

*Małgorzata Trojanowska
Katedra Energetyki Rolniczej
Jerzy Małopolski
Katedra Inżynierii Rolniczej i Informatyki
Akademia Rolnicza w Krakowie*

KRÓTKOTERMINOWE PROGNOZOWANIE ZAPOTRZEBOWANIA NA ENERGIĘ ELEKTRYCZNĄ ODBIORCÓW WIEJSKICH PRZY WYKORZYSTANIU MODELI MAMDANIEGO

Streszczenie

W pracy zbudowano modele z wnioskowaniem typu Mamdani do godzinowego prognozowania zapotrzebowania na energię elektryczną odbiorców wiejskich, jako charakterystycznej grupy użytkowników energii. Ze względu na charakter zmienności obciążeń opracowano odrębne modele dla typowych dni tygodnia. Przeprowadzona analiza wykazała przydatność tych modeli do krótkoterminowej predykcji i ich konkurencyjność w stosunku do modeli neuronowych.

Słowa kluczowe: energia elektryczna, prognozowanie krótkoterminowe, modele rozmyte

Wprowadzenie

Wraz z rozwojem konkurencji i mechanizmów wolnorynkowych na rynkach energii elektrycznej wzrasta znaczenie prognozowania zapotrzebowania na energię elektryczną, zwłaszcza krótkoterminowego (godzinowego i dobowego). Do tego celu zostało wypróbowanych, z różnym skutkiem, wiele modeli i metod prognostycznych, wśród których można wyróżnić modele klasyczne (statystyczne) oraz techniki bazujące na sztucznej inteligencji. Te ostatnie obejmują głównie systemy ekspertowe, wnioskowanie rozmyte oraz sieci neuronowe. Spośród metod sztucznej inteligencji najmniej uwagi poświęcano do tej pory wykorzystaniu do predykcji zapotrzebowania na energię elektryczną modeli rozmytych, chociaż pozwalają one dogodnie opisać niepewność i niedokładność danych wejściowych, które nieodłącznie towarzyszą temu procesowi. Najważniejszymi i najczęściej stosowanymi modelami rozmytymi są modele Mamdaniego. Opierają się one na zbiorze reguł JEŚLI–TO i stanowią jakościowy opis systemu najbardziej bliski językowi naturalnemu [Mamdani 1974, 1977].

Celem pracy było zbudowanie modeli z wnioskowaniem typu Mamdani do godzinowego prognozowania zapotrzebowania na energię elektryczną.

Metodyka pracy

Sprawdzenie przydatności takich modeli przedstawiono na przykładzie prognozy godzinowego zapotrzebowania energii elektrycznej na terenach wiejskich województwa małopolskiego, znajdujących się w rejonie obsługi energetycznej jednego z przedsiębiorstw energetycznych.

Przedsiębiorstwo to jest odpowiedzialne za dostawę energii elektrycznej do ok. 64,5 tys. odbiorców wiejskich, którzy są zaopatrywani w energię elektryczną z siedmiu Głównych Punktów Zasilających (GPZ), za pośrednictwem 1,2 tys. km linii średniego napięcia, 2,2 tys. km linii niskiego napięcia oraz 830 stacji transformatorowych 15/0,4 kV.

Wśród odbiorców przeważają gospodarstwa domowe (33,6 tys.) i rolne (21,7 tys.). Obiekty infrastrukturalne stanowią jedynie 14% wszystkich odbiorców. Średnie roczne zużycie energii elektrycznej przez wiejskie gospodarstwo kształtuje się na poziomie 2,3 MWh.

Przy budowie prognostycznych modeli z wnioskowaniem typu Mamdani dążono do opracowania takich modeli Mamdaniego, które by dokładnie opisywały przebieg obciążenia, a jednocześnie miały możliwie jak najmniejszą liczbę zmiennych wejściowych i jak najprostszą strukturę. Cel ten osiągnięto przez:

- wprowadzenie jednej wielowymiarowej zmiennej wejściowej i jednowymiarowej zmiennej wyjściowej modeli,
- wyodrębnienie ze zbioru danych zbioru uczącego i testującego,
- zastosowanie algorytmu doboru zmiennych wejściowych do modelu, w którym stosuje się metodę analizy współczynników korelacji [Dudek 2000] oraz rozważa się wyrażenie będące sumą średniego absolutnego błędu procentowego prognoz *ex post* (*mean absolute percentage error*, MAPE) [Dittman 2003] wyznaczonych na podstawie budowanych modeli na zbiorze uczącym i tzw. członu kary (iloczyn arbitralnie przyjętego współczynnika kary jednostkowej i liczby zmiennych wejściowych) [Lula 2000],
- zastosowanie algorytmu wyznaczania struktury modelu, w którym rozważa się miernik będący sumą MAPE i jego odchylenia standardowego na zbiorze testującym [Francik 2003],
- optymalizowanie zarówno parametrów warstwy fuzyfikacyjnej, jak i defuzyfikacyjnej za pomocą metody gradientów sprzężonych [Osowski 1996].

Funkcje przynależności zbiorów rozmytych A_i ($i = 1, \dots, m$) określonych w przestrzeni wejściowej są symetrycznymi funkcjami Gaussa. Z kolei w przestrzeni wyjściowej funkcje przynależności zbiorów rozmytych B_i ($i = 1, \dots, m$)

są singletonami. Za wartość i -tego odchylenia standardowego przyjęto jedną trzecią odległości i -tego centrum od centrum jego najbliższego sąsiada. Umożliwia to przedstawienie bazy reguł w postaci:

$$R1: \text{ JEŚLI } (x_1 \text{ blisko } c_{11}) \text{ I } \dots \text{ I } (x_r \text{ blisko } c_{1r}) \text{ TO } (y \text{ blisko } b_1) \quad (1)$$

⋮
⋮
⋮

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

gdzie:

x_1, \dots, x_r – wejścia systemu,

y – wyjście systemu,

c_{i1}, \dots, c_{ir} – współrzędne centrum zbioru A_i ,

b_i – wartość modalna zbioru B_i ,


$i = 1, \dots, m$.

Opierając się na przedstawionej bazie reguł przeprowadzono inferencję MAX-MIN, a przy defuzyfikacji zastosowano metodę wysokości [Piegat 1999].

Wyniki badań

Opracowanie rozmytych modeli prognostycznych przeprowadzono na podstawie wyników pomiarów godzinowego zapotrzebowania na energię elektryczną odbiorców wiejskich zasilanych z wybranego GPZ w latach 2003–2004. Specyficzną cechą zapotrzebowania na energię elektryczną jest duża zmienność jego poziomu w czasie nawet o kilkadziesiąt procent w ciągu doby oraz zróżnicowanie zapotrzebowania w różnych porach roku czy dniach tygodnia. Na rysunku 1 przedstawiono przykładowe przebiegi godzinowego zapotrzebowania na energię elektryczną w wybranym miesiącu zimowym i letnim.

Ze względu na podobieństwo zmienności obciążeń w poszczególnych dniach tygodnia, wyróżniono cztery rodzaje dni, tj. poniedziałek, pozostałe dni robocze tygodnia, sobotę i niedzielę. Dla każdego z nich budowano odrębne modele rozmyte. Z analizy zmienności obciążeń elektroenergetycznych wynika, że na wielkość zapotrzebowania na energię elektryczną w danej godzinie mają wpływ wielkości tego zapotrzebowania w godzinach poprzednich. Na tej podstawie wyboru zmiennych wejściowych do modeli dokonano ze zbioru wartości godzinowego zapotrzebowania na energię elektryczną w zakresie opóźnień od 1 do 168 godzin (x_1, \dots, x_{168}). Wyniki doboru zmiennych wejściowych oraz liczbę reguł poszczególnych modeli zawiera tabela 1. Przykładowo wyniki obliczeń parametrów modelu dla poniedziałków zestawiono w tabeli 2.



Rys. 1. Przebieg godzinowego zapotrzebowania na energię elektryczną w: a) styczniu 2003 r., b) lipcu 2004 r.

Fig.1. Changes of hourly electric energy demand in a) January 2003, b) July 2004

Tabela 1. Wyniki doboru zmiennych wejściowych do modeli Mamdaniego godzinowego zapotrzebowania na energię elektryczną w latach 2003–2004

Table 1. Results of selecting independent variables to Mamdani models of hourly electric energy demand within 2003-2004

Dzień tygodnia	Zmienne wejściowe do modelu	Liczba reguł modelu
Poniedziałek	X ₁ , X ₄₇ , X ₇₂ , X ₇₃ , X ₁₆₈	7
Pozostałe dni robocze	X ₁ , X ₂₄ , X ₂₅ , X ₄₈ , X ₁₆₈	6
Sobota	X ₁ , X ₂₄ , X ₂₆ , X ₁₃₀ , X ₁₆₈	8
Niedziela	X ₁ , X ₄₈ , X ₅₀ , X ₁₆₈	6

Tabela 2. Wyniki estymacji modelu Mamdaniego godzinowego zapotrzebowania na energię elektryczną w poniedziałki w latach 2003–2004

Table 2. Results of estimating Mamdani model of hourly electric energy demand on Mondays within 2003-2004

C ₁₁	C ₁₄₇	C ₁₇₂	C ₁₇₃	C ₁₁₆₈	b ₁
1,86	1,23	2,62	1,62	2,03	2,03
C ₂₁	C ₂₄₇	C ₂₇₂	C ₂₇₃	C ₂₁₆₈	b ₂
1,09	1,51	1,23	2,68	1,09	1,02
C ₃₁	C ₃₄₇	C ₃₇₂	C ₃₇₃	C ₃₁₆₈	b ₃
1,90	2,6	1,14	2,12	1,94	1,70
C ₄₁	C ₄₄₇	C ₄₇₂	C ₄₇₃	C ₄₁₆₈	b ₄
3,33	1,82	3,27	2,28	2,98	3,25
C ₅₁	C ₅₄₇	C ₅₇₂	C ₅₇₃	C ₅₁₆₈	b ₅
2,20	1,22	2,00	1,67	1,08	1,76
C ₆₁	C ₆₄₇	C ₆₇₂	C ₆₇₃	C ₆₁₆₈	b ₆
2,29	1,53	2,17	3,27	2,81	2,00
C ₇₁	C ₇₄₇	C ₇₇₂	C ₇₇₃	C ₇₁₆₈	b ₇
2,88	2,64	2,23	1,34	2,38	2,54

Dla każdego z opracowanych modeli wyznaczono prognozy wygaśle i na ich podstawie wyliczono błędy MAPE (tab. 3), jako najczęściej stosowane w technice prognostycznej wskaźniki oceny jakości predykcji.

Tabela 3. Średnie absolutne błędy prognoz ex post godzinowego zapotrzebowania na energię elektryczną wyznaczonych na zbiorze uczącym i testującym z lat 2003–2004 w oparciu o modele Mamdaniego

Table 3. Average absolute errors of ex-post forecasts on the learning and testing sets for years 2003-2004 on the basis of Mamdani models

Dzień tygodnia	MAPE (%)	
	Zbiór uczący	Zbiór testujący
Poniedziałek	3,57	3,99
Pozostałe dni robocze	3,49	3,46
Sobota	3,60	3,71
Niedziela	3,53	3,53
Wszystkie dni	3,53	3,56

Podsumowanie

Uzyskane wyniki badań wszystkich opracowanych modeli Mamdaniego potwierdziły ich przydatność do krótkoterminowej predykcji zapotrzebowania na energię elektryczną odbiorców wiejskich.

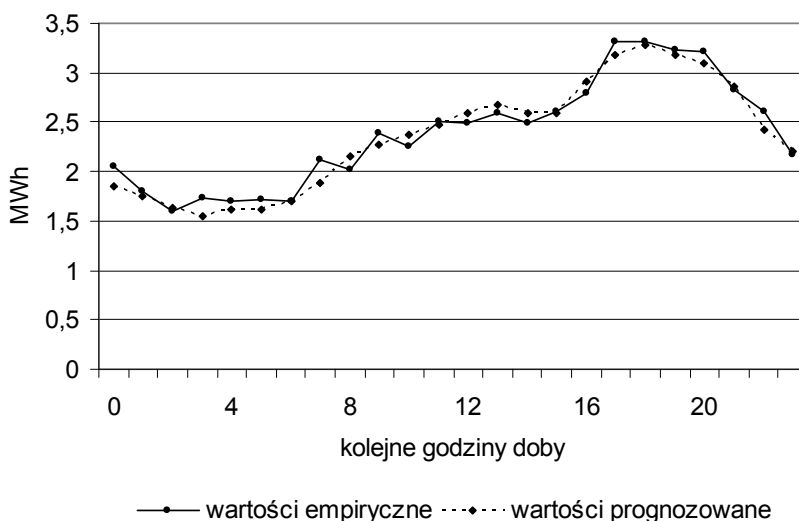
Obliczone zgodnie z tymi modelami prognozy dobrze odwzorowują przebieg godzinowego zapotrzebowania (rys. 2) i charakteryzują się błędami MAPE nieprzekraczającymi 4%, przy niewielkich różnicach pomiędzy błędami na zbiorze uczącym i testującym.

Wartości błędów prognoz, wyznaczonych na podstawie zbudowanych modeli rozmytych, są tego samego rzędu co błędy prognoz wyliczonych przy wykorzystaniu sztucznych sieci neuronowych, uważanych przez wielu autorów za najbardziej skuteczną metodę w prognozowaniu krótkoterminowym.

Bibliografia

Dittman P. 2003. Prognozowanie w przedsiębiorstwie. Oficyna Ekonomiczna, Kraków

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



Rys. 2. Przebieg godzinowego zapotrzebowania na energię elektryczną i prognoza wygasła tego zapotrzebowania określona na zbiorze testującym dla przykładowej doby zimowej

Fig. 2. Course of hourly electric energy demand and its extinct forecast determined on the testing set for an exemplary chosed winter day

Francik S. 2003. Możliwości wykorzystania SSN do prognozowania sprzedaży maszyn rolniczych w warunkach rynkowych. *Inżynieria Rolnicza*, 12(54): 97–105

Lula P. 2000. Wykorzystanie sztucznej inteligencji w prognozowaniu. *Seminarium Statsoft nt. Prognozowanie w przedsiębiorstwie*. Warszawa, ss. 39–69

Mamdani E. H. 1974. Applications of fuzzy algorithms for control of simple dynamic plant. *Proceedings IEEE*, No. 121 (12): 1585–1588

Mamdani E. H. 1977. Applications of fuzzy algorithms to approximate reasoning using linguistic synthesis. *IEEE Transactions on Computers* 1977, vol. C–26, No.12: 1181–1182

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

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

