

MODELE ROZMYTE ZAPOTRZEBOWANIA NA MOC DLA POTRZEB KRÓTKOTERMINOWEGO PROGNOZOWANIA ZUŻYCIA ENERGII ELEKTRYCZNEJ NA WSI CZĘŚĆ I. ALGORYTMY WYZNACZANIA MODELI ROZMYTYCH

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 i oprogramowano algorytmy wyznaczania modeli rozmytych, a w szczególności algorytm doboru zmiennych wejściowych do modeli oraz algorytm wyznaczania struktury modeli. Spowodowało to przyśpieszenie procesu budowy modeli prognostycznych opartych na teorii zbiorów rozmytych, dając w ten sposób możliwość łatwego ich zastosowania do prognozowania zużycia energii elektrycznej na wsi

Słowa kluczowe: energia elektryczna, prognozowanie krótkoterminowe, algorytm, model rozmyty

Wprowadzenie

Realia rynku energii elektrycznej skłaniają spółki odpowiedzialne za zaopatrzenie w energię do poszukiwania coraz bardziej efektywnych metod prognostycznych. Wiedza na temat najbliższej przyszłości pozwala bowiem podejmować trafne decyzje dotyczące bieżącej działalności spółki. Ponieważ klasyczne techniki prognostyczne wyznaczały coraz mniej wiarygodne prognozy, w ostatnich latach zwiększyło się zainteresowanie możliwościami wykorzystania do prognozowania zapotrzebowania na energię elektryczną alternatywnych technik prognostycznych, które są mniej wrażliwe na przypadkowe nieregularności, odbiegające od cech charakterystycznych badanego procesu. Rozwinęła się cała grupa metod znana pod wspólną nazwą metod sztucznej inteligencji. Do grupy tej należą też techniki prognostyczne wykorzystujące teorię zbiorów rozmytych. W literaturze przedmiotu [Popławski 2005a, 2005b; Trojanowska i Małopolski 2007; Małopolski i Trojanowska 2008] można znaleźć przykłady udanych prób jej zastosowania do prognozowania potrzeb elektroenergetycznych. Bazy reguł (wiedzy) modeli rozmytych przedstawiają ważne informacje o modelowanych systemach, których nie można uzyskać przy zastosowaniu sztucznych sieci neuronowych, najczęściej spośród wszystkich metod sztucznej inteligencji wykorzystywanych do prognozowania w elektroenergetyce.

Aplikacja teorii zbiorów rozmytych do prognozowania potrzeb elektroenergetycznych daje możliwość wyboru modelu predykcyjnego spośród wielu modeli o różnych zestawach zmiennych wejściowych i o różnych strukturach.

Cel i zakres pracy

Celem pracy było opracowanie algorytmów wyznaczania optymalnych modeli rozmytych, które generowałyby krótkoterminowe prognozy zapotrzebowania na energię elektryczną dobrej jakości, a jednocześnie miały możliwie jak najmniejszą liczbę zmiennych wejściowych i jak najprostszą strukturę. W zakres pracy weszło opracowanie algorytmu doboru zmiennych wejściowych do modeli oraz algorytmu wyznaczania struktury modeli, które następnie oprogramowano.

Wyniki badań

Algorytmy wyznaczania optymalnych modeli rozmytych

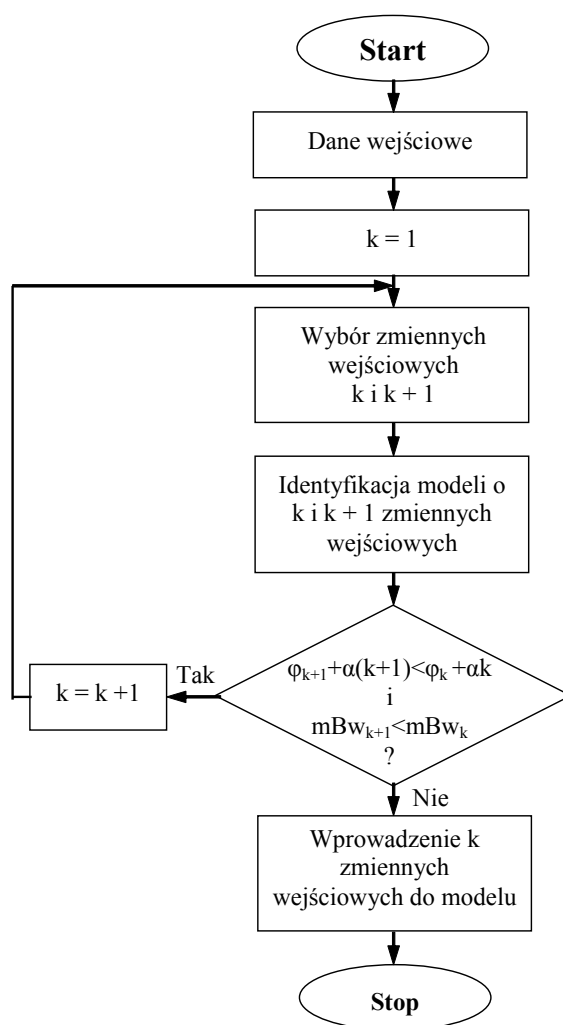
Modele optymalne wyznacza się spośród modeli o ustalonych zmiennych wejściowych, o stałej bazie reguł i stałej liczbie zbiorów rozmytych. Ponieważ przy wykonywaniu krótkoterminowych prognoz zapotrzebowania na energię elektryczną dysponuje się zbiorem danych o dużej liczebności, wydziela się z niego zbiór uczący oraz zbiór testujący. Do wyznaczania parametrów modeli jest wykorzystywana metoda gradientów sprzężonych [Findeisen i in. 1977; Osowski 1996]. W celu dodatkowego przyśpieszenia procesu doboru najlepszego modelu optymalizuje się zarówno parametry warstwy fuzyfikacyjnej jak i defuzyfikacyjnej, minimalizując sumaryczny błąd kwadratowy modeli na zbiorze uczącym.

Przy wyznaczaniu zmiennych wejściowych do modeli oraz ich struktury jest sprawdzana jakość prognoz obliczonych w oparciu o te modele, przez określenie średniego absolutnego błędu procentowego prognoz *ex post* (φ) liczonego na zbiorach uczących i testujących.

W celu minimalizacji zbioru zmiennych wejściowych modelu, do błędu φ liczonego na zbiorze uczącym modelu dodaje się tzw. człon kary będący iloczynem odpowiednio zdefiniowanego współczynnika – kary jednostkowej α i liczby uwzględnionych zmiennych [Lula 2000]. W przeciwieństwie do zbioru uczącego, zmniejszanie błędu φ na zbiorze testującym nie musi być powiązane z minimalizacją odchylenia standardowego tego błędu, którego zbyt wysoka wartość może znacznie obniżyć wiarygodność obliczonych prognoz. Problem ten jest szczególnie istotny w przypadku prognoz dobowych, wyznaczanych w oparciu o modele, dla których zmiennymi wejściowymi są wartości wcześniejszych prognoz. W takim przypadku wystąpienie jednego dużego błędu predykcji w danej godzinie może pociągnąć za sobą znaczne zwiększenie błędów prognoz wykonanych dla kolejnych godzin. Dlatego też do oceny jakości prognoz wyznaczanych na zbiorach testujących zastosowano miernik mBw [Francik 2003], będący sumą błędu φ i odchylenia standardowego absolutnych błędów procentowych tych prognoz.

Algorytm doboru zmiennych wejściowych do modeli

Podstawową czynnością w procesie wyznaczania modeli jest dobór zmiennych wejściowych. Zastosowany w pracy algorytm wyznaczania tych zmiennych obrazuje schemat blokowy pokazany na rysunku 1.



Rys. 1. Schemat blokowy doboru zmiennych wejściowych do modelu
 Fig. 1. Block diagram for selecting input variables for a model

Tok postępowania przy wyznaczaniu zmiennych wejściowych przedstawia się następująco:

Start

1. Dane wejściowe
Zestawia się wszystkie możliwe zmienne wejściowe oraz zmienną wyjściową.
2. Początkowa liczba zmiennych wejściowych
Przyjęto, że początkowa liczba zmiennych wejściowych wynosi jeden.
3. Wybór k i $k+1$ zmiennych wejściowych do modelu rozmytego
Do rozwiązania tego problemu zastosowano w pracy metodę analizy współczynników korelacji [Dąsał 2002]. W metodzie tej zmienne wejściowe powinny być silnie skorelowane ze zmienną wyjściową, a słabo między sobą.
4. Identyfikacja modeli o k i $k+1$ zmiennych wejściowych
Wykorzystując omówiony poniżej algorytm wyznaczania struktury modeli buduje się modele o k i $k+1$ zmiennych wejściowych.
5. Porównywanie modeli o k i $k+1$ zmiennych wejściowych
Przyjmuje się wartość współczynnik kary jednostkowej α [Lula 2000].
Niech φ_k oznacza wartość błędu φ prognozy wyznaczonej na zbiorze uczącym w oparciu o model o k zmiennych wejściowych, a mBw_k wartość miernika mBw na zbiorze testującym dla tego samego modelu. Model o $k+1$ zmiennych wejściowych jest uznawany za lepszy od modelu o k zmiennych, jeśli są spełnione nierówności:

$$\varphi_{k+1} + \alpha(k+1) < \varphi_k + \alpha k \quad (1)$$

$$mBw_{k+1} < mBw_k$$

W takim przypadku zwiększa się k o jeden i wraca do punktu 3. Jeśli któraś z nierówności nie jest spełniona, to przechodzi się do punktu 6.

6. Końcowy wybór k zmiennych wejściowych do modelu rozmytego
Stop.

Algorytm wyznaczania struktury modeli

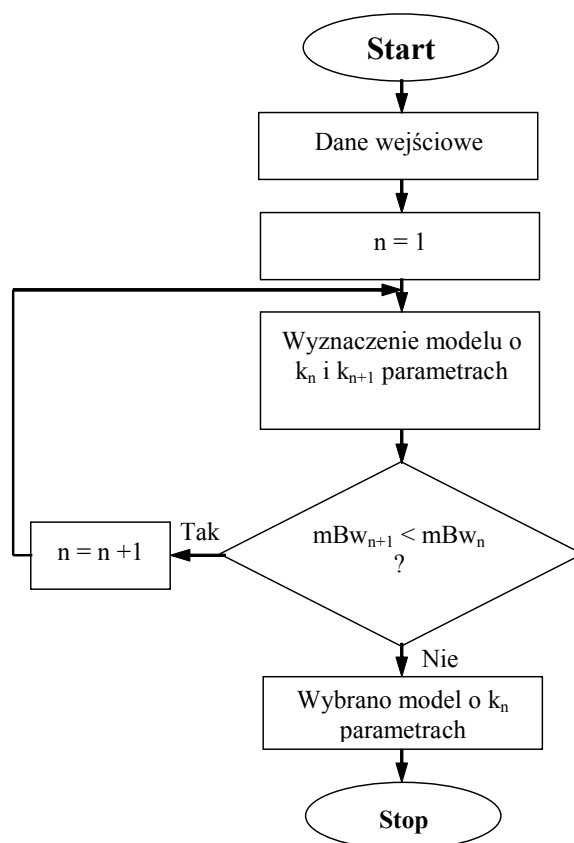
W pracy do wyznaczania struktury modeli o ustalonych zmiennych wejściowych zastosowano zasadę konstruktywną [Piegat 1999]. Algorytm opracowany w oparciu o tę zasadę obrazuje schemat blokowy przedstawiony na rysunku 2.

Tok postępowania przy wyznaczaniu parametrów modelu przedstawia się następująco:

Start

1. Dane wejściowe
Ustalone są zmienne wejściowe i zmienna wyjściowa.
2. Początkowa liczba parametrów modelu
Procedurę rozpoczyna się od modelu o najprostszej strukturze, przy czym przez k_1 określono liczbę parametrów takiego modelu. Określenie to oznacza modele o $k+1$ regułach.
3. Wyznaczenie modelu o k_n i k_{n+1} parametrach (k_n jest rosnącym ciągiem możliwych liczb parametrów modelu)

W przypadku, gdy możliwe jest wyznaczenie modeli o tej samej liczbie parametrów, ale o różnych strukturach wybiera się model, dla którego miernik mBw na zbiorze testującym jest najmniejszy.



Rys. 2. Schemat blokowy wyznaczania struktury modelu

Fig. 2. Block diagram for determining the structure of a model

4. Porównywanie modeli o k_n i k_{n+1} parametrach

Niech mBw_n oznacza wartość miernika mBw dla wyznaczonego modelu o k_n parametrach.

Jeśli

$$mBw_{n+1} < mBw_n \quad (2)$$

to n zwiększa się o jeden i wraca do punktu 2. W przeciwnym przypadku przechodzi się do punktu 5.

5. Końcowy wybór modelu o k_n parametrach

Stop.

Podsumowanie

Opracowanie i oprogramowanie algorytmu doboru zmiennych wejściowych do modeli rozmytych oraz algorytmu wyznaczania struktury tych modeli przyspieszyło proces budowy modeli predykcyjnych opartych na teorii zbiorów rozmytych, dając w ten sposób możliwość łatwego ich wykorzystania w praktyce prognostycznej przy przewidywaniu zapotrzebowania na energię elektryczną odbiorców wiejskich.

Bibliografia

- Dąsal K.** 2002. Wpływ doboru zmiennych na błąd prognozy w modelu sieci neuronowej. VI Konferencja Naukowa PE 2002 „Prognozowanie w elektroenergetyce”. Częstochowa. s. 98-108.
- Findeisen W., Szymanowski J., Wierzbicki A.** 1977. Teoria i metody obliczeniowe optymalizacji. WNT. Warszawa. ISBN 83-01-00976-4.
- Francik S.** 2003. Możliwości wykorzystania SSN do prognozowania sprzedaży maszyn rolniczych w warunkach rynkowych. *Inżynieria Rolnicza* 12 (54). s. 97-105.
- Lula P.** 2000. Wykorzystanie sztucznej inteligencji w prognozowaniu. Materiały Seminarium Statsoft. „Prognozowanie w przedsiębiorstwie”. Warszawa. s. 39-69.
- Małopolski J., Trojanowska M.** 2008. Wykorzystanie modeli Mamdaniego do predykcji dobowych obciążeń wiejskich sieci elektroenergetycznych. *Inżynieria Rolnicza* Nr 9 (107). s. 205-212.
- Osowski S.** 1996. Sieci neuronowe w ujęciu algorytmicznym. WNT. Warszawa. ISBN 83-204-1976-X.
- Piegat A.** 1999. Modelowanie i sterowanie rozmyte. AOW EXIT. Warszawa. ISBN 83-87674-14-1.
- Popławski T.** 2005a. Application of the Takagi–Sugeno (TS) fuzzy logic model for load curves prediction in the local power system. III–rd International Scientific Symposium Elektroenergetyka, Stara Lesna Slovak Republic. ISBN 80-8073-305-8.
- Popławski T.** 2005b. Zastosowanie rozmytego modelu Mamdaniego do prognoz obciążeń w lokalnych systemach elektroenergetycznych. XII Międzynarodowa Konferencja Naukowa „Aktualne problemy w elektroenergetyce APE’05”. Gdańsk–Jurata. s. 65-72.
- Trojanowska M., Małopolski J.** 2007. Krótkoterminowe prognozowanie zapotrzebowania na energię elektryczną odbiorców wiejskich przy wykorzystaniu modeli Mamdaniego. *Problemy Inżynierii Rolniczej* 3(57). s. 35-42.

FUZZY MODELS OF POWER DEMAND FOR THE PURPOSES OF SHORT-TERM PREDICTING OF ELECTRIC ENERGY CONSUMPTION IN THE COUNTRY PART I. ALGORITHMS USED TO DETERMINE FUZZY MODELS

Abstract. The scope of the research involved development and programming of algorithms for determining fuzzy models, and in particular an algorithm for selecting input variables for models and an algorithm for determining the structure of models. This resulted in the acceleration of the process involving construction of predicting models based on fuzzy set theory, thus making it possible to use them for predicting electric energy consumption in the country.

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

Adres do korespondencji:

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