkurencji na rynkach energii wzrasta znaczenie zwłaszcza prognoz krótkoterminowych. Do predykcji krótkoterminowej coraz powszechniej wykorzystuje się metody sztucznej inteligencji, w tym oparte na teorii zbiorów rozmytych. Wśród modeli rozmytych szczególnie przydatne do prognozowania zapotrzebowania na energię elektryczną wydają się być modele z wnioskowaniem typu Takagi-Sugeno [1985], gdyż można w nich zawrzeć obiektywną wiedzę o systemie w jawnej postaci.

Celem pracy było zbudowanie predykcyjnych modeli rozmytych z wnioskowaniem typu Takagi-Sugeno, przydatnych do lokalnego prognozowania godzinowego zapotrzebowania na energię elektryczną z dobowym wyprzedzeniem. Ponieważ szereg czasowy godzinowego zapotrzebowania na energię elek-

tryczną wykazuje zmienność dobową, tygodniową i roczną oraz trend, szereg przetworzono wprowadzając tzw. profile obciążeń [Dudek 2000], by uniezależnić się od cyklu tygodniowego, sezonowego i trendu.

Metoda badań

Profile obciążeń utworzono przez unormowanie dobowych przebiegów zapotrzebowania na energię elektryczną dla każdej doby tygodnia według wzoru:

$$p_{hd} = \frac{P_{hd} - P_{\acute{s}rd}}{\sigma_d}, \quad h = 1, 2, \dots, 24 \quad (1)$$

gdzie:

p_{hd} – h-ta składowa wektora profilu doby, d,

P_{hd} – zapotrzebowanie na energię elektryczną w h-tej godzinie doby, d,

$P_{\acute{s}rd}$ – średnie godzinowe zapotrzebowanie na energię elektryczną w dobie, d,

σ_d – odchylenie standardowe godzinowego zapotrzebowania na energię elektryczną w dobie, d.

Prognozę zapotrzebowania na energię w danej godzinie doby wyznaczano z zależności:

$$\hat{P}_{hd} = \hat{p}_{hd} \hat{\sigma}_d + \hat{P}_{\acute{s}rd}, \quad h = 1, 2, \dots, 24 \quad (2)$$

gdzie:

\hat{P}_{hd} – prognoza zapotrzebowania na energię elektryczną w h-tej godzinie doby d,

\hat{p}_{hd} – prognoza h-tej składowej wektora profilu doby, d,

$\hat{P}_{\acute{s}rd}$ – prognoza średniego godzinowego zapotrzebowania na energię elektryczną w ciągu doby, d,

$\hat{\sigma}_d$ – prognoza odchylenia standardowego godzinowego zapotrzebowania na energię elektryczną w ciągu doby, d.

Ze względu na duże podobieństwo przebiegów, profile danego dnia tygodnia określonego miesiąca przyjmowano jako średnią arytmetyczną profili tych samych dni tygodnia w danym miesiącu.

Średnie godzinowe zapotrzebowanie na energię elektryczną w dobie oraz odchylenie standardowe tego zapotrzebowania zamodelowano z wykorzystaniem teorii zbiorów rozmytych, opracowując liniowe modele Takagi-Sugeno (TK_P , TK_σ) o gaussowskich funkcjach przynależności w przestrzeni wejściowej. Oba modele miały jedną wielowymiarową zmienną wejściową i jedną zmienną wyjściową.

Wyznaczano modele o stałej strukturze [Driankov i in. 1996], tj. modele o ustalonych zmiennych wejściowych, stałej bazie reguł i stałej liczbie zbiorów rozmytych. Ze zbioru danych wyodrębniono zbiór uczący i zbiór testujący. Parametry modeli wyznaczano w taki sposób, aby sumaryczne błędy

kwadratowe modeli na zbiorach uczących były minimalne. Optymalizowano przemiennie parametry warstwy defuzyfikacyjnej i fuzyfikacyjnej metodą gradientów sprzężonych [Osowski 1996], wyznaczając parametry startowe rozmytą metodą c-środków [Piegat 1999]. Wyboru optymalnych modeli dokonano przez zastosowanie algorytmu doboru zmiennych wejściowych do modeli oraz algorytmu wyznaczania ich struktury opisanych w pracy Trojanowskiej i Małopolskiego [2007]. Celem zastosowania algorytmów było otrzymanie takich finalnych modeli, które opisywałyby dokładnie prognozowany przebieg, a jednocześnie miały możliwie jak najmniejszą liczbę zmiennych wejściowych i reguł. Także określenie w przestrzeni wejściowej zbiorów rozmytych, których funkcje przynależności są symetrycznymi funkcjami Gaussa, pozwoliło na otrzymanie efektywnych modeli o niewielkiej liczbie reguł. Za wartość odchylenia standardowego danej funkcji Gaussa przyjęto 1/3 minimum odległości jej ekstremum od ekstremów pozostałych funkcji. Dodatkowo uproszczenie budowy modelu uzyskano przez wyznaczenie w przestrzeni wyjściowej singletonów. Działania te umożliwiły przedstawienie bazy reguł w następującej postaci precyzyjnie opisującej działanie modelu:

$$R1: \text{JEŚLI } (x_1 \text{ blisko } c_{11}) \text{ I } \dots \text{ I } (x_r \text{ blisko } c_{1r}) \text{ TO } (y = a_{10} + a_{11}x_1 + \dots + a_{1r}x_r) \quad (3)$$

$$Rm: \text{JEŚLI } (x_1 \text{ blisko } c_{m1}) \text{ I } \dots \text{ I } (x_r \text{ blisko } c_{mr}) \text{ TO } (y = a_{m0} + a_{m1}x_1 + \dots + a_{mr}x_r),$$

gdzie:

x_1, \dots, x_r – wejścia systemu,

y – wyjście systemu,

c_{ir} , ..., c_{ir} – współrzędne centrum zbioru A_i ,

a_{ik} – współczynniki funkcji liniowej,

$i = 1, \dots, m; k = 1, \dots, r$.


Opierając się na bazie reguł (3) przeprowadzano inferencję MAX-MIN, a przy defuzyfikacji zastosowano metodę wysokości [Piegat 1999].

Wyniki badań

Modelowano przebiegi godzinowego zapotrzebowania na energię elektryczną odbiorców wiejskich jako charakterystycznej grupy odbiorców. Oparto się przy tym na wynikach pomiarów obciążeń prowadzonych na terenach południowej Małopolski w wybranym głównym punkcie zasilającym w latach 2003-2005. Przebieg tego zapotrzebowania przedstawiono na rysunku 1.

Do budowy modelu dobowego zapotrzebowania na energię elektryczną posłużyły dane pomiarowe z lat 2003–2004. Zbiór uczący obejmował 462 dni, a zbiór testujący 224. Do testowania modelu wykorzystano również dane z 2005 r. Z powodu tygodniowej okresowości badanego zapotrzebowania, wyboru zmiennych wejściowych do modeli TK_P i TK_σ dokonano w zakresie opóźnień od 1 do 7 dni odpowiednio ze zbioru wartości średnich mocy dobo-

wych ($P_{\text{sr}1}, P_{\text{sr}2}, \dots, P_{\text{sr}7}$) oraz odchyłeń standardowych dobowego przebiegu ($\sigma_1, \dots, \sigma_7$). Wyniki doboru zmiennych wejściowych oraz liczbę reguł poszczególnych modeli zawiera tabela 1.



Rys. 1. Przebieg godzinowego zapotrzebowania na energię elektryczną w latach 2003-2005 przez odbiorców wiejskich z terenów południowej Małopolski
 Fig. 1. The course of an hour's demand of electric energy within 2003-2005 by the rural consumers in Southern Małopolska region

Tab. 1. Wyniki doboru zmiennych wejściowych do modelu średniej mocy dobowej (TK_P) i modelu odchylenia standardowego przebiegu dobowego (TK_σ)
 Tab. 1. The results of selection of entrance variables to model of average of 24 the hour power (TK_P) and the model of standard deviation of 24 the hour course (TK_σ)

Model	TK_P	TK_σ
Zmienne wejściowe	$P_{\text{sr}1}, P_{\text{sr}2}, P_{\text{sr}6}, P_{\text{sr}7}$	$\sigma_1, \sigma_2, \sigma_3, \sigma_7$
Liczba reguł	6	5

Na przykład, baza reguł (3) modelu średniej mocy dobowej zapisana w postaci jawnej, to:

$$R1: \text{JEŚLI } (P_{\text{sr}1} \text{ blisko } 2,20)I(P_{\text{sr}2} \text{ blisko } 2,25)I(P_{\text{sr}6} \text{ blisko } 1,99)I(P_{\text{sr}7} \text{ blisko } 2,34) \\ \text{TO } (y = -0,15 + 0,28 P_{\text{sr}1} + 0,11 P_{\text{sr}2} - 0,01 P_{\text{sr}6} + 0,68 P_{\text{sr}7}) \quad (4)$$

$$R2: \text{JEŚLI } (P_{\text{sr}1} \text{ blisko } 2,15)I(P_{\text{sr}2} \text{ blisko } 2,26)I(P_{\text{sr}6} \text{ blisko } 2,00)I(P_{\text{sr}7} \text{ blisko } 2,39) \\ \text{TO } (y = 0,15 P_{\text{sr}1} + 0,16 P_{\text{sr}2} - 0,12 P_{\text{sr}6} + 0,75 P_{\text{sr}7})$$


$$R3: \text{JEŚLI } (P_{\text{sr}1} \text{ blisko } 2,00)I(P_{\text{sr}2} \text{ blisko } 1,77)I(P_{\text{sr}6} \text{ blisko } 1,97)I(P_{\text{sr}7} \text{ blisko } 1,70) \\ \text{TO } (y = -0,31 + 0,57 P_{\text{sr}1} + 0,38 P_{\text{sr}2} + 0,01 P_{\text{sr}6} + 0,02 P_{\text{sr}7})$$

$$R4: \text{JEŚLI } (P_{\text{sr}1} \text{ blisko } 1,86)I(P_{\text{sr}2} \text{ blisko } 1,68)I(P_{\text{sr}6} \text{ blisko } 1,80)I(P_{\text{sr}7} \text{ blisko } 2,11) \\ \text{TO } (y = -0,02 + 0,44 P_{\text{sr}1} + 0,25 P_{\text{sr}2} - 0,20 P_{\text{sr}6} + 0,52 P_{\text{sr}7})$$

R5: JEŚLI (P_{sr1} blisko 1,72) $I(P_{sr2}$ blisko 1,95) $I(P_{sr6}$ blisko 1,80) $I(P_{sr7}$ blisko 1,94)
 TO ($y = 0,14 + 0,42 P_{sr1} + 0,23 P_{sr2} + 0,08 P_{sr6} + 0,27 P_{sr7}$)

R6: JEŚLI (P_{sr1} blisko 1,86) $I(P_{sr2}$ blisko 1,78) $I(P_{sr6}$ blisko 1,91) $I(P_{sr7}$ blisko 1,90)
 TO ($y = 0,17 + 1,19 P_{sr1} - 0,11 P_{sr2} + 0,04 P_{sr6} - 0,14 P_{sr7}$)

Na podstawie opracowanych profili poszczególnych dni tygodnia i zbudowanych modeli średniej mocy dobowej (TK_p) oraz odchylenia standardowego przebiegu dobowego (TK_o) wyznaczono prognozy wygaśnię dobowego zapotrzebowania na energię elektryczną odbiorców wiejskich i obliczono błędy tych prognoz. Na rysunku 2 przedstawiono rozkład procentowych błędów dobowych prognoz wygaśnię z lat 2003–2005, a w tabeli 2 wartości średnich absolutnych błędów ex post prognoz (MAPE) wyznaczonych na zbiorze uczącym i testującym. Prawie 60% prognoz ma błędy poniżej 4%, a zdecydowana większość z nich (ok. 90%) nie przekracza 6%.



Rys. 2. Rozkład błędów prognoz ex post dobowego zapotrzebowania na energię elektryczną w latach 2003–2005

Fig. 2. Errors' frequency distribution for the ex-post forecasts of 24 hours' electric energy demand within 2003-2005

Tabela 2. Wartości błędów prognoz ex post dobowego zapotrzebowania na energię elektryczną

Table 2. Values of errors for the ex-post forecasts of 24 hours' demand of electric energy

Typ danych	Okres prognozy	MAPE (%)
Uczące	2003-2004	3,5
Testujące	2003-2004	3,6
	2005	4,9

Podsumowanie

Dekompozycja zadania prognozy dobowego zapotrzebowania na energię elektryczną na wyznaczenie profilu doby oraz zaprognozowanie średniego godzinowego zapotrzebowania na energię elektryczną w ciągu doby oraz

odchylenia standardowego tego zapotrzebowania z wykorzystaniem rozmytych modeli Takagi-Sugeno dała dobre rezultaty. Błędy MAPE nie przekroczyły 5%, a zatem prognozy wyznaczone według przedstawionej metody są dobrej jakości [Zeliaś i in. 2004]. Zaproponowana metoda nadaje się też do zastosowania przy predykcji z większymi wyprzedzeniami czasowymi, ponieważ prognozy profili nie zależą od momentu ich rozpoczęcia, a jedynie wartości średniej mocy dobowej i odchylenia standardowego przebiegu dobowego są uzależnione od powiązań z najbliższą przeszłością.

Bibliografia

Driankov D., Hellendorn H., Reinfrank M. 1996. Wprowadzenie do sterowania rozmytego. WNT, Warszawa

Dudek G. 2000. Krótkoterminowe prognozowanie obciążenia systemu elektroenergetycznego z zastosowaniem sztucznych sieci neuronowych o radialnych funkcjach bazowych. Materiały V Konferencji Naukowej nt. Prognozowanie w elektroenergetyce PE 2000, ss. 59–69

Osowski S. 1996. Sieci neuronowe w ujęciu algorytmicznym. WNT, Warszawa

Piegat A. 1999. Modelowanie i sterowanie rozmyte. AOW EXIT, Warszawa

Takagi T. Sugeno M. 1985. Fuzzy identification of systems and its applications to modelling and control. IEEE Transactions on Systems, Man, and Cybernetics, vol. 15, No. 1, ss. 116–132

Trojanowska M., Małopolski J. 2007. Krótkoterminowe prognozowanie zapotrzebowania na energię elektryczną odbiorców wiejskich przy wykorzystaniu modeli Mamdaniego. Problemy Inżynierii Rolniczej, 3(57): 35–42

Zeliaś A., Pawełek B., Wanat S. 2004. Prognozowanie ekonomiczne. WN PWN Warszawa