

## **MODELE ROZMYTE ZAPOTRZEBOWANIA NA MOC DLA POTRZEB KRÓTKOTERMINOWEGO PROGNOZOWANIA ZUŻYCIA ENERGII ELEKTRYCZNEJ NA WSI. CZĘŚĆ II. OPRACOWANIE PREDYKCYJNYCH MODELI RELACYJNYCH**

Jerzy Małopolski

*Instytut Inżynierii Rolniczej i Informatyki, Uniwersytet Rolniczy w Krakowie*

Małgorzata Trojanowska

*Katedra Energetyki i Automatykacji Procesów Rolniczych, Uniwersytet Rolniczy w Krakowie*

**Streszczenie.** Opracowano modele relacyjne do krótkoterminowego prognozowania zapotrzebowania na energię elektryczną odbiorców wiejskich. Przy ich wyznaczaniu skorzystano z opisanych w części I algorytmów wyznaczania modeli rozmytych. Przeprowadzona analiza wykazała przydatność zbudowanych w ten sposób modeli relacyjnych do predykcji z wyprzedzeniem godzinowym.

**Słowa kluczowe:** energia elektryczna, prognozowanie krótkoterminowe, algorytm, model relacyjny

### **Wprowadzenie**

Najczęściej stosowanymi w praktyce modelami rozmytymi są modele z wnioskowaniem typu Mamdani [Mamdani 1974,1977]. Do celów prognostycznych bardziej nadają się jednak modele z wnioskowaniem typu Takagi-Sugeno [Takagi i Sugeno 1985], gdyż na ogół dokładniej odwzorowują przebiegi zmienności badanych zjawisk.

W 1984 r. Pedrycz [Pedrycz 1984,1993] zaproponował nowy rodzaj modeli rozmytych, będących uogólnieniem modeli Mamdaniego. W modelach tych zwanych modelami relacyjnymi poszczególnym regułom przypisuje się odpowiedni współczynnik ufności przyjmujący wartości z przedziału domkniętego  $[0;1]$ . Wydaje się, że takie zróżnicowanie ważności poszczególnych reguł modeli relacyjnych może spowodować ich większą użyteczność do predykcji zapotrzebowania na energię elektryczną nie tylko w porównaniu z modelami Mamdaniego, ale i modelami Takagi-Sugeno.

### **Cel i zakres pracy**

Celem pracy było wykorzystanie opracowanych algorytmów wyznaczania modeli rozmytych [Małopolski, Trojanowska 2009] do zbudowania predykcyjnych modeli relacyj-

nych zapotrzebowania na moc odbiorców wiejskich. W zakres pracy weszło również sprawdzenie przydatności tych modeli do krótkoterminowego prognozowania zużycia energii elektrycznej.

## Wyniki badań

W zastosowanych w pracy modelach relacyjnych przestrzenie rozważań  $X_1, \dots, X_r$  wejść systemu dzielono na dwa lub trzy podzbiory rozmyte o trapezowych lub trójkątnych funkcjach przynależności, spełniających warunek podziału jedności (suma przynależności każdego elementu z przestrzeni rozważań równa się 1). Z kolei w przestrzeni rozważań zmiennej wyjściowej wyznaczano po dwa lub trzy singletony. Wtedy baza reguł ma postać:

$$R1: \text{JEŚLI } (x_1 \text{ jest } A_{11}) \text{ I } \dots \text{ I } (x_r \text{ jest } A_{r1}) \text{ TO } (y \text{ jest } \mu_{11}B_1) \text{ LUB } \dots \text{ LUB } (y \text{ jest } \mu_{1p}B_p) \quad (1)$$

⋮  
⋮  
⋮

$$Rm: \text{JEŚLI } (x_1 \text{ jest } A_{1m}) \text{ I } \dots \text{ I } (x_r \text{ jest } A_{rm}) \text{ TO } (y \text{ jest } \mu_{m1}B_1) \text{ LUB } \dots \text{ LUB } (y \text{ jest } \mu_{mp}B_p),$$

gdzie:

- $x_1, \dots, x_r$  – wejścia systemu,
- $y$  – wyjście systemu,
- $A_{ki}$  – zbiory rozmyte odniesienia w przestrzeniach rozważań  $X_1, \dots, X_r$ ,
- $B_j$  – zbiory rozmyte odniesienia w przestrzeni rozważań  $Y$  zmiennej wyjściowej,
- $\mu_{ij}$  – współczynniki ufności,
- $k = 1, \dots, r; i = 1, \dots, m,$
- $j = 1, \dots, p.$


Wyjście  $y$  systemu obliczano metodą wysokości [Piegat 1999]. Zapis konkluzji typu  $(y \text{ jest } \mu_{ij}B_j)$  oznacza, że podczas defuzyfikacji stopień aktywacji zbioru  $B_j$  należy pomnożyć przez współczynnik ufności  $\mu_{ij}$ .

Opracowanie rozmytych modeli relacyjnych przeprowadzono na podstawie wyników pomiarów godzinowego zapotrzebowania na energię elektryczną grupy odbiorców wiejskich zasilanych z wybranego GPZ-tu z terenu Polski południowej. Przebieg zmienności tego zapotrzebowania w okresie roku przedstawiono na rysunku 1.

Z analizy zmienności obciążeń elektroenergetycznych wynika, że na wielkość zapotrzebowania na energię elektryczną w danej godzinie mają wpływ wielkości tego zapotrzebowania w godzinach poprzednich. Można też zauważyć podobne przebiegi dobowych obciążeń godzinowych w typowych dnia tygodnia. W związku z tym w pracy wyróżniono cztery typy dni: poniedziałek, pozostałe dni robocze tygodnia (od wtorku do piątku), sobotę i niedzielę. Dla każdego z nich budowano odrębne modele rozmyte.

Baza danych dotyczących godzinowego zapotrzebowania na energię elektryczną jest duża i wykorzystanie wszystkich danych z bazy do budowy modeli jest niecelowe. Spośród

danych dotyczących obciążeń elektroenergetycznych wyodrębniono zbiór uczący i zbiór testujący. Wybrane dane w obu tych zbiorach dotyczyły w jednakowym stopniu wszystkich pór, przy czym zbiór uczący miał o około 50% więcej elementów od zbioru testującego.



Rys. 1. Przebieg godzinowego zapotrzebowania na energię elektryczną odbiorców wiejskich  
 Fig. 1. Trajectory of hourly electric energy demand for rural consumers

Korzystając z algorytmu doboru zmiennych wejściowych [Małopolski, Trojanowska 2009] przyjęto:

1. w punkcie 1 – zestawienie zmiennych wejściowych objęło wartości godzinowego zapotrzebowania na energię elektryczną w zakresie opóźnień od 1 do 168 godzin ( $x_1, \dots, x_{168}$ ),
2. w punkcie 5 – miernik  $mBw_k$  wyznaczano na bazie danych testujących oraz przyjęto wartość współczynnika kary jednostkowej  $\alpha = 0,2\%$ .

Wyniki doboru zmiennych wejściowych do poszczególnych modeli oraz liczbę ich reguł przedstawia tabela 1. Przykładowo wyniki obliczeń parametrów modelu dla poniedziałków zestawiono w tabeli 2.

Dla każdego z opracowanych modeli wyznaczono prognozy wygaśle. Wykresy absolutnych błędów procentowych prognoz na zbiorze uczącym oraz na zbiorze testującym przedstawiono na rysunku 2.

Tabela 1. Wyniki doboru zmiennych wejściowych i liczby reguł modeli relacyjnych godzinowego zapotrzebowania na energię elektryczną

Table 1. Results of selecting input variables and the number of rules for relationship models of hourly electric energy demand

Dzień tygodnia	Zmienne wejściowe do modelu	Liczba reguł modelu
Poniedziałek	$x_1, x_{47}, x_{72}, x_{73}, x_{168}$	32
Pozostałe dni robocze	$x_1, x_{24}, x_{25}, x_{168}$	24
Sobota	$x_1, x_{24}, x_{130}, x_{168}$	36
Niedziela	$x_1, x_{48}, x_{50}, x_{168}$	24

Tabela 2. Wyniki estymacji modelu relacyjnych godzinowego zapotrzebowania na energię elektryczną w poniedziałki

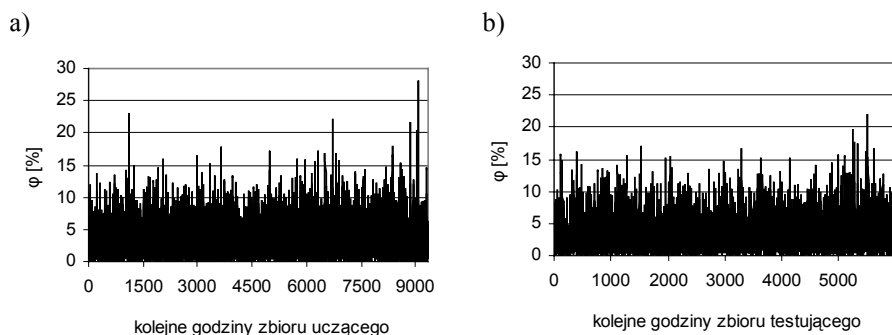
Table 2. Estimation results for relationship models of hourly electric energy demand on Mondays

$x_{10}$	$x_{11}$	$x_{12}$	$x_{13}$	$x_{470}$	$x_{471}$	$x_{472}$	$x_{473}$	$x_{720}$	$x_{721}$	
1,02	1,08	3,35	3,35	1,10	1,10	3,20	3,33	1,08	1,11	
$x_{722}$	$x_{723}$	$x_{730}$	$x_{731}$	$x_{732}$	$x_{733}$	$x_{1680}$	$x_{1681}$	$x_{1682}$	$x_{1683}$	
3,20	3,33	1,08	1,22	3,20	3,33	1,02	1,02	3,25	3,31	
$b_1$	$b_2$	$\mu_{11}$	$\mu_{12}$	$\mu_{21}$	$\mu_{22}$	$\mu_{31}$	$\mu_{32}$	$\mu_{41}$	$\mu_{42}$	$\mu_{51}$
1,02	3,35	0,42	0,01	0,12	0,00	1,00	0,00	0,90	0,00	0,17
$\mu_{52}$	$\mu_{61}$	$\mu_{62}$	$\mu_{71}$	$\mu_{72}$	$\mu_{81}$	$\mu_{82}$	$\mu_{91}$	$\mu_{92}$	$\mu_{101}$	$\mu_{102}$
0,00	0,00	0,18	0,38	0,00	0,27	0,54	0,39	0,02	0,53	0,6
$\mu_{111}$	$\mu_{112}$	$\mu_{121}$	$\mu_{122}$	$\mu_{131}$	$\mu_{132}$	$\mu_{141}$	$\mu_{142}$	$\mu_{151}$	$\mu_{152}$	$\mu_{161}$
1,00	0,00	1,00	0,00	0,00	0,46	0,08	0,04	0,61	0,03	0,11
$\mu_{162}$	$\mu_{171}$	$\mu_{172}$	$\mu_{181}$	$\mu_{182}$	$\mu_{191}$	$\mu_{192}$	$\mu_{201}$	$\mu_{202}$	$\mu_{211}$	$\mu_{212}$
0,66	0,15	0,22	0,36	0,70	0,46	0,00	0,30	0,18	0,00	0,55
$\mu_{221}$	$\mu_{222}$	$\mu_{231}$	$\mu_{232}$	$\mu_{241}$	$\mu_{242}$	$\mu_{251}$	$\mu_{252}$	$\mu_{261}$	$\mu_{262}$	$\mu_{271}$
0,00	1,00	0,05	0,15	0,01	0,12	0,3	0,00	0,00	0,00	0,17
$\mu_{272}$	$\mu_{281}$	$\mu_{282}$	$\mu_{291}$	$\mu_{292}$	$\mu_{301}$	$\mu_{302}$	$\mu_{311}$	$\mu_{312}$	$\mu_{321}$	$\mu_{322}$
0,28	0,09	0,64	0,00	0,26	0,00	0,89	0,00	0,53	0,00	0,10

Z analizy wykresów wynika, że błędy o wartości powyżej 20% występują sporadycznie, przy czym błąd maksymalny na zbiorze uczącym jest większy od błędu maksymalnego na zbiorze testującym. Dla potrzeb analizy błędów prognoz sporządzono histogramy błędów, które przedstawia rysunek 3.


Z rysunków widać, że zarówno dla zbioru uczącego, jak i testującego większość (ok. 75%) błędów mieści się w zakresie 0–5%, a ponad 35% stanowią błędy prognoz o małej wartości, poniżej 2%.

Oceniając jakość prognoz obliczono również wartości średnie błędów dla zbioru uczącego i dla zbioru testującego (tab. 3).



Rys. 2. Wykresy absolutnych błędów prognoz wygasłych godzinowego zapotrzebowania na energię elektryczną wyznaczonych na zbiorze: a) uczącym, b) testującym

Fig. 2. Diagrams showing absolute errors of expired predictions for hourly electric energy demand determined for the following sets: a) teaching, b) testing



Rys. 3. Rozkłady absolutnych błędów prognoz wygasłych godzinowego zapotrzebowania na energię elektryczną wyznaczonych na zbiorze: a) uczącym, b) testującym

Fig. 3. Distributions of absolute errors of expired predictions for hourly electric energy demand

Tabela 3. Średnie absolutne błędy prognoz ex post godzinowego zapotrzebowania na energię elektryczną wyznaczonych w oparciu o modele relacyjne

Table 3. Average absolute errors of ex post predictions for hourly electric energy demand, determined on the basis of relationship models

Dzień tygodnia	Zbiór uczący	Zbiór testujący
Poniedziałek	3,53	3,91
Pozostałe dni robocze	3,50	3,50
Sobota	3,61	3,63
Niedziela	3,40	3,47
Wszystkie dni	3,51	3,57

## Podsumowanie

Wyniki badań wykazały przydatność rozmytych modeli relacyjnych do krótkoterminowego prognozowania zapotrzebowania na energię elektryczną odbiorców wiejskich. Obliczone z otrzymanych modeli prognozy można uznać za dobre, gdyż średnie absolutne błędy prognoz mieszczą się w granicach od 3,4% do 3,91% [Zeliaś i in. 2004], przy czym jedna trzecia błędów prognoz nie przekracza 2%, a błędy większe od 20% zdarzają się sporadycznie.

## Bibliografia

- Małopolski J., Trojanowska M.** 2009. Modele rozmyte zapotrzebowania na moc dla potrzeb krótkoterminowego prognozowania zużycia energii elektrycznej na wsi. Część I. Algorytmy wyznaczania modeli rozmytych. Inżynieria Rolnicza 2009, (w druku).
- Mamdani E. H.** 1974. Applications of fuzzy algorithms for control of simple dynamic plant. Proceedings IEEE, No. 121 (12). s. 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. s. 1181-1182.
- Pedrycz W.** 1984. An identification algorithm in fuzzy relational systems. Fuzzy Sets and Systems, No. 13. s. 153-167.
- Pedrycz W.** 1993. Fuzzy control and fuzzy systems. New York: John Wiley and Sons. ISBN 0-471-93475-5.
- 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. s.116-132.
- Zeliaś A., Pawelek B., Wanat S.** 2004. Prognozowanie ekonomiczne. WN PWN Warszawa. ISBN 83-01-14043-7.

## **FUZZY MODELS OF POWER DEMAND FOR THE PURPOSES OF SHORT-TERM PREDICTING OF ELECTRIC ENERGY CONSUMPTION IN THE COUNTRY PART II. DEVELOPMENT OF PREDICTIVE RELATIONSHIP MODELS**

**Abstract.** The research involved development of relationship models for short-term predicting of electric energy demand for rural consumers. When defining them, the researchers used algorithms for determining fuzzy models described in part I. Completed analysis has proven that relationship models built in this way are useful for prediction with one-hour advance.

**Key words:** electric energy, short-term predicting, algorithm, relationship model

**Adres do korespondencji:**

Jerzy Małopolski; e-mail: [malopolski@ur.krakow.pl](mailto:malopolski@ur.krakow.pl)  
Instytut Inżynierii Rolniczej i Informatyki  
Uniwersytet Rolniczy w Krakowie  
ul. Balicka 116B  
30-149 Kraków