

ZASTOSOWANIE METOD SZTUCZNEJ INTELIGENCJI DO PROGNOZOWANIA MIESIĘCZNEJ SPRZEDAŻY ENERGII ELEKTRYCZNEJ NA WSI

Małgorzata Trojanowska, Jerzy Małopolski

Akademia Rolnicza w Krakowie

Streszczenie. W artykule analizowano możliwości wykorzystania metod sztucznej inteligencji, a w szczególności modeli opartych na teorii chaosu zdeterminowanego, modeli neuronowych oraz modeli rozmytych do prognozowania miesięcznej sprzedaży energii elektrycznej odbiorcom wiejskim. Przeprowadzone obliczenia potwierdziły dużą przydatność sztucznych sieci neuronowych do prognozowania zapotrzebowania na energię elektryczną. Konkurencyjne w stosunku do modeli neuronowych i godne polecenia do celów predykcyjnych okazały się rozmyte modele z wnioskowaniem typu Takagi-Sugeno.

Słowa kluczowe: energia elektryczna, prognoza, teoria chaosu, sieci neuronowe, zbiory rozmyte

WSTĘP

Przewidywanie przyszłych wartości zapotrzebowania energii elektrycznej odgrywa kluczową rolę w procesach decyzyjnych związanych m.in. z planowaniem eksploatacji systemu elektroenergetycznego. Za eksploatację sieci elektroenergetycznych odpowiedzialne są spółki trudniące się przesyłem i dystrybucją energii elektrycznej, a decyzje w tym zakresie podejmują, opierając się m.in. na prognozach sprzedaży energii elektrycznej sporządzanych w szczególności dla miesięcznych wyprzedzeń czasowych.

Ostatnie lata charakteryzują się w naszym kraju szybkimi i często nieoczekiwanymi zmianami we wszystkich dziedzinach działalności człowieka. Prognozowanie, które bazuje zazwyczaj na analizie przeszłości, stało się więc trudniejsze. Dotychczasowe, klasyczne modelowanie zapotrzebowania na energię elektryczną generuje coraz mniej wiarygodne prognozy. W następstwie tego w ostatnich latach zwiększyło się zainteresowanie możliwościami wykorzystania w prognozowaniu potrzeb elektroenergetycznych grupy metod znanych pod wspólną nazwą metod sztucznej inteligencji. Metody sztucznej inteligencji są obecnie rozwijane na świecie niezwykle intensywnie i to zarówno od strony teoretycznej, jak i aplikacyjnej.

Adres do korespondencji – Corresponding Author: Małgorzata Trojanowska, Zakład Energetyki Rolniczej; Jerzy Małopolski, Katedra Mechanizacji Rolnictwa Akademii Rolniczej w Krakowie, ul. Balicka 104, 30-149 Kraków, e-mail:trojanowska@ar.krakow.pl, e-mail:malopolski@ar.krakow.pl

Celem pracy było przeanalizowanie możliwości wykorzystania metod sztucznej inteligencji, a w szczególności modeli opartych na teorii chaosu zdeterminowanego, modeli neuronowych oraz modeli rozmytych do prognozowania miesięcznej sprzedaży energii elektrycznej. Cel pracy zrealizowano, opierając się na danych dotyczących sprzedaży energii elektrycznej odbiorcom wiejskim jako charakterystycznej grupy użytkowników energii.

MATERIAŁ I METODY

Możliwości wykorzystania metod sztucznej inteligencji do prognozowania sprzedaży energii sprawdzano na podstawie sprawozdania miesięcznej sprzedaży energii elektrycznej w latach 1993–2002 wiejskim odbiorcom z obszaru województwa małopolskiego przez wybraną spółkę dystrybucyjną. Dotyczą one 291 tys. odbiorców. W tej liczbie mieści się ok. 125 tys. gospodarstw rolnych o średniej powierzchni 3,2 ha UR.

Prognozowanie oparte na teorii chaosu zdeterminowanego

W ostatnim dziesięcioleciu pojawiło się wiele opracowań prezentujących przykłady udanego wykorzystania teorii chaosu zdeterminowanego do prognozowania zapotrzebowania na energię elektryczną. Teoria chaosu zdeterminowanego bada nieregularne, nieuporządkowane zachowanie się układów deterministycznych. Do opisu struktur chaotycznych można wykorzystać fraktale. Są to obiekty, których dowolnie małe kawałki mają kształt podobny do całości. Własność ta nazywa się samopodobieństwem. Opisuje się ją za pomocą wymiaru fraktalnego. Analogicznie można określić procesy samopodobne przebiegające w czasie i dokonać ich predykcji wykorzystując modele oparte na wymiarze fraktalnym. Jeden z takich modeli wykorzystano do prognozy miesięcznego zużycia energii elektrycznej. Opisuje się go równaniem [Prognozowanie w elektroenergetyce... 2002]:

$$\hat{X}_{h+1}(t) = B_{t/t-1}^{\wedge}(h) \cdot X_{h+1}(t-1) \quad (1)$$

gdzie:

$$B_{t/t-1}^{\wedge}(h) = \frac{\sum_{j=h-k}^h X_j(t) \cdot X_j(t-1)}{\sum_{j=h-k}^h X_j^2(t-1)} \quad (2)$$

h – numer miesiąca,

t – numer roku,

$X_h(t)$ – zapotrzebowanie energii elektrycznej w t -tym roku i h -tym miesiącu,

$\hat{X}_{h+1}(t)$ – prognoza zapotrzebowania energii elektrycznej w t -tym roku i $(h+1)$ -tym miesiącu,

k – liczba wyników próbkowania.

Jest to model służący do predykcji wartości funkcji w chwili $h+1$, jeśli realizacje procesu w chwilach $h, \dots, h-k$ są znane. W przypadku prognozy na dłuższy okres czasu w miejsce wartości realizacji procesu trzeba podstawić do modelu wartości prognoz.

Prognozowanie za pomocą sztucznych sieci neuronowych

Spośród metod sztucznej inteligencji do prognozowania zapotrzebowania na energię elektryczną najczęściej wykorzystuje się sztuczne sieci neuronowe. Ich zaletą jest zdolność uogólniania wiedzy dla nowych danych, nieznanych wcześniej, a wadą brak zawarcia w nich obiektywnej wiedzy o badanym systemie w jawnej postaci.

W pracy do opisu miesięcznej sprzedaży energii elektrycznej wykorzystano sztuczną sieć neuronową o radialnych funkcjach bazowych typu gaussowskiego (GRBF) [Osowski 1996; Prognozowanie w elektroenergetyce... 2002]. Atrakcyjność sieci o radialnych funkcjach bazowych związana jest z szybkością uczenia. Jest to jednokierunkowa, nieliniowa sieć trójwarstwowa. Oprócz klasycznej warstwy wejściowej i liniowej warstwy wyjściowej, ma ona specyficzną warstwę ukrytą, w której występuje ściśle powiązanie aktywności neuronu z odpowiednim obszarem przestrzeni danych uczących. Za wartość odchylenia standardowego j -tej funkcji radialnej przyjęto odległość j -tego centrum od jego najbliższego sąsiada. Ze względu na małą liczebność zbioru danych, uczenie sieci przeprowadzono na pełnym zbiorze pomiarowym, stosując metodę gradientów sprzężonych. Do wyboru parametrów startowych wykorzystano metodę k -środków [Osowski 1996, Findeisen i in. 1977].

W celu doboru odpowiedniej struktury sieci stosowano zasadę konstruktywną [Piegat 1999] polegającą na rozpoczynaniu nauczania z małą liczbą neuronów i stopniowym ich powiększaniu. Procedurę tę kończono w momencie, gdy otrzymano zadowalającą wartość błędu i gdy w wyniku dalszego zwiększania liczby neuronów nie otrzymywano znaczącej poprawy modelu.

Prognozowanie w oparciu o teorię zbiorów rozmytych

W odróżnieniu od modeli neuronowych i modeli opartych na teorii chaosu zdeterminowanego, modele rozmyte nie są dotychczas w praktyce wykorzystywane do predykcji zapotrzebowania na energię elektryczną, chociaż teoria zbiorów rozmytych jest dogodnym narzędziem matematycznym pozwalającym opisać niepewność i niedokładność danych wejściowych, które nieodłącznie towarzyszą procesowi prognozowania.

Spośród spotykanych rozmytych modeli do celów prognostycznych najlepiej nadają się modelami z wnioskowaniem typu Takagi-Sugeno [Yager 1985, Piegat 1999]. Ich zaletą jest przekazywanie w jawnej postaci obiektywnej wiedzy o badanym systemie. Metoda wnioskowania stosowana w tych modelach jest związana z bazą reguł specjalnego formatu, który charakteryzuje się następującymi typami funkcyjnego:

$$\text{JEŚLI } (x_1 \text{ jest } A_{11}) \text{ I } \dots \text{ I } (x_r \text{ jest } A_{1r}) \text{ TO } (y_1 = a_{10} + a_{11}x_1 + \dots + a_{1r}x_r) \quad (3)$$

TAKŻE

...

TAKŻE

$$\text{JEŚLI } (x_1 \text{ jest } A_{m1}) \text{ I } \dots \text{ I } (x_r \text{ jest } A_{mr}) \text{ TO } (y_m = a_{m0} + a_{m1}x_1 + \dots + a_{mr}x_r)$$

przy czym A_{ij} ($i = 1, \dots, m; j = 1, \dots, r$) są zbiorami rozmytymi odniesienia na przestrzeniach wejściowych X_1, \dots, X_r , x_1, \dots, x_r , wartościami zmiennych wejściowych, natomiast a_{ij} współczynnikami funkcji liniowej.

Wyjście y systemu oblicza się za pomocą wzoru:

$$y = \sum_{i=1}^m \frac{\tau_i}{\sum_{j=1}^m \tau_j} (a_{i0} + a_{i1}x_1 + \dots + a_{ir}x_r) \quad (4)$$

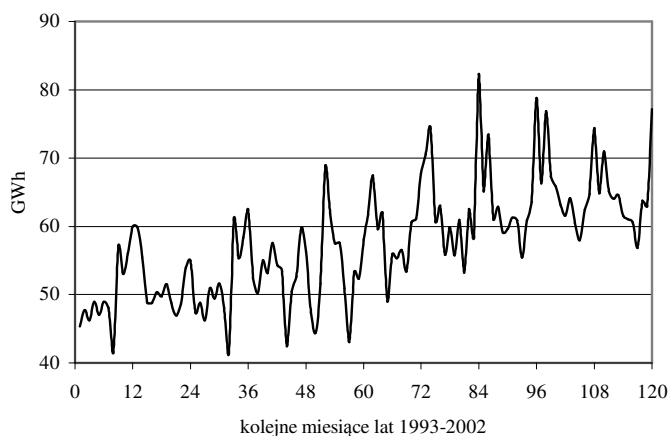
gdzie: $\tau_i = \mu_{A_{i1}}(x_1) \cdot \dots \cdot \mu_{A_{ir}}(x_{1r})$,

$\mu_{A_{i1}}, \dots, \mu_{A_{ir}}$ – funkcje przynależności zbiorów rozmytych odpowiednio A_{i1}, \dots, A_{ir} .

W geometrycznym ujęciu reguły wnioskowania Takagi-Sugeno odpowiadają przybliżaniu odwzorowania $X_1 \times \dots \times X_r \rightarrow Y$ za pomocą funkcji odcinkami liniowej, z tym że podział przestrzeni wejściowej na zbiory rozmyte umożliwia gładkie przechodzenie między poszczególnymi funkcjami liniowymi. W tych strefach wejść, gdzie stopnie przynależności do poszczególnych zbiorów A_{ij} spełniają warunek $\mu_{A_{ij}}(x_j) = 1$, współczynniki a_{ij} mają taką samą interpretację, jak w przypadku modelu regresji liniowej wielokrotnej. Parametry modelu należy tak wyznaczyć, aby jego sumaryczny błąd kwadratowy był minimalny. W tym celu zastosowano w pracy metodę gradientów sprzężonych [Osowski 1996, Findeisen i in. 1977].


WYNIKI

Przebieg miesięcznej sprzedaży energii elektrycznej w latach 1993–2002 przez wybraną spółkę dystrybucyjną wiejskim odbiorcom przedstawiono na rysunku 1. Spo-




Rys. 1. Przebieg miesięcznej sprzedaży energii elektrycznej odbiorcom wiejskim w latach 1993–2002 przez wybraną spółkę dystrybucyjną

Fig. 1. The course of electric energy monthly sales to rural customers in 1993-2002 by chosen distribution company

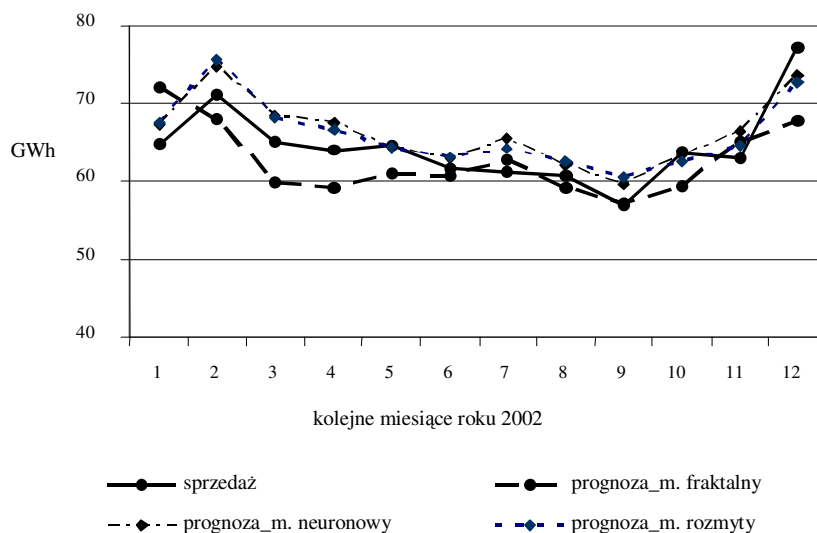


Rys. 2. Struktura sieci GRBF
Fig. 2. Structure of GRBF net



JEŚLI $(x_{h-1} = A_{11})$ I $(x_{h-12} = A_{21})$ TO $(x_h = 23,73 - 0,114x_{h-1} + 0,677x_{h-12})$
 JEŚLI $(x_{h-1} = A_{11})$ I $(x_{h-12} = A_{22})$ TO $(x_h = -137,53 + 1,201x_{h-1} + 2,084x_{h-12})$
 JEŚLI $(x_{h-1} = A_{12})$ I $(x_{h-12} = A_{21})$ TO $(x_h = 40,63 + 0,386x_{h-1} - 0,124x_{h-12})$
 JEŚLI $(x_{h-1} = A_{12})$ I $(x_{h-12} = A_{22})$ TO $(x_h = 45,88 - 0,161x_{h-1} + 0,516x_{h-12})$

Rys. 3. Przebiegi funkcji przynależności i baza reguł dla rozmytego modelu
Fig. 3. The courses of attachment functions and the base of rules for the fuzzy model



Rys. 4. Sprzedaż i prognozy sprzedaży energii elektrycznej odbiorcom wiejskim w roku 2002
 Fig. 4. The sale and forecasts of electric energy sales to rural customers in the year 2002

śród uzyskanych od spółki 120 danych, 12 ostatnich użyto do sprawdzenia trafności prognoz wyznaczonych na podstawie danych dotyczących wcześniejszej sprzedaży energii elektrycznej.

Wykorzystując model oparty na wymiarze fraktalnym sporządzono prognozy sprzedaży energii elektrycznej dla poszczególnych miesięcy 2002 roku (rys. 4). Wyznaczono je, wykorzystując wyliczoną dla każdego miesiąca średnią wartość z okresu ostatnich ośmiu lat, a ciąg uczący objął dziewiętnaście miesięcy: od czerwca 2000 do grudnia 2001 r.

Stosując sieci neuronowe do celów prognostycznych, wyznaczono sieć typu GRBF posiadającą dwa neurony na wejściu, trzy neurony w warstwie ukrytej i jeden neuron na wyjściu. Strukturę tej sieci przedstawia rysunek 2. Wyliczone tą metodą prognozy miesięcznej sprzedaży energii elektrycznej w roku 2002 przedstawiono na rysunku 4.

Ze względu na charakter zmienności miesięcznego zapotrzebowania na energię elektryczną (rys. 1), w pracy budowano modele rozmyte opisujące zależność funkcyjną $x_h = f(x_{h-1}, x_{h-12})$, gdzie x_h jest zużyciem energii elektrycznej w h -tym miesiącu, a zatem rozpatrywano modele systemów z dwoma rozmytymi wejściami X_1 i X_2 oraz jednym rozmytym wyjściem Y [Piegat 1999]. Każdy ze zbiorów X_1 i X_2 , które są domkniętymi przedziałami, został podzielony na dwa podzbiory rozmyte o trapezowych funkcjach przynależności, spełniających warunek podziału jedności. Wcześniejsze badania przeprowadzone przez autorów wykazały bowiem, że przyjęcie większej liczby podzbiorów nie poprawia jakości prognoz, a znacznie utrudnia przeprowadzenie optymalizacji.

W pracy przyjęto $X_1 = X_2 = [41,61;82,22]$ i otrzymano funkcje przynależności oraz bazę reguł, które przedstawiono na rysunku 3. Wyliczone na podstawie opracowanego rozmytego modelu prognozy sprzedaży energii elektrycznej w poszczególnych miesiącach 2002 roku pokazano na rysunku 4.

Tabela 1. Porównanie trafności prognoz miesięcznej sprzedaży energii elektrycznej wyznaczonych na podstawie modeli zbudowanych według metody sztucznej inteligencji
Table 1. The comparison of quality of prognoses of electric energy monthly sales on the basis of the models which were built in support of artificial intelligence methods

Model prognostyczny Forecasting model	Średni błąd prognoz ex post dla 2002 roku, % Average error of forecasts ex post for 2002 year, %
Model fraktalny Fractal model	5,54
Model neuronowy Neural model	3,93
Model rozmyty Fuzzy model	3,89

Aby ułatwić użytkownikowi wybór modelu, wyliczono według opracowanych modeli, średnie absolutne względne błędy prognoz ex post dla roku 2002, które zawiera tabela 1.

PODSUMOWANIE

Przeprowadzone obliczenia potwierdziły dużą przydatność sztucznych sieci neuronowych do prognozowania zapotrzebowania na energię elektryczną, a w szczególności miesięcznej sprzedaży energii elektrycznej odbiorcom wiejskim. Nie mniejszą trafnością niż prognozy wyznaczone według modelu neuronowego charakteryzują się prognozy określone na podstawie rozmytego modelu z wnioskowaniem typu Takagi-Sugeno. Średnie absolutne błędy prognoz ex post, będące miarą ich trafności, w obu tych przypadkach były rzędu 3,9%.

Przydatność modeli TAKAGI-SUGENO wydaje się więc być konkurencyjna w stosunku do modeli neuronowych i godna polecenia do zastosowania w celach predykcyjnych.

PIŚMIENNICTWO

- Findeisen W., Szymanowski J., Wierzbicki A., 1977. Teoria i metody obliczeniowe optymalizacji. WNT Warszawa.
- Osowski S., 1996. Sieci neuronowe w ujęciu algorytmicznym. WNT Warszawa.
- Piegat A., 1999. Modelowanie i sterowanie rozmyte. AOW EXIT Warszawa.
- Prognozowanie w elektroenergetyce. Zagadnienia wybrane. Red. I. Dobrzańska. 2002. Wyd. Pol. Częstoch., Częstochowa.
- Yager R. R., Filev D. P., 1995. Podstawy modelowania i sterowania rozmytego. WNT Warszawa.

**APPLICATION OF ARTIFICIAL INTELLIGENCE METHODS
TO FORECAST ELECTRIC ENERGY MONTHLY SALES IN RURAL AREAS**

Abstract. In this paper the possibilities of application artificial intelligence to forecast electric energy monthly sales to rural receivers were presented. There were three models which were built on the basis of determinate chaos theory, artificial neural networks and fuzzy set theory. Calculations proved that artificial neural networks are good enough to forecast the demand for the supplies of electricity. Fuzzy Takagi-Sugeno model is competitive in comparison with neural model and worth recommending to forecasting.

Keywords: electric energy, forecast, chaos theory, neural networks, fuzzy sets

Zaakceptowano do druku – Accepted for print: 3.11.2004