

PRZYKŁADY WYKORZYSTANIA MODELOWANIA NEURONOWEGO W PRAKTYCE ROLNICZEJ

Streszczenie

Sztuczne sieci neuronowe, ze względów technicznych, są uproszczonym symulatorem pracy ludzkiego mózgu reprezentując niektóre jego cechy. Potrafią się uczyć, są mało wrażliwe na niekompletną informację wejściową, przetwarzają wprowadzone sygnały i podają na wyjściu wyniki w czasie rzeczywistym. Wspomniane właściwości pozwalają przypuszczać, że SNN mogą wykonać zadanie identyfikacji oraz prognozowania podobnie jak czyni to człowiek. Dzięki komputerowej automatyzacji procesu identyfikacji udaje się częściowo wyeliminować czynnik ludzki i tym samym ograniczyć element subiektywizmu oceny. Zdolności klasyfikacyjne oraz predykcyjne sztucznych sieci neuronowych stanowią jeden z głównych obszarów ich zastosowania. Praca miała na celu prezentację kilku przykładów praktycznego wykorzystania tych właściwości do modelowania wybranych problemów klasyfikacyjnych i predykcyjnych występujących w rolnictwie.

Słowa kluczowe: modelowanie neuronowe; klasyfikatory neuronowe; instrumenty predykcyjne

Wprowadzenie

Sztuczne sieci neuronowe znajdują coraz częściej zastosowanie w szeroko rozumianej praktyce rolniczej oraz ogrodniczej [1, 2, 4, 7]. Ich uznane i coraz bardziej doceniane własności, szczególnie w zakresie klasyfikacji oraz predykcji, służą m.in. do konstruowania neuronowych systemów ekspertowych wspomagających szeroko rozumianą produkcję rolniczą [3, 14]. Aplikacje te, pracując w czasie rzeczywistym, efektywnie wspierają procesy decyzyjne zachodzące w wielu obszarach rolnictwa [5, 15]. Zaowocowało to nawet pojawieniem się pierwszych urządzeń i maszyn rolniczych, które efektywnie wykorzystują metody sztucznej inteligencji, a zatem nie wymagających ciągłego nadzoru oraz obsługi. Należy jednak zaznaczyć, że są to dopiero początki wykorzystania modeli neuronowych w tej dziedzinie. Poniżej przedstawiono kilka wybranych projektów wykorzystujących zaawansowane techniki przetwarzania neuronowego, mających za zadanie wspomaganie procesów decyzyjnych zachodzących w praktyce rolniczej.

Modele klasyfikacyjne

Jedną z podstawowych właściwości sztucznych sieci neuronowych są ich umiejętności klasyfikacyjne [4, 2, 15]. Zdolność sieci neuronowych do klasyfikacji może być wykorzystana w wielu obszarach rolnictwa [2, 3, 5]. W szczególności może zaowocować w przyszłości inteligentnymi systemami identyfikacyjnymi. W oparciu o neuronową technikę analizy i rozpoznawania obrazu, maszyna może wykonywać różne prace w rolnictwie bez ingerencji człowieka.


- System informatyczny „ObrazKoh” do identyfikacji wybranych szkodników sadów

W ramach prac prowadzonych w Instytucie Inżynierii Biosystemów Uniwersytetu Przyrodniczego w Poznaniu powstał system informatyczny „ObrazKoh” przeznaczony do identyfikacji wybranych szkodników sadów owocowych [6,8,9]. Celem prowadzonych prac było zaprojektowanie, wykonanie i przetestowanie systemu informatycznego, w którego strukturze podstawowym elementem była wytworzona sieć neuronowa typu Kohonena. Zbudowany system informatyczny przeznaczony był do bezwzorcowej identyfikacji 5

wybranych szkodników drzew owocowych żerujących w sadach, dokonywanej wyłącznie w oparciu o informacje graficzną w formie zdjęć cyfrowych agrofagów. Było to 5 następujących szkodników [11, 13]:

- 1 - Misecznik śliwowy (parthenolecanium corni Bouche).
- 2 - Pruszczarek gruszowiec (Dasyneura piri Bonche).
- 3 - Pruszczarek jabłoniak (Dasyneura mali Kieff).
- 4 - Trociniarka torzyśniad (Zeuzera pyrina L.).
- 5 - Trociniarka czerwica (Cossus cossus L.).


Wymienione agrofagi przedstawiono na rys. 1.



Rys. 1. Pięć wybranych szkodników sadów
Fig. 1. Five chosen pests of orchards

Jako reprezentatywną cechę klasyfikacyjną przyjęto barwę szkodników, zakodowaną zgodnie z modelem koloru RGB (Red, Green, Blue). W celu wytworzenia zbiorów uczących niezbędnych do uczenia modeli neuronowych zaprojektowano i zbudowano pomocnicze narzędzie dygitalizujące obrazy szkodników (występujące w postaci bitmap) i transformujące je do postaci akceptowalnej przez symulator sztucznych sieci neuronowych. Sieć Kohonena została wygenerowana techniką „bez nauczyciela” z wykorzystaniem modułu „Sieci neuronowe” zaimplementowanego w komercyjnym pakiecie Statistica. Kod nauczzonej sieci został „wyekstrahowany” ze środowiska Statistica (za pomocą dostępnej opcji „Generator kodu”) i zaimplementowany w oryginalnej aplikacji „ObrazKoh”.

Rozpoznawanie szkodnika odbywało się na podstawie neuronowej identyfikacji zaznaczonego fragmentu obrazu (rys. 2).



Rys. 2. Interfejs systemu „ObrazKoh”
Fig. 2. Interface of „ObrazKoh” system

- System informatyczny „Szkodniki” do identyfikacji wybranych szkodników zbóż

Również w ramach projektu realizowanego w Instytucie Inżynierii Biosystemów Uniwersytetu Przyrodniczego w Poznaniu powstał system informatyczny „Szkodniki” dedykowany jako wsparcie procesu identyfikacji 3 wybranych szkodników zbóż. Celem było wytworzenie aplikacji przeznaczonej do rozpoznawania szkodników na podstawie ich obrazów prezentowanych w postaci cyfrowych zdjęć. Wytworzony system informatyczny dokonuje neuronowej klasyfikacji z wykorzystaniem sieci neuronowej o radialnych funkcjach bazowych typu RBF (*Radial Basis Function*). Procesowi rozpoznawania poddano 3 następujące szkodniki [10, 13]:

- 1 - Mszycyca czeremchowo-zbożowa.
- 2 - Skrzyplionka zbożowa (*Lema melanopa*).
- 3 - Pryszczarek zbożowiec.

Wymienione agrofagi przedstawiono na rys. 3.




Rys. 3. Wybrane szkodniki zbóż
Fig. 3. Chosen pests of cereals

Jako reprezentatywne cechy stanowiące podstawę klasyfikacji przyjęto 2 grupy parametrów:

- 1- barwę szkodników (zakodowaną zgodnie z modelem koloru RGB [2, 4, 16]),
- 2- wybrane współczynniki kształtu [2, 16]:
 - współczynnik Fereta R_F ,
 - współczynnik Malinowskiej R_M ,
 - bezwymiarowy współczynnik kształtu R_S ,
 - współczynnik regularności R_E .

W celu wytworzenia wektorów (zbiorów) uczących zbudowano pomocnicze narzędzie skalujące i dygitalizujące obrazy szkodników. Instrument ten realizował również proces generowania właściwych współczynników kształtu oraz zakodowanych składowych barwy modelu RGB, a następnie transformował je do postaci akceptowalnej przez symulator generujący model neuronowy. Sieć typu RBF została wytworzona z wykorzystaniem modułu „Sieci neuronowe” zaimplementowanego w pakiecie Statistica. Następnie wygenerowany kod nauczonej sieci został „wyekstrahowany” ze środowiska Statistica (za pomocą dostępnej opcji

„Generator kodu”) i zaimplementowany w zbudowanej, oryginalnej aplikacji „Szkodniki”.



Rys. 4. Interfejs systemu informatycznego „Szkodniki”
Fig. 4. Interface „Szkodniki” („Pests”) system

Modele predykcyjne

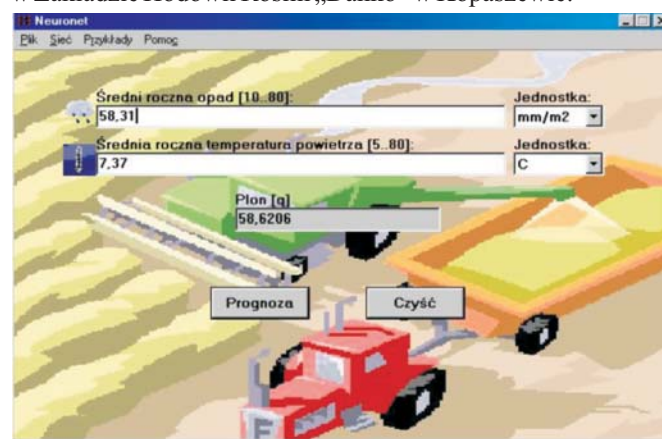
Neuronowe modele predykcyjne, będące w istocie szczególnym przypadkiem modeli regresyjnych, realizują proces wnioskowania wykorzystując ważną cechę sztucznych sieci neuronowych, jaką jest ich zdolność do generalizacji [1, 4]. Efektem pracy wygenerowanego neuronowego modelu predykcyjnego jest estymacja nieznannej wartości zmiennej objaśnianej (na ogół w krótkim okresie prognozowania), reprezentująca przewidywaną prognozę.

- System informatyczny „Neuronet” do predykcji plonu pszenżyta

W projekcie badano problem przewidywania wysokości plonu pszenżyta w oparciu o pozyskane wcześniej dane doświadczalne. Zbiór wejściowy sieci neuronowej stanowiły wyniki badań empirycznych, opisujące parametry warunkujące rozwój i istotny mające wpływ na plon pszenżyta, tj:

- 1 - średni miesięczny opad atmosferyczny,
- 2 - średnia miesięczna temperatura gleby.

Jako zmienną wyjściową przyjęto poszukiwaną wielkość plonu. Wiarygodne informacje dotyczące wielkości plonu pszenżyta w przeszłości, uzyskano w oparciu o dane pozyskane w Zakładzie Hodowli Roślin „Danko” w Kopaszewie.



Rys. 5. Interfejs systemu programu „Neuronet”
Fig. 5. Interface of programme "Neuronet"

Program „Neuronet” prognozuje wielkość plonu pszenżyta na podstawie średniej rocznej temperatury powietrza i średniego opadu atmosferycznego. System działa w oparciu o wygenerowaną w pakiecie Statistica (a następnie zaimplementowaną) perceptronową sieć neuronową typu MLP

(Multilayer Perceptron), uczona techniką „z nauczycielem” z wykorzystaniem algorytmu Levenberga - Marquardta [4, 7].

- System informatyczny „Plon v.1.0” do predykcji plonu wybranych zbóż

System informatyczny „Plon v.1.0” prognozuje wielkość plonu pszenicy, żyta oraz jęczmienia. System działa w oparciu o wygenerowaną w pakiecie Statistica (a następnie zaimplementowaną) radialną sieć neuronową typu RBF (Radial Basis Functions), uczoną hybrydowo w 3 etapach:

- centra wyznaczono za pomocą algorytmu „k-średnich”,
- odchylenia określono za pomocą algorytmu „k-najbliższych sąsiadów”,
- liniowa warstwa wyjściowa uczona była techniką „pseudoinwersji”.



Rys. 6. Interfejs oraz formularze robocze systemu systemu informatycznego "Plon v.1.0"

Fig. 6. Interface of computing system "Plon v.1.0"

Wygenerowany model dokonuje predykcji plonów w oparciu o wartości zadane na wejściu sztucznej sieci neuronowej, stanowiące podstawowe, reprezentatywne wielkości charakterystyczne, warunkujące prawidłowy rozwój tych roślin. Jako cechy reprezentatywne przyjęto następujące 4 zmienne wejściowe:

- 1 - średnią temperaturę miesięczną,
- 2 - średnie opady w miesiącu,
- 3 - średnie miesięczne nasłonecznienie,
- 4 - miesiąc zakodowany w zakresie liczb 1-12.

Do uczenia sieci wykorzystano historyczne dane dotyczące plonów w latach 1995-2003.

Wyjście sieci stanowił poszukiwany plon wskazanej rośliny. W procesie uczenia sieci wykorzystano 108 przypadków podzielonych losowo na trzy zbiory: uczący (57 przypadków), walidacyjny (36 przypadków) oraz testowy (15 przypadków).

- System informatyczny „PrognozaPlony” do krótko-terminowego prognozowania wybranych plodów rolnych z wykorzystaniem szeregów czasowych

Celem analizy (predykcji) szeregów czasowych jest tu przewidywanie wartości pewnej zmiennej, na podstawie jej wcześniejszych wartości lub wartości innych zmiennych [7]. Wytworzono system informatyczny „PrognozaPlony”, który prezentuje możliwości wykorzystania sztucznych sieci neuronowych typu perceptron wielowarstwowy MLP w postaci szeregów czasowych do krótkoterminowego prognozowania wybranych plonów na przykładzie buraków cukrowych oraz pszenicy. System szacuje przewidywany plon pszenicy oraz buraków cukrowych w określonej perspektywie czasu. Bazą do

zbudowania tego programu był kod wygenerowany w programie Statistica (moduł „Sieci neuronowe” wraz z „Generatorem kodu”) i zaimplementowany następnie w aplikacji „PrognozaPlony” wytworzonej w oparciu o platformę Borland Builder v.6.0. Dane wykorzystane do uczenia sieci neuronowej pochodziły ze źródła GUS: banki i bazy danych, bank danych regionalnych oraz z Roczników Statystycznych z lat 1980-2004.



Rys. 7. Interfejs oraz formularze robocze systemu „PrognozaPlony” do prognozowania plonu pszenicy oraz buraków

Fig. 7. Interface and working form system „PrognozaPlony” (“CropForecast”) to prognose wheat and sugar beet

- System informatyczny „ProgAzot v.1.1” do prognozowania strat azotu z pól nawożonych gnojowicą

Zaprojektowany oraz wytworzony system komputerowy „ProgAzot v.1.1” pozwala na prognozowanie wielkości strat azotu, spowodowanych emisją amoniaku zachodzącą w czasie procesu nawożenia pól gnojowicą [1, 2, 11]. Aplikacja działa w oparciu o 3 - warstwową sztuczną sieć neuronową typu perceptron wielowarstwowy MLP o topologii (4:4-15-5-1:1), uczonej algorytmem wstecznej propagacji błędu BP (Back Propagation). Jako reprezentatywne zmienne wejściowe sieci wybrano 4 czynniki agrotechniczne, mające istotny wpływ na poziom emisji amoniaku z pól nawożonych gnojowicą. Są to:

- 1 - początkowa zawartość azotu amonowego w gnojowicy,
- 2 - aplikowaną dawkę nawozu,
- 3 - okres agrotechniczny,
- 4 - technika, jaką gnojowica była rozlewana po polu.



Rys. 8. „ProgAzot” - interfejs oraz główne okno prognozy

Fig. 8. „ProgAzot” - interface and main window of forecast

Zaprojektowana, wytworzona i przetestowana aplikacja jest narzędziem umożliwiającym oszacowanie skali zagrożenia wzrastającą emisją amoniaku podczas nawożenia gnojowicą. Może być również z powodzeniem wykorzystana przez rolników, np. w celu doboru odpowiedniego terminu, dawki oraz metody rozlewu nawozu.

Podsumowanie

Dynamiczny rozwój technik informatycznych oraz ich coraz bardziej powszechna dostępność staje się istotnym czynnikiem warunkującym postęp oraz rozwój wielu dziedzin rolnictwa. Jednym ze stosunkowo nowo zagospodarowanych obszarów jest próba informatycznego wspomaganie procesów decyzyjnych realizowanych przez człowieka z wykorzystaniem nowoczesnych metod sztucznej inteligencji. Uznane zdolności klasyfikacyjne oraz predykcyjne modeli neuronowych mogą stanowić efektywne wsparcie procesów decyzyjnych zachodzących w wielu obszarach szeroko rozumianej praktyki rolniczej.

Bibliografia

- [1] Boniecki P., Dach J., Pilarski K., Piekarska-Boniecka H.: Artificial neural networks for modeling ammonia emissions released from sewage sludge composting. *Atmospheric Environment*, 2012, 57, 49-54.
- [2] Boniecki P.; Nowakowski, K.; Tomczak, R.: Neural networks type MLP in the process of identification chosen varieties of maize. 3rd International Conference on Digital Image Processing (ICDIP 2011), Proceedings of SPIE, DOI: 10.1117/12.896184.
- [3] Boniecki P., Dach, J., Nowakowski K., Jakubek A.: Neural image analysis of maturity stage during composting of sewage sludge. International Conference on Digital Image Processing (ICDIP 2009), Proceedings: 200-203, DOI: 10.1109/ICDIP.2009.85
- [4] Boniecki P.: Elementy modelowania neuronowego w rolnictwie. Publisher University of Life Sciences, Poznan, 2008.
- [5] Bouharati S., Benmahammed K., Harzallah D. and El-Asaf Y.M.: Application of artificial neural neuro-fuzzy logic inference system for predicting the microbiological pollution in fresh water. *J Appl Sci*, 2008, 8, 309-315.
- [6] Cross J.V., Hall D.R., Shawc P., Anfora G.: Exploitation of the sex pheromone of apple leaf midge *Dasineura mali* Kieffer (Diptera: Cecidomyiidae): Part 2. Use of sex pheromone traps for pest monitoring. *Crop Protection*, 2009, 28, 128-133.
- [7] Hagan M.T. and Menhaj M.B.: Training feed forward networks with the Marquardt algorithm. *IEEE Trans Neural Net*, 2004, 6, 861-867.
- [8] Jaastad G., Trandemb N., Hovland B., Mogan S.: Effect of botanically derived pesticides on mirid pests and beneficials in apple. *Crop Protection*, 2009, 28, 309-313.
- [9] Kierczyńska S.: Consumption of fruit on the background of their production in Poland. *Annals of the Association of Agricultural Economists and Agribusiness VII*, 2005, 8, 108-113.
- [10] Kubiak K., Kogut W., Krajewski A., Lindner E., Maciejczyk-Kempińska U., Mirkowska Z., Strojewska I.: *Arboriculture in Poland*. COBRO, Warsaw, 2000.
- [11] Niżewski P., Boniecki P.: Neuronowy system komputerowy prognozujący poziom emisji amoniaku po nawożeniu gnojowicą. *Journal of Research and Applications in Agricultural Engineering*, 2006, 4, 44-48.
- [12] Wiech K.: *Pests of fruit tree*. Plantpress, Krakow, 1999.
- [13] Wilkaniec B.: *Entomology, detail entomology 2*. PWRiL, 2010.
- [14] Yin Y. and Ding Y.: A close to real-time prediction method of total coliform bacteria in foods based on image identification technology and artificial neural network. *Food Res Int*, 2009, 42, 191-199.
- [15] Zheng H., Jiang B. and Lua H.: An adaptive neural-fuzzy inference system (ANFIS) for detection of bruises on Chinese bayberry (*Myrica rubra*) based on fractal dimension and RGB intensity color. *J Food Eng*, 2011, 104, 663-667.
- [16] Tadeusiewicz R., Korohoda P.: *Komputerowa analiza i przetwarzanie obrazów*. FPT, 1997.

EXAMPLES OF THE USE OF NEURAL MODELING IN AGRICULTURAL PRACTICE

Summary

Artificial Neural Networks can learn, are less sensible to incomplete input information, they are processing entered signals and give results in actual time. The above properties and the analysis during the research allow to make a conclusion that ANN may execute the identification and prediction task similarly to a human being. Thanks to such identification process automation it could be possible to eliminate the subjective factor. Classification and predictive abilities of artificial neural networks are one of the main topics of their application. The aim of this paper was to use these some properties for modeling selected and predictive classification problems encountered in agriculture.

Key words: neuronal modeling; neuronal classifiers; prediction instruments



Podręcznik pt. **MASZYNY ROLNICZE** adresowany jest do szerokiego grona pracowników dydaktycznych i słuchaczy uczelni przyrodniczych oraz użytkowników maszyn rolniczych. Zawarto w nim podstawowe informacje z przedmiotu "Technika rolnicza i eksploatacja maszyn rolniczych" wykładanego na ww. Uczelniach. Problematyka wykładów tego przedmiotu obejmuje charakterystykę szerokiego i niezwykle różnorodnego asortymentu maszyn i urządzeń technicznych. Wyczerpujące omówienie czy opisanie całości materiału jest niemożliwe. Z tych też względów w podręczniku przedstawiono ściśle wyselekcjonowane partie materiału - informacje podstawowe oraz te, które są dziełem autorów lub powstały przy znaczącym ich udziale. Stąd też, pomimo że podręcznik ma charakter pozycji dydaktycznej, nosi znamiona pracy monograficznej. Materiał uzupełniający stanowi literatura zamieszczona na końcu każdego z rozdziałów.

Wydawca:

Branżowy Ośrodek Informacji Naukowej, Ekonomicznej i Normalizacyjnej
Przemysłowy Instytut Maszyn Rolniczych
60-963 Poznań, ul. Starołęcka 31
tel. 48 61 87 12 200; fax 48 61 879 32 62;
e-mail: office@pimr.poznan.pl; Internet: <http://www.pimr.poznan.pl>