

*Jędrzej Trajer, Krzysztof Kozłowski
Katedra Podstaw Inżynierii
Szkoła Główna Gospodarstwa Wiejskiego w Warszawie*

NEURONOWY MODEL PROGNOZOWANIA DZIENNEGO NAPROMIENIENIA SŁONECZNEGO

Streszczenie

W pracy przedstawiono neuronowy model prognozowania dobowych sum napromienienia słonecznego. Opracowanie stanowi kontynuację projektu prognoz długo, średnio i krótkoterminowych, w którym niezadowalający okazał się model prognoz dobowych. W ulepszonym obecnie modelu poprawiono jego skuteczność uwzględniając dodatkowe czynniki dotyczące zachmurzenia.

Słowa kluczowe: prognozowanie, sieci neuronowe, dzienne nasłonecznienie

Wprowadzenie

Opracowany kaskadowy model neuronowy prognoz napromienienia słonecznego [Trajer, Czekalski 2004] wykazywał niedostateczną skuteczność prognoz krótkoterminowych. Stwierdzono, iż ulepszenia wymaga etap prognozy sum dobowych i w tym zakresie podjęto próbę ulepszenia tego modelu. Modyfikacja modelu polegała na przeprowadzeniu analiz co do wpływu innych czynników istotnych na przebieg zjawiska wraz z korektą struktury modelu. Analiza wykazała że podstawowym czynnikiem determinującym efekty cieplne eksploatacji systemów słonecznych jest zachmurzenie. Potwierdzają to dane literaturowe [Boland i in. 2001], [Becker 2001], [Kasten 1980], w których to pracach wykazano, że przezroczystość atmosfery stanowi podstawowy czynnik determinujący sumę napromienienia słonecznego. O ważności tego czynnika może też świadczyć fakt opracowania specjalnej mapy indeksu przezroczystości nieba w Europie dla potrzeb wyznaczania napromienienia słonecznego [Bayer i in. 1997]. W dotychczas opracowanych modelach sum napromienienia słonecznego różni autorzy np. [Richardson i in. 2002], [Boland i in. 2001] uwzględniają też inne czynniki, takie jak temperatura i wilgotność powietrza, czy kąt padania promieniowania słonecznego na płaszczyznę. W prezentowanej pracy pominięto wpływ tych czynników ze względu na braki w danych. Dotychczas przedstawiane w literaturze modele obliczeń napromienienia

słonecznego są w większości modelami matematycznymi z elementami obliczeń statystycznych, choć też zaczynają pojawiać się modele wykorzystujące metody sztucznej inteligencji np. model oparty o system ekspertowy [Bellocchi 2002]. Autorzy nie znaleźli modelu prognozowania napromienienia słonecznego z wykorzystaniem sztucznych sieci neuronowych, stąd uzasadnienie jego opracowania.

Cel, zakres i metoda pracy

Bazę danych stanowiły wyniki pomiarów napromienienia całkowitego płaszczyzny nachylonej pod optymalnym kątem z lat 1995 – 2000 na stanowisku Katedry Podstaw Inżynierii – SGGW na Ursynowie. Pomiary napromienienia wykonywano w sposób ciągły, początkowo z rejestracją wartości chwilowych. Następnie wyniki uśredniano w obrębie jednej godziny i zapisywano do pamięci stałej w jednostkach [kWh/m²]. Uwzględniono także średnie dobowe zachmurzenie zebrane przez Instytut Meteorologii i Gospodarki Wodnej z lat 1995 - 2000. Zachmurzenie oceniono w przyjętej przez IMiGW skali 0-8. Do budowy neuronowego modelu prognostycznego zastosowano sieci typu perceptron wielowarstwowy (MLP) i wykorzystano oprogramowanie *Statistica Neural Networks*. Metodykę tworzenia sieci neuronowych i ich ocenę przyjęto według ogólnych zasad przedstawianych w literaturze [Osowski 1996], [Tadeusiewicz 1993], [Trajer 2005].

Wyniki badań i ich analiza

Najlepiej prognozującą okazała się sieć neuronowa o architekturze 5:4:1. W modelu tym za dane wejściowe przyjęto numer dnia roku, sumy napromienienia z dób poprzedzających prognozę pierwszej D1 i drugiej D2, wynik prognozy dekadowej [Trajer, Czekalski 2004] oraz średnią dobową prognozę zachmurzenia. Jakość uczenia modelu oceniano za pomocą statystyk regresyjnych. Uzyskane wartości współczynnika korelacji 0,92 i ilorazu odchylenia błędu 0,39 świadczą o stosunkowo dobrej jakości modelu ze względu na dane uczące. Weryfikację modelu przeprowadzono na zbiorze danych testujących, które nie były używane w procesie uczenia - zbiór ten obejmował dane z 365 dni. Za parametr oceny modelu przyjęto globalny względny błąd aproksymacji $\delta(D)_{gl}$:

$$\delta(D)_{gl} = \sqrt{\frac{\sum_{i=1}^n (y_i - d_i)^2}{\sum_{i=1}^n y_i^2}} \cdot 100 \quad \%$$

gdzie:

n – liczba dni,


y, d – odpowiednio wartości rzeczywistych i prognozowanych okresowych sum dobowego napromienienia.

Średni globalny błąd względny dla całego roku wyniósł 23,2%. W tabeli 1 podano ocenę procentową prognoz w postaci wielkości globalnych błędów względnych obliczanych dla okresów miesięcznych, a na rysunku 1 ich wartości w postaci bezwymiarowej.

Tabela 1. Względny procentowy błąd prognoz miesięcznych

Table 1. Relative percentage error of monthly prediction

Czas	I	II	III	IV	V	VI	VII	VIII	IX	X	XI	XII
δ [%]	43,9	53,9	28,5	21,5	19,1	15,2	22,1	20,0	27,1	31,8	42,8	49,1




Rys. 1. Względny błąd prognoz miesięcznych

Fig.1. Relative error of monthly prediction

Na rysunku 2 zilustrowano zakres tych błędów wyrażonych w jednostkach napromienienia słonecznego [kWh/m^2] w stosunku do minimalnego średniego miesięcznego napromienienia.

Wyniki tej weryfikacji wskazują na zadawalające rezultaty, jeśli weźmie się pod uwagę bezwzględny zakres zmian napromienienia słonecznego wywołany zachmurzeniem w funkcji czasu. Prognozowane zjawisko jest typu deterministycznego (najistotniejsze są położenie geograficzne, kąt padania promieniowania słonecznego i dzień roku) z dużym wpływem zakłóceń (jak wykazano zachmurzenie ma tu znaczący wpływ na prognozowaną wielkość).



Rys. 2. Ocena efektywności miesięcznych prognoz napromienienia słonecznego [kWh/m²]

Fig. 2. Effectiveness valuation of monthly prediction of solar radiation

Podsumowanie

Model uwzględniający wartość prognozy zachmurzenia na zadany dzień poprawia średni błąd prognozy z otrzymanego wcześniej modelu z 41,8 % na 23,2 % w skali roku. Po wyznaczeniu błędów dla poszczególnych miesięcy okazało się, że błąd zawiera się pomiędzy 15,2% (w lecie) a 53,9% (w zimie). Najlepsze prognozy (poniżej 20% błędu) otrzymujemy dla miesięcy letnich - maj-sierpień, natomiast dla miesięcy zimowych (listopad – luty) – błąd przekracza 40 %. Model można próbować udoskonalić badając wpływ innych czynników na wielkość prognozowaną, np. temperaturę i wilgotność powietrza atmosferycznego. Należy pamiętać, że użyte dane dotyczące promieniowania słonecznego i prognozy zachmurzenia muszą dotyczyć badanego obszaru.

Literatura

Beyer H. G., Czeplak G., Terzenbach U. and Wald L. 1997. Assessment of the method used to construct clearness index maps for the new European solar radiation atlas (ESRA). *Solar Energy* 61.

Becker S. 2001. Calculation of direct solar and diffuse radiation in Israel. *International Journal of Climatology*, 21.

Boland J., Scott L., Luther M. 2001. *Modelling the diffuse fraction of global solar radiation on a horizontal surface*. *Environmetrics*, 12 (2).

Bzowska D., Kossecka E. 1993. Analiza promieniowania słonecznego w Warszawie w aspekcie energetyki słonecznej. IPPT PAN, Wydawnictwo Spółdzielcze sp. z o.o. 4/1993, Warszawa.

Kasten F and Czeplak G 1980 Solar and terrestrial radiation dependent on the amount and type of cloud. *Solar Energy* 24.

Osowski S. 1996. Sieci neuronowe w ujęciu algorytmicznym. Wydawnictwo Naukowo-Techniczne, Warszawa.

Richardson A.G., Reddy K.R., Boone M.L. 2002. Prediction of solar radiation from air temperature. *ISHS Acta Horticulturae* 593: IV International Symposium on Models for Plant Growth and Control in Greenhouses: Modeling for the 21st Century - Agronomic and Greenhouse Crop Models.

Tadeusiewicz R. 1993. Sieci neuronowe, Akademicka Oficyna Wydawnicza RM, Warszawa.

Trajer J., Czekalski D. 2005. Prognozowanie sum napromienienia słonecznego dla potrzeb energetyki lokalnej. *Inżynieria Rolnicza*, 8(68), Kraków.

Trajer J. 2005. Sztuczne sieci neuronowe w modelowaniu procesów z ograniczonym zbiorem danych w inżynierii rolniczej. *Inżynieria Rolnicza*, 2(62).

THE NEURALS MODEL OF DAILY PREDICTION OF SOLAR RADIATION

Summary

The neural model of daily prediction of solar radiation are presenting. The method of prediction solar radiation was worked out with cloudiness influence. The results of six years solar radiation measurements, conducted at SGGW-Ursynów station on tilted surface oriented south and data cloudiness, were used as database. The neuronal model was worked out, in which short-term prognoses use results from medium-term model and cloudiness. Model has been veried.

Key words: prediction, artificial neural network, value of daily solar radiation