

SIECI NEURONOWE JAKO NARZĘDZIE UMOŻLIWIJAjące PROGNOZOWANIE ZAPOTRZEBOWANIA NA WODĘ W UPRAWACH ROLNYCH

Maciej Neugebauer, Krzysztof Nalepa, Piotr Sołowiej

Katedra Elektrotechniki i Energetyki, Uniwersytet Warmińsko-Mazurski w Olsztynie

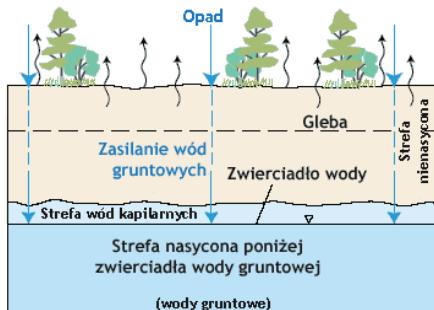
Streszczenie. W pracy przedstawiono możliwości wykorzystania modelowania neuronowego w celu wyznaczenia momentu w którym należy rozpoczęć nawadnianie upraw. Właściwy moment rozpoczęcia nawadniania umożliwia uniknięcie przesuszenia roślin, a jednocześnie pozwala na bardziej efektywne wykorzystanie systemów nawadniających uprawy (np. deszczowni). Jako dane wejściowe w modelowaniu neuronowym przyjęto dane charakteryzujące poszczególne uprawy – gatunek, okres wegetacji, rodzaj gleby, położenie względem najbliższych zbiorników wód powierzchniowych oraz prognozy siedmiodniowe dotyczące opadów na danym terenie.

Slowa kluczowe: sieci neuronowe, prognozowanie, nawadnianie pól, opady deszczu

Wprowadzenie

Długoterminowe prognozy ilości opadów dla Polski nie są korzystne. Już teraz widać, na podstawie danych meteorologicznych, że suma opadów w kraju w poszczególnych latach jest coraz niższa. Również tegoroczna wiosna (wg IMGW) charakteryzuje się niższą ilością opadów niż lata poprzednie. Zjawisko to potęguje narastanie suszy hydrologicznej [Sasim, Mierkiewicz 2005]. Wpływa to niekorzystnie na poziom wód gruntowych i powierzchniowych, na rysunku 1 i 2 przedstawiono budowę gleby z uwzględnieniem obiegu wód gruntowych.

Ponieważ uprawy rolnicze wymagają wody, coraz częstsze jest stosowanie deszczowni w celu utrzymania plonów na wysokim poziomie, zapewniającym opłacalność produkcji rolnej. Rozpoczęcie nawadniania, zanim jeszcze nastąpi przesuszenie roślin – z uwzględnieniem różnego zapotrzebowania na wodę w zależności od fazy rozwoju, gatunku, warunków geologiczno-geograficznych – umożliwia zapobieżenie przesuszenia roślin. Minimalizacja kosztów produkcji wymaga, aby w gospodarstwie było jak najmniej deszczowni – wykorzystywanych jednak bardzo intensywnie co pozwala zmniejszyć koszty jednostkowe eksploatacji.



Rys. 1. Obieg wody w glebie.
Fig 1. Water circulation in soil



Rys. 2. Poziomy wód gruntowych w zależności od czasu przenikania wody
Fig 2. Ground water level in depend on time of penetration

źródło: <http://ga.water.usgs.gov/edu/watercyclepolish.html>

Sformułowanie problemu

W celu umożliwienia zmniejszania skutków niedoboru wody w uprawach rolnych należy z wyprzedzeniem planować wykorzystanie deszczowni w zależności od typu uprawy, warunków pogodowych i położenia pola.

Problem nawadniania upraw jest analizowany różnymi metodami, szczególnie w kontekście coraz większego deficytu wody. Według obliczeń [Grochalski 2003] do produkcji 1 t pszenicy o wartości około 200 USD trzeba zużyć 1000 l wody. Problem ten jest analizowany w różnych krajach – np. Berbel, Gomez-Limon [2000] w Hiszpanii a Weatherhead, Knox [2000] w Anglii i Walii. Wpływ systemów nawadniania na wysokość plonów kukurydzy badali Bergez, Nolleau [2003].

Sztuczne Sieci Neuronowe (SSN) są narzędziem stosowanym do modelowania trendu i zmienności sezonowej różnych wielkości, także do prognozowania wystąpienia określonych czynników czy zjawisk w określonym czasie [np.: Boniecki, Weres 2003; Boniecki 2004; Bielińska 2002; Brandt 1999; Migdał-Najman Najman 2000; Lee i in. 1996; Yasdi 1999] a więc możliwe jest również prognozowanie ilości opadów w poszczególnych dniach i tygodniach roku.

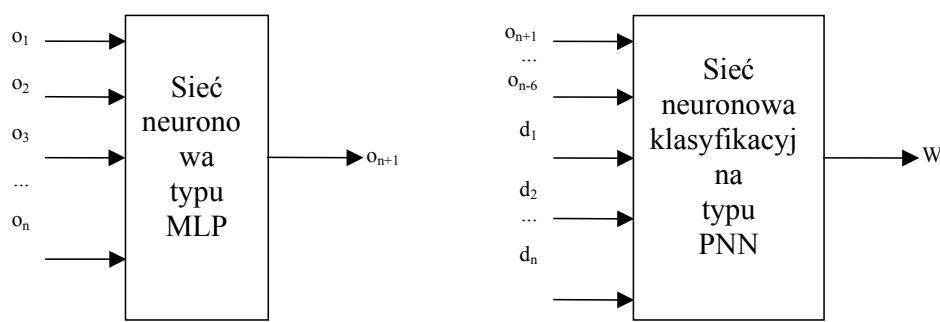
W celu określenia momentu w którym należy rozpocząć nawadnianie danej uprawy postanowiono wykorzystać (SSN), badanie możliwości wykorzystania SSN w celu prognozowania zmian wydajności źródeł wody przedstawiona jest w Maier, Dandy [2000].

W tym celu należy najpierw zidentyfikować czynniki wpływające na możliwość przesuszenia roślin oraz zebrać dla nich dane liczbowe, które pozwolą stworzyć i wyuczyć SSN tak, aby na podstawie jej prognozy można było odpowiednio wcześnie rozpoczęć proces nawadniania pól – jeszcze przed wystąpieniem przesuszenia roślin.

Modelowanie neuronowe

Do czynników określających właściwy czas rozpoczęcia nawadniania (na danym obszarze) można zaliczyć: poziom wód gruntowych, odległość od zbiorników wód powierzchniowych, rodzaj uprawy, okres wegetacji, typ gleby, sumę dotychczasowych opadów na badanym obszarze, dane dotyczące opadów z lat poprzednich (w celu stworzenia prognozy opadów).

Do rozwiązania postawionego zadania użyto programu Statistica w którym utworzono zespół SSN pokazanych na rysunku 3. Zgodnie z literaturą, do modelowania i predykcji złożonych zjawisk lepiej nadają się zespoły SSN [np. Nguyen, Chan 2004; Zhang i in. 1997]



Rys. 3. Rysunek przedstawiający zastosowany zespół SSN. Opis w tekście
Fig. 3. Illustration demonstrated used of group of SSN. Description in text

Pierwszym blokiem zastosowanego zespołu sieci – jest perceptron wielowarstwowy (MLP) zastosowany jako sieć prognozująca szereg czasowy opadów w danym rejonie. Wykorzystanie różnych sieci neuronowych do prognozowania opadów deszczu opisują [np.: Luk i in. 2001; Trafalas i in. 2005] Dane wejściowe $o_1 - o_n$ to dobowe sumy opadów (dla n dni), dana wyjściowa o_{n+1} to prognozowana wielkość opadów na kolejny dzień. Tak uzyskane dane są następnie przetwarzane przez probabilistyczną sieć klasyfikacyjną. Wejścia sieci $o_{n+1} - o_{n-6}$ to dane dotyczące opadów dla kolejnych siedmiu dni, dane $d_1 - d_n$ to informacje dotyczące samej uprawy tj.:

- rodzaj uprawy;
- położenie uprawy;
- rodzaj gleby.

Wyjście sieci W to dana dyskretna, przyjmująca wartość 0 lub 1 gdzie 0 oznacza, że nie trzeba podlewać w dniu $n+1$, 1 trzeba podlewać. Cykl ten powtarza się aż do dnia $n+7$ (czyli uzyskujemy tygodniową prognozę dla każdej analizowanej uprawy), lub też do użycia na wyjściu wartości 1.

Ponieważ dane dotyczące opadów dla danego obszaru pozostają niezmienione, więc analizy dla kolejnych upraw na tym obszarze ograniczają się tylko do wykorzystania sieci klasycznego.

W badaniach przyjęto $n = 14$, sieć MLP z jedną warstwą ukrytą w trzech wariantach: o 10, 14 i 18 neuronach w warstwie ukrytej oraz z sigmoidalną funkcją aktywacji. Sieć klasyczna ma 10 wejść i jedno wyjście, liczbę warstw ukrytych wraz z liczbą neuronów program dobrał samodzielnie (jedna warstwa ukryta o takiej samej liczbie neuronów co w warstwie wejściowej).

Dane dotyczące opadów zostały uzyskane z olsztyńskiego stanowiska IMGW oraz z badań własnych (stacja meteorologiczna Vantage PRO). Dane dotyczą opadów za okres 04-07.2004 oraz 04-07.2005. W celu zwiększenia liczby danych oraz wychwycenia trendu zmian w rozkładzie opadów w poszczególnych okresach roku, wyliczono wartości średnie dla poszczególnych dni uzyskując trzeci zbiór danych 04-07. średnie 04/05 (3 razy po 122 dni).

Dane dotyczące upraw oraz położenie pól, zostały zebrane w badaniach ankietowych oraz literaturowych, w danych tych zawarte były informacje dotyczące;

- d_1 – rodzaj uprawy (zapotrzebowanie roślin na wodę w sakli od 1 do 4);
- d_2 – okres wegetacji (miesiąc roku);
- d_3 – położenie pola (wysokość) względem najbliższego zbiornika wód powierzchniowych w metrach;
- d_4 – rodzaj gleby – w zależności od przepuszczalności – 1 słabo przepuszczalna (glinista) – 4 dobrze przepuszczalna (lekka).

Podsumowanie

1. Wyniki uzyskanych symulacji dla zbioru testowego dają od 61 do 76% zgodności trafiń w zależności od wariantu sieci prognozującej szereg czasowy.
2. Dobór odpowiedniej architektury sieci neuronowej, zebrane właściwie dane w odpowiedniej liczbie umożliwiają uzyskanie na wyjściu SSN informacji dotyczących, kolejności, czasu i intensywności podlewania poszczególnych upraw i pól, tak aby koszty użytkowania deszczowni były najniższe a plony uzyskane z upraw możliwie największe.
3. W celu zmniejszenia błędu prognozowania można odrzucić moduł prognozujący (wpływa najbardziej znacząco na wielkość błędu) – a wykorzystać sieć neuronową klasyczną przy założeniu, że w ogóle nie będzie padać – na wyjściu sieci odpowiedź po ilu dniach należy rozpocząć podlewanie.
4. Pamiętać trzeba jeszcze tylko o jednej rzeczy, w przypadku wystąpienia suszy hydrologicznej, intensywne wykorzystywanie wód powierzchniowych w celu zasilania deszczowni, może jeszcze bardziej pogłębić skutki suszy powodując obniżenie poziomu wód gruntowych.

Bibliografia

- Berbel J. Gomez-Limon J. A.** 2000. The impact of water-pricing policy in Spain: an analysis of three irrigated areas. Agricultural Water Management 43(2000). s. 219-238.
- Bergez J. E. Nolleau S.** 2003. Maize grain yield variability between irrigation stands: a theoretical study. Agricultural Water Management 60(2003). s. 43-57.
- Bielińska E.** 2002. Metody prognozowania. Wyd. Śląsk. Katowice. ISBN 83-7164-349-7.
- Boniecki P. Weres J.** 2003. Wykorzystanie technik neuronowych do predykcji wielkości zbiorów wybranych płodów rolnych. Journal of Research and Applications in Agricultural Engineering 48(4). s. 56-59.
- Boniecki P.** 2004. Sieci neuronowe typu *MLP* oraz *RBF* jako komplementarne modele aproksymacyjne w procesie predykcji plonu pszenicy. Journal of Research and Applications in Agricultural Engineering 1(2004). s. 28-34.
- Brandt S.** 1999. Analiza danych, metody statystyczne i obliczeniowe. Wydawnictwo Naukowe PWN. Warszawa. ISBN 83-01-12986-7.
- Grochalski S.M. (red.)** 2003. Problemy globalne współczesnego świata. Wydawnictwo Uniwersytetu Opolskiego.
- Lee K.C. Han I., Kwon Y.** 1996. Hybrid neural network models for bankruptcy predictions. Decision Support Systems 18(1996). s. 63-72.
- Luk K.C. Ball J.E. Sharma A.** 2001. An Application of Artificial Neural Networks for Rainfall Forecasting. Mathematical and Computer Modelling 33(2001). s. 683-693.
- Maier H.R. Dandy G.C.** 2000. Neural networks for the prediction and forecasting of water resources variables: a review of modelling issues and applications. Environmental Modelling & Software 15(2000). s. 101-124.
- Migdal-Najman K. Najman K.** 2000. Sieci neuronowe wykorzystane do prognozowania WIG. Profesjonalny Inwestor 8/2000. s. 10-18.
- Nguyen H.H. Chan C.W.** 2004. Multiple neural networks form a long term time series forecast. Neural Computing&Applications 13(2004). s. 90-98.
- Sasim M., Mierkiewicz M.** 2005. Susza w 2003 roku. Gazeta obserwatora IMGW nr 1. s. 37-38.
- Trafalis T.B., Santosa B., Richman M.B.** 2005. Learning networks in rainfall estimation. Computational Management Science 2(2005). s. 229-251.
- Weatherhead E.K., Knox J.W.** 2000. Predicting and mapping the future demand for irrigation water in England and Wales. Agricultural Water Management 43(2000). s. 203-218.
- Yasdi R.** 1999. Prediction of Road Traffic using a Neural Network Approach. Neural Computing&Applications 8(1999). s. 135-142.
- Zhang M. Fulcher J. Scofield R.A.** 1997. Rainfall estimation using artificial network group. Neurocomputing 16(1997). s. 97-115.

NEURAL NETWORK AS A TOOL ENABLING PREDICTION OF WATER DEMAND IN AGRICULTURE

Summary. The paper presents the enable of neural network modeling for the purpose to find the start point of water the fields. The right moment of start the water the fields enable avoided dry up the plants, and at the same time allow on the more efficient using of irrigated systems (for example water-butt). As input date in neural network modelling was taken the date which characterize each cultivation – kind, phase of vegetation, kind of soil, location with regard to nearest water reservoir and seven-days rain forecast.

Key words: neural networks, prediction, field irrigation, rainfall

Adres do korespondencji:

Maciej Neugebauer; e-mail: mak@uwm.edu.pl
Katedra Elektrotechniki i Energetyki
Uniwersytet Warmińsko-Mazurski w Olsztynie
ul. Oczapowskiego 11
10-736 Olsztyn